



UNIVERSIDADE FEDERAL DO AMAZONAS - UFAM
INSTITUTO DE COMPUTAÇÃO- ICOMP
PROGRAMA PÓS-GRADUAÇÃO EM INFORMÁTICA - PPGI

Integração de Dados de Audiência de TV Linear e Streaming: Um Modelo Computacional para Medição de Engajamento

Raphael Coêlho Santos

Manaus - AM

Março 2026

Raphael Coêlho Santos

Integração de Dados de Audiência de TV Linear e Streaming:
Um Modelo Computacional para Medição de Engajamento

Dissertação submetida ao Programa de Pós-Graduação
em Informática como requisito para obtenção do título
de Mestre em Informática.

Orientador(a)

José Reginaldo H. Carvalho , Dr.

Universidade Federal do Amazonas - UFAM

Instituto de Computação- IComp

Manaus - AM

Março 2026

Ficha Catalográfica

Elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

S237i Santos, Raphael Coêlho
Integração de dados de audiência de tv linear e streaming: um modelo computacional para medição de engajamento / Raphael Coêlho Santos. - 2026.
101 f. : il., color. ; 31 cm.

Orientador(a): José Reginaldo Hughes Carvalho.
Dissertação (mestrado) - Universidade Federal do Amazonas, Programa de Pós-Graduação em Informática, Manaus-AM, 2026.

1. Aprendizado de máquina. 2. Engajamento do público. 3. Streaming. 4. TV linear. 5. Aprendizado por transferência. I. Carvalho, José Reginaldo Hughes. II. Universidade Federal do Amazonas. Programa de Pós-Graduação em Informática. III. Título



Ministério da Educação
Universidade Federal do Amazonas
Coordenação do Programa de Pós-Graduação em Informática

FOLHA DE APROVAÇÃO

"INTEGRAÇÃO DE DADOS DE AUDIÊNCIA DE TV LINEAR E STREAMING: UM MODELO COMPUTACIONAL PARA MEDIÇÃO DE ENGAJAMENTO"

RAPHAEL COÊLHO SANTOS

Dissertação de Mestrado defendida e aprovada pela banca examinadora constituída pelos Professores:

Prof. Dr. José Reginaldo Hughes Carvalho - **Presidente**

Documento assinado digitalmente
gov.br FABIO SANTOS DA SILVA
Data: 19/03/2026 10:51:34-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Fabio Santos Silva - **Membro Externo**

Prof. Dr. Cesar Augusto Viana Melo - **Membro Externo**

Manaus, 06 de Março de 2026.



Documento assinado eletronicamente por **José Reginaldo Hughes Carvalho, Professor do Magistério Superior**, em 09/03/2026, às 13:44, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **César Augusto Viana Melo, Professor do Magistério Superior**, em 10/03/2026, às 11:27, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufam.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **3039663** e o código CRC **08BBD824**.

Referência: Processo nº 23105.007897/2026-77

SEI nº 3039663

Dissertação de Mestrado sob o título *Integração de Dados de Audiência de TV Linear e Streaming: Um Modelo Computacional para Medição de Engajamento*, apresentada por Raphael Coêlho Santos ao Instituto de Computação da Universidade Federal do Amazonas como requisito para obtenção do título de Mestre em Informática.

Dedico este trabalho Àquele que sustenta meus passos
mesmo quando não vejo o caminho.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES-PROEX) - Código de Financiamento 001. Este trabalho foi parcialmente financiado pela Fundação de Amparo à Pesquisa do Estado do Amazonas – FAPEAM – por meio do projeto POSGRAD 2024/2025.

Agradeço, primeiramente, a Deus, por me proporcionar esta jornada acadêmica e por me conceder força e perseverança ao longo deste percurso.

À minha família, pelo apoio constante, pela compreensão nos momentos de ausência e por acreditarem em mim durante toda essa caminhada. O suporte de vocês foi fundamental para que eu pudesse chegar até aqui.

Ao meu orientador, Prof. Dr. José Reginaldo Hughes Carvalho, pela orientação segura, disponibilidade constante e pelas discussões que contribuíram significativamente para o amadurecimento deste trabalho. Sua postura crítica, aliada ao incentivo à autonomia, foi essencial para o desenvolvimento desta pesquisa.

Agradeço também aos membros da banca examinadora, Prof. Dr. Fabio Santos Silva e Prof. Dr. Cesar Augusto Viana Melo, pelas valiosas contribuições, sugestões e pelo tempo dedicado à avaliação deste trabalho. Suas considerações críticas e apontamentos foram fundamentais para o aprimoramento desta pesquisa, contribuindo para uma análise mais rigorosa e para o fortalecimento dos resultados apresentados.

Estendo este agradecimento aos Profs. Drs. Eulanda Miranda dos Santos, Marco Antonio Pinheiro de Cristo, Raimundo da Silva Barreto, Eduardo Luzeiro Feitosa, Eduardo James Pereira Souto e Juan Gabriel Colonna, bem como a todos os professores que contribuíram para minha formação ao longo de toda a minha trajetória acadêmica.

À Rede Amazônica, na pessoa de Eduardo Lopes, pelo apoio inicial e pela intermediação que viabilizou esta pesquisa, e na pessoa de Silvério Machado, pela atenção, pelas orientações e pelo suporte contínuo ao longo de todo o trabalho, com destaque para a autorização e a disponibilização dos dados de audiência da emissora, pelos esclarecimentos técnicos e pelas contribuições fundamentais para a compreensão e interpretação dos dados, bem como do contexto televisivo, essenciais para o desenvolvimento deste estudo.

Ao Marcel Campos, pela disponibilidade em autorizar o uso dos dados de seu canal, assim como pelo apoio ao longo da minha trajetória, por meio de conteúdos e discussões que ampliaram minha visão sobre tecnologia, métricas de engajamento e análise de dados. Sua contribuição, especialmente pelo acesso aos dados e pela abordagem prática com que trata esses temas, foi importante para o desenvolvimento da abordagem adotada neste trabalho.

Ao Robson Damasceno e ao Frank Azevedo, pelo apoio ao longo do processo acadêmico, contribuindo com orientações e suporte em momentos importantes, bem como pela atenção e cordialidade no atendimento aos estudantes. Estendo também meus agradecimentos aos demais integrantes da secretaria do Instituto de Computação (IComp), pela disponibilidade e pelo auxílio nas questões burocráticas e administrativas ao longo do curso.

Por fim, agradeço a todos que, de forma direta ou indireta, contribuíram para a realização deste trabalho. Cada apoio, orientação e incentivo foram fundamentais para a realização deste trabalho.

“Porque o Senhor é quem dá sabedoria; da sua boca procedem o conhecimento e o entendimento.”

Provérbios 2:6

Integração de Dados de Audiência de TV Linear e Streaming: Um Modelo Computacional para Medição de Engajamento

Autor: Raphael Coêlho Santos

Orientador: José Reginaldo H. Carvalho , Dr.

Resumo

Esta pesquisa tem como objetivo investigar a integração e a comparação de dados de audiência provenientes de TV linear, serviços de streaming e do contexto emergente da TV 3.0, propondo um modelo de aprendizado de máquina para interpretar o engajamento do público. Para isso, são analisadas estratégias de compatibilização entre domínios, transformando dados de streaming em representações estruturais compatíveis com os dados agregados da TV linear.

Os resultados mostram que a transferência de conhecimento é sensível às diferenças no regime de observação dos dados, podendo gerar ganhos parciais quando há compatibilidade estrutural, mas também revelando limitações quando os alvos apresentam naturezas distintas. Esses achados delimitam as condições sob as quais a integração entre dados de streaming e TV linear é metodologicamente plausível, contribuindo para o desenvolvimento de abordagens integradas de mensuração de audiência em ambientes híbridos de mídia.

Palavras-chave: Aprendizado de máquina, Engajamento de audiência, Streaming, TV linear.

Integração de Dados de Audiência de TV Linear e Streaming: Um Modelo Computacional para Medição de Engajamento

Autor: Raphael Coêlho Santos

Orientador: José Reginaldo H. Carvalho , Dr.

Abstract

This research aims to investigate the integration and comparison of audience data from linear television, streaming services, and the emerging context of TV 3.0, proposing a machine learning model to interpret audience engagement. To this end, strategies for cross-domain compatibility are analyzed, transforming streaming data into structural representations compatible with aggregated linear TV data.

Results show that knowledge transfer is sensitive to differences in data observation regimes, producing partial gains when structural compatibility exists, but also revealing limitations when target variables differ in nature. These findings delimit the conditions under which integration between streaming and linear TV data is methodologically plausible, contributing to the development of integrated audience measurement approaches in hybrid media environments.

Keywords: Machine learning, Audience engagement, Streaming, Linear TV

LISTA DE ILUSTRAÇÕES

Figura 1 – Arquitetura da solução proposta, organizada em camadas de dados, modelo e aplicação, evidenciando a separação entre fontes de dados, processamento e geração de inferências.	61
Figura 2 – Pipeline proposto de aprendizagem entre domínios. A estrutura de engajamento é aprendida a partir de sinais granulares do domínio de streaming (origem) e adaptada para o domínio da TV linear (alvo) sob restrições de atributos, por meio de harmonização de características e transferência de aprendizado.	62
Figura 3 – Engajamento ativo (TV 2024): dispersão y_{true} vs. y_{pred} para SVR (TV-only).	79
Figura 4 – Engajamento ativo (TV 2024): dispersão y_{true} vs. y_{pred} para MLPRegressor (TV-only).	79
Figura 5 – Engajamento ativo (TV 2024): dispersão y_{true} vs. y_{pred} para Transfer Learning (Estratégia 1).	80
Figura 6 – Engajamento ativo (TV 2024): dispersão y_{true} vs. y_{pred} para Transfer Learning (Estratégia 2).	80
Figura 7 – Engajamento ativo (TV 2024): histograma dos resíduos do MLPRegressor (TV-only).	81
Figura 8 – Engajamento ativo (TV 2024): histograma dos resíduos do Transfer Learning (Estratégia 1).	81
Figura 9 – Engajamento passivo (TV 2024): dispersão y_{true} vs. y_{pred} para SVR (TV-only).	84
Figura 10 – Engajamento passivo (TV 2024): dispersão y_{true} vs. y_{pred} para MLPRegressor (TV-only).	84

Figura 11 – Engajamento passivo (TV 2024): dispersão y_{true} vs. y_{pred} para Transfer Learning (Estratégia 1).	85
Figura 12 – Engajamento passivo (TV 2024): dispersão y_{true} vs. y_{pred} para Transfer Learning (Estratégia 2).	85
Figura 13 – Engajamento passivo (TV 2024): histograma dos resíduos do MLPRegressor (TV-only).	86
Figura 14 – Engajamento passivo (TV 2024): histograma dos resíduos do Transfer Learning (Estratégia 1).	86

LISTA DE TABELAS

Tabela 1 – Bloco 1: trabalhos sobre recomendação em streaming e dinâmica comportamental.	46
Tabela 2 – Bloco 2: trabalhos sobre mensuração de engajamento e sinais associados. . .	47
Tabela 3 – Bloco 3: trabalhos sobre impactos, transparência e implicações de sistemas de recomendação/engajamento.	50
Tabela 4 – Bloco 4: surveys fundamentais de transferência e recomendação cross-domain.	52
Tabela 5 – Bloco 5: trabalhos sobre sinais semânticos e subjetivos (texto, emoção, engajamento social e hábito).	56
Tabela 6 – Tabela geral de comparação dos trabalhos relacionados.	58
Tabela 7 – Principais hiperparâmetros utilizados nos modelos	68
Tabela 8 – Resumo das bases utilizadas.	69
Tabela 9 – Modelo principal — Engajamento Ativo (teste em TV 2024).	78
Tabela 10 – Modelo principal — Engajamento Passivo (teste em TV 2024).	83
Tabela 11 – Efeito relativo previsto pelo modelo para cada tema no período noturno — engajamento ativo (TV 2024).	100
Tabela 12 – Efeito relativo previsto pelo modelo para cada tema no período noturno — engajamento passivo (TV 2024).	101

LISTA DE ABREVIATURAS E SIGLAS

CTR Click-Through Rate

HDR High Dynamic Range

IBOPE Instituto Brasileiro de Opinião Pública e Estatística

ISDB-T Integrated Services Digital Broadcasting – Terrestrial

MAE Mean Absolute Error

MLP Multilayer Perceptron

MSE Mean Squared Error

Pearson Correlação de Pearson

RMSE Root Mean Squared Error

RBF Radial Basis Function

R² Coeficiente de determinação

SBC Sociedade Brasileira de Computação

SBTV Sistema Brasileiro de Televisão Digital

Spearman Correlação de Spearman

SVR Support Vector Regression

TV Televisão

UHD TV Ultra High Definition Television

SUMÁRIO

Lista de abreviaturas e siglas	15
1 INTRODUÇÃO	21
1.1 Motivação	24
1.2 Hipótese	25
1.3 Objetivos	25
1.4 Organização do Trabalho	26
2 FUNDAMENTAÇÃO TEÓRICA	27
2.1 Televisão Linear e Coleta de Audiência	27
2.1.1 Televisão Tradicional no Brasil	27
2.1.2 Modelos de Coleta de Audiência da TV Linear	28
2.1.3 Uso dos Dados de Audiência na TV Tradicional	29
2.1.4 Dificuldades no Desligamento do Sinal Analógico e Implementação da TV Digital no Brasil	30
2.2 Streaming e Coleta de Dados Granulares	31
2.2.1 Conceito e Evolução do Streaming	31
2.2.2 Coleta de Dados nos Serviços de Streaming	32
2.3 Qualidade dos Dados e Interpretação do Engajamento	33
2.4 Formalização do Problema de Interpretação de Engajamento	35
2.4.1 Representação dos Domínios	35
2.4.2 Definição Formal de Engajamento	36
2.4.3 Formulação como Aprendizado Supervisionado	36
2.4.4 Problema de Transferência entre Regimes	37
2.4.5 Relação conceitual entre granularidade e potencial informacional	37

2.5	Aprendizagem de Máquina na Interpretação de Audiência	38
2.6	TV 3.0 e Perspectivas de Convergência	39
2.6.1	Coleta de Dados e Perspectivas da TV 3.0	39
2.7	Síntese Teórica e Implicações para a Pesquisa	40
3	TRABALHOS RELACIONADOS	42
4	SOLUÇÃO PROPOSTA	59
4.1	Visão Geral da Solução	59
4.2	Arquitetura da Solução e Pipeline Metodológico	60
4.3	Definição Conceitual dos Atributos	62
4.3.1	Atributos de Perfil	62
4.3.2	Atributos de Conteúdo	63
4.3.3	Atributos Temporais	63
4.3.4	Implicações para Aprendizagem de Máquina	63
4.4	Definição Conceitual de Engajamento	64
4.4.1	Engajamento Ativo	64
4.4.2	Engajamento Passivo	64
4.4.3	Diferenças entre TV e Streaming	64
4.5	Estratégia de Aprendizado	64
4.5.1	Por que Regressão	64
4.5.2	Escolha dos Modelos SVR e MLP	65
4.5.3	Uso de Transfer Learning	65
4.5.4	Estratégias Avaliadas	65
4.6	Configuração dos Modelos e Definição de Hiperparâmetros	65
4.6.1	Pré-processamento dos Dados	65
4.6.2	Configuração do SVR	66
4.6.3	MLP Baseline (Scikit-learn)	66
4.6.4	MLP com Transfer Learning	66
4.6.5	Estratégia de Treinamento	67
4.6.6	Estratégia de Validação	67

4.6.7	Complexidade Computacional	67
5	EXPERIMENTOS E RESULTADOS	69
5.1	Bases de Dados	69
5.1.1	TV linear (2023 e 2024)	69
5.1.2	Streaming (YouTube)	70
5.2	Preparação e Harmonização dos Dados	71
5.2.1	Harmonização temática e <i>one-hot encoding</i>	71
5.2.2	Variáveis temporais e categoria “Desconhecido”	71
5.2.3	Padronização demográfica e conjunto final de <i>features</i>	72
5.3	Definição das Variáveis-Alvo	72
5.3.1	Engajamento ativo no streaming	72
5.3.2	Engajamento passivo no streaming: evolução e escolha do <i>z-score</i>	73
5.3.3	Engajamento passivo na TV: proxy contextual por razão	73
5.4	Modelos Utilizados	74
5.4.1	SVR	74
5.4.2	MLP	74
5.4.3	Transfer Learning (streaming → TV)	75
5.5	Protocolo Experimental	75
5.5.1	Estratégias de treino/teste e avaliação temporal	75
5.5.2	Métricas	75
5.6	Resultados Experimentais	76
5.6.1	Modelos interpretáveis: Árvore de Decisão e Floresta Aleatória	76
5.6.2	Configuração do modelo principal e protocolo experimental	76
5.6.3	Resultados — Engajamento Ativo	77
5.6.4	Resultados — Engajamento Passivo	82
5.6.5	Discussão: vazamento temporal, diferença de escala e falha da Estratégia 2	87
5.6.6	Análise de temas no período noturno (TV 2024)	88
5.7	Síntese dos Resultados	88

6	DISCUSSÃO E CONCLUSÕES	89
6.1	Discussão dos Resultados	89
6.2	Implicações metodológicas sobre o alvo e compatibilidade entre domínios	92
6.3	Limitações do Trabalho	93
6.4	Contribuições da Pesquisa	94
6.5	Trabalhos Futuros	94
6.6	Considerações Finais	95
	Referências	97
APÊNDICE A	PRIMEIRO APÊNDICE	100
A.1	Análise Contrafactual de Temas — Engajamento Ativo (Pe- ríodo Noturno, TV 2024)	100
A.2	Análise Contrafactual de Temas — Engajamento Passivo (Período Noturno, TV 2024)	101

1

INTRODUÇÃO

O Desenvolvimento tecnológico em comunicação de massa frequentemente resulta na criação de jargões e na formação de senso comum que sustentam a ideia propagandística de substituição e defasagem de tecnologias e métodos considerados obsoletos frente à chegada de inovações mais modernas. Afirmações como “o cinema substituiria o teatro”, “a televisão substituiria o cinema” e, mais recentemente, “as plataformas de streaming substituirão a televisão” são recorrentes nesse contexto.

A implementação dos serviços de streaming no consumo de mídias tem fomentado um novo modelo de consumo de conteúdo audiovisual, caracterizado por um deslocamento do conteúdo, antes exibido exclusivamente em televisores, para outras plataformas e dispositivos. Esse fenômeno não é novo, considerando que um processo similar ocorreu com o cinema em relação à televisão no passado ([SVARTMAN, 2023](#)).

Porém, a substituição de uma tecnologia por outra nem sempre é rápida ou homogênea. Embora o surgimento de novas formas de consumo de mídia, como o streaming, tenha alterado significativamente o panorama audiovisual, a transição tecnológica em ambientes de comunicação de massa enfrenta múltiplos desafios. O processo de desligamento do sinal analógico de televisão no Brasil e a implementação da TV digital, por exemplo, encontraram obstáculos técnicos e sociais, incluindo a necessidade de garantir cobertura digital para 93% dos domicílios e a superação de barreiras logísticas e econômicas, especialmente em regiões menos favorecidas ([ZAMBELLI, 2023](#)). Esses desafios indicam que a adoção de novas tecnologias, como a TV 3.0, que pretende integrar as características dos serviços de streaming, pode enfrentar um caminho semelhante, repleto de complexidades e resistência ([LIMA, 2021](#); [KNEIPP, 2023](#)).

O modelo contemporâneo de consumo televisivo é dividido em duas categorias principais: televisão linear e televisão não linear. A televisão linear é caracterizada pela exibição de uma grade de programação preestabelecida, subdividida entre TVs abertas, que dependem de audiência e venda de horários publicitários, e TVs fechadas, que dependem do pagamento de assinaturas pelos espectadores. Por outro lado, a televisão não linear se define pela distribuição de conteúdo em catálogos e exibição sob demanda, sem a necessidade de uma grade de programação fixa — ou seja, as plataformas de streaming ([CASTELLANO; MEIMARIDIS, 2021](#)).

Alguns teóricos introduzem o conceito de “hiper televisão” como uma fusão dessas duas categorias, representando uma evolução do modelo tradicional de televisão, na qual, tanto na transmissão ao vivo quanto sob demanda, os espectadores têm uma maior interatividade com o conteúdo, estabelecendo um relacionamento direto entre criadores e audiência ([SVARTMAN, 2023](#)).

Essas duas categorias apresentam modelos distintos de medição da qualidade da experiência do usuário. Na televisão linear, o modelo de negócios depende da audiência, sendo baseado na venda de espaço publicitário proporcional ao número de telespectadores sintonizados em um canal, programa e horário específicos. No Brasil, a medição de audiência é realizada pelo Ibope, que coleta informações por meio de dispositivos instalados nas TVs dos lares selecionados, registrando automaticamente as escolhas de canal e transmitindo esses dados por sinais de rádio ou operadoras de celular. Esses dados são baseados em uma amostra estatística representativa da população total de telespectadores ([BECKER; GAMBARO; FILHO, 2015](#)).

Em contraste, na televisão não linear — as plataformas de streaming — a medição de audiência é realizada diretamente pelos servidores que disponibilizam o conteúdo, permitindo a diferenciação entre os perfis dos usuários. Nesse caso, não há necessidade de uma empresa especializada em medição, pois todos os dados dos espectadores e usuários da plataforma são coletados em sua totalidade.

Para obter maior precisão na interpretação dos dados coletados, ambas as categorias de televisão adotam estratégias diferentes. No caso da televisão linear, a busca por maior precisão na interpretação dos dados sobre a qualidade da experiência do espectador pode envolver a realização de pesquisas de satisfação, com amostras populacionais diversificadas. Os espectadores selecionados assistem ao conteúdo e respondem a questionários com críticas e sugestões que

podem ser utilizadas para aprimorar a produção.

Já as plataformas de streaming fazem uso comum de técnicas de inteligência artificial e aprendizado de máquina para a coleta e interpretação dos dados dos espectadores. Essas técnicas são utilizadas para melhorar a recomendação de novos conteúdos aos usuários, com base em seus perfis e interesses, bem como para aumentar a precisão na exibição de anúncios, identificando usuários com maior probabilidade de realizar compras ([CASTELLANO; MEIMARIDIS, 2021](#)).

Apesar do avanço significativo das técnicas de coleta e interpretação de dados adotadas pelas plataformas de streaming, observa-se que esses métodos permanecem, em grande parte, restritos ao domínio não linear, no qual a disponibilidade de dados é ampla, contínua e individualizada. Em contrapartida, a televisão linear ainda depende de modelos de medição baseados em amostragens estatísticas e atributos limitados, o que impõe restrições à profundidade e à granularidade da interpretação do comportamento dos telespectadores.

A literatura recente evidencia esforços voltados à melhoria da medição de audiência tanto na televisão linear quanto nas plataformas de streaming; contudo, ainda são escassos os trabalhos que investigam, de forma sistemática, a transferência de conhecimento entre esses dois domínios, especialmente considerando cenários de restrição de atributos característicos da TV linear. Em particular, observa-se uma lacuna quanto à exploração de modelos capazes de aprender padrões de engajamento a partir de dados ricos de streaming e, posteriormente, aplicar esse conhecimento em contextos nos quais apenas dados reduzidos e agregados estão disponíveis.

Essa lacuna torna-se ainda mais relevante no contexto brasileiro, marcado por uma transição tecnológica gradual e heterogênea, na qual a consolidação de novos padrões, como a TV 3.0, tende a ocorrer de forma progressiva. Nesse cenário, a dependência exclusiva de soluções futuras pode atrasar avanços significativos na interpretação do comportamento da audiência televisiva. Assim, torna-se pertinente investigar abordagens intermediárias que permitam aprimorar a interpretação dos dados de audiência da TV linear a partir do aproveitamento do conhecimento já consolidado no domínio do streaming.

Diante desse contexto, emerge o seguinte problema de pesquisa: é possível interpretar o engajamento dos usuários da TV linear com desempenho comparável ao obtido nas plataformas de streaming, mesmo sob restrição de atributos, por meio da transferência de conhecimento aprendida em dados mais ricos? A busca por responder a essa questão fundamenta a proposta

deste trabalho e orienta a definição de sua motivação, hipótese e objetivos.

Ao investigar essa questão, os experimentos conduzidos nesta pesquisa revelam um aspecto estrutural importante: a transferência direta de modelos de engajamento aprendidos em dados de streaming para o domínio da TV linear, sob restrição de atributos, mostra-se instável e pode resultar em transferência negativa, evidenciando limitações fundamentais da adaptação entre regimes de observação com diferentes granularidades.

1.1 Motivação

O longo e complexo processo de transição do sinal analógico para o digital no Brasil, marcado por obstáculos técnicos, sociais e econômicos, evidencia a necessidade de soluções alternativas para a interpretação dos dados de audiência televisiva enquanto novas tecnologias, como a TV 3.0, não se consolidam plenamente ([ZAMBELLI, 2023](#); [LIMA, 2021](#); [KNEIPP, 2023](#)). A experiência do desligamento do sinal analógico demonstra que a adoção de novos padrões tecnológicos ocorre de forma gradual e heterogênea, o que reforça a importância de investigar abordagens capazes de aprimorar a interpretação da audiência a partir da infraestrutura e dos dados atualmente disponíveis.

A interpretação dos dados de audiência da TV linear apresenta desafios inerentes à sua natureza amostral e à limitação de atributos disponíveis, uma vez que as medições tradicionais se baseiam em pesquisas populacionais e em dispositivos instalados em um conjunto restrito de domicílios ([BECKER; GAMBARO; FILHO, 2015](#)). Em contraste, as plataformas de streaming operam com dados completos e altamente granulares, coletados diretamente de todos os seus usuários, permitindo análises mais detalhadas do comportamento e do engajamento da audiência.

Diante desse cenário, surge a motivação para investigar se o conhecimento aprendido a partir de dados ricos de streaming pode ser transferido para o domínio da TV linear, mesmo sob restrição de atributos. A possibilidade de empregar modelos de aprendizagem de máquina treinados em contextos de alta disponibilidade de dados e aplicá-los em cenários mais limitados representa um desafio relevante do ponto de vista científico, com potencial para ampliar a compreensão do engajamento dos telespectadores e aprimorar os processos de interpretação da audiência televisiva. Como consequência, tais avanços podem contribuir para práticas mais

precisas de recomendação de conteúdo e anúncios no contexto da TV linear.

1.2 Hipótese

A hipótese deste trabalho é que, ao transformar dados ricos de usuários de plataformas de streaming em um formato compatível com os dados tradicionalmente disponíveis na TV linear, é possível treinar modelos de aprendizagem de máquina capazes de interpretar padrões de engajamento com desempenho comparável ao observado no domínio de streaming, mesmo sob restrição de atributos. Tal abordagem permitiria ampliar a capacidade de interpretação do engajamento dos telespectadores da TV linear a partir do conhecimento transferido entre domínios distintos. Entretanto, investiga-se também a possibilidade de que diferenças estruturais entre os regimes de observação possam limitar a generalização do modelo, produzindo instabilidade ou degradação de desempenho após a transferência.

1.3 Objetivos

Desenvolver um modelo de aprendizagem de máquina capaz de interpretar o engajamento de usuários da TV linear a partir da transferência de conhecimento aprendida em dados de streaming, mesmo sob restrição de atributos, visando obter desempenho comparável na interpretação da audiência em ambos os domínios.

Objetivos específicos incluem:

- Definir um conjunto de atributos relevantes para a análise de engajamento dos usuários, assegurando a compatibilidade entre os domínios de streaming e TV linear;
- Construir um conjunto de dados reduzido, no formato característico da TV linear, a partir da adaptação e transformação de dados completos provenientes de plataformas de *streaming*;
- Treinar e validar modelos de aprendizagem de máquina utilizando dados completos (streaming) e dados reduzidos (TV linear), analisando a capacidade de interpretação do engajamento dos usuários sob restrição de atributos;

- Avaliar o potencial de aplicação dos modelos propostos em cenários de recomendação de conteúdo e anúncios no contexto da TV linear.

1.4 Organização do Trabalho

Este trabalho está organizado em seis capítulos, além das referências e dos apêndices. O Capítulo 1 apresenta a introdução, incluindo a motivação, a hipótese, os objetivos e a contextualização geral da pesquisa.

O Capítulo 2 apresenta a fundamentação teórica, abordando os modelos de coleta de audiência na TV linear, os mecanismos de coleta de dados em serviços de streaming, conceitos de qualidade dos dados e interpretação de engajamento, bem como a formalização do problema de aprendizado e as perspectivas associadas à TV 3.0.

O Capítulo 3 descreve os trabalhos relacionados, discutindo pesquisas anteriores sobre medição de audiência, interpretação de dados de consumo audiovisual e aplicações de aprendizado de máquina nesse contexto.

O Capítulo 4 apresenta a solução proposta, detalhando a arquitetura metodológica, a definição conceitual dos atributos e do engajamento, além das estratégias de aprendizado adotadas, incluindo o uso de regressão, modelos SVR e MLP e abordagens de transferência entre domínios.

O Capítulo 5 descreve os experimentos e resultados, contemplando as bases de dados utilizadas, os processos de preparação e harmonização, a definição das variáveis-alvo, os modelos empregados, o protocolo experimental e a análise dos resultados para engajamento ativo e passivo, incluindo discussões metodológicas sobre diferenças de escala, vazamento temporal e limitações da transferência.

Por fim, o Capítulo 6 apresenta a discussão e as conclusões, sintetizando os resultados, discutindo implicações metodológicas, limitações do estudo, contribuições da pesquisa e direções para trabalhos futuros. As referências bibliográficas e os apêndices complementam o trabalho com material adicional.

2

FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, apresentam-se os principais conceitos teóricos e tecnológicos que fundamentam esta dissertação. Inicialmente, são discutidos os modelos de coleta de dados de audiência na televisão aberta, incluindo a TV digital e as perspectivas da TV 3.0, bem como os sistemas de streaming e suas estratégias de coleta de dados. Em seguida, são analisadas as características e limitações dos métodos tradicionais de medição de audiência, com ênfase na qualidade e na granularidade dos dados disponíveis. Por fim, o capítulo aborda conceitos relacionados à interpretação do engajamento do público em mídias audiovisuais, estabelecendo a base teórica necessária para a proposta de integração e análise dos dados desenvolvida neste trabalho.

2.1 Televisão Linear e Coleta de Audiência

2.1.1 Televisão Tradicional no Brasil

A televisão brasileira teve início na década de 1950, seguindo inicialmente o modelo de transmissão do rádio, com foco em programação local e regional. Embora as emissoras de televisão sejam concessões públicas, desde sua origem a televisão no Brasil consolidou-se como uma iniciativa predominantemente privada, conduzida por grupos empresariais que já atuavam no setor de mídia impressa e radiofônica. A primeira emissora, a TV Tupi de São Paulo, pertencia ao empresário Assis Chateaubriand, figura central no desenvolvimento do sistema televisivo nacional. Esse processo diferencia-se do modelo europeu, no qual a televisão foi majoritariamente estruturada

como um serviço público.

Com a expansão do mercado televisivo e o aumento das receitas publicitárias, as emissoras brasileiras passaram a assumir integralmente as etapas de produção, exibição e distribuição de conteúdo. Esse movimento contribuiu para a consolidação de grandes redes nacionais, viabilizadas por avanços tecnológicos financiados tanto pelos lucros do setor quanto por interesses políticos e econômicos nacionais (SVARTMAN, 2023). Como resultado, a televisão aberta estabeleceu-se como o principal meio de comunicação de massa no país durante décadas.

Apesar das transformações recentes no consumo de mídia, a TV tradicional ou linear ainda desempenha um papel relevante, sobretudo em regiões com acesso limitado à internet. No entanto, diferentemente das plataformas digitais, a estrutura da televisão linear mantém um modelo de programação fixa e um sistema de medição de audiência baseado em amostragem, o que impõe restrições à forma como o comportamento do telespectador pode ser observado e interpretado. Embora a televisão digital represente um avanço em termos de qualidade de imagem e som, a estratégia de coleta de dados de audiência adotada no Brasil permanece, em essência, semelhante à da TV analógica.

2.1.2 Modelos de Coleta de Audiência da TV Linear

No Brasil, a principal entidade responsável pela medição de audiência televisiva é o Kantar IBOPE Media (doravante, IBOPE). O processo de coleta é realizado por meio de dispositivos conhecidos como audímetros ou *people meters*, instalados em residências previamente selecionadas. Esses dispositivos registram automaticamente informações referentes ao canal assistido e ao tempo de permanência, transmitindo os dados coletados para a central de processamento por meio de sinais de rádio ou redes celulares (BECKER; GAMBARO; FILHO, 2015).

A medição de audiência concentra-se, historicamente, na Região Metropolitana de São Paulo, utilizando uma amostra composta por aproximadamente 760 residências, conforme descrito por (BECKER; GAMBARO; FILHO, 2015). Nesse modelo, cada ponto percentual de audiência corresponde à proporção de domicílios ou indivíduos da amostra que assistiram a determinado programa em um intervalo específico. Por exemplo, um índice de 10 pontos indica que 10% da população amostral esteve exposta ao conteúdo analisado (BECKER; GAMBARO;

[FILHO, 2015](#)).

Esses índices desempenham papel central no modelo de negócios da televisão aberta, fundamentado na comercialização de espaços publicitários. Anunciantes utilizam os dados de audiência para definir horários e programas com maior potencial de alcance, enquanto emissoras com maiores índices podem negociar valores mais elevados para inserções comerciais. Embora aspectos qualitativos da audiência, como perfil demográfico e comportamento de consumo, também sejam considerados, a métrica predominante continua sendo o volume agregado de telespectadores ([BECKER; GAMBARO; FILHO, 2015](#)).

Com base em dados do Kantar IBOPE Media, Cassaro ([CASSARO, 2021](#)) indica que, entre as emissoras de TV aberta, apenas a TV Globo apresentou audiência superior à do streaming ao longo do dia, tanto no período integral de 24 horas quanto na chamada faixa comercial, das 7h à 0h. Em contrapartida, após um período de crescimento contínuo, os canais de TV por assinatura passaram a registrar queda de audiência a partir de 2017 ([CASSARO, 2021](#)). Durante a pandemia de COVID-19, em 2020, o consumo de streaming na faixa comercial atingiu cerca de 15% do mercado brasileiro, evidenciando uma mudança significativa nos hábitos de consumo audiovisual ([CASSARO, 2021](#)).

Apesar de sua relevância histórica e econômica, o modelo de medição baseado em amostragem apresenta limitações importantes. A baixa granularidade dos dados impede a observação detalhada do comportamento individual dos telespectadores, restringindo a interpretação de padrões mais complexos de engajamento. Além disso, o caráter estatístico da amostra pode introduzir vieses relacionados à representatividade populacional, especialmente em um contexto de fragmentação do consumo de mídia e crescimento acelerado das plataformas digitais. Esses fatores têm motivado questionamentos quanto à precisão dos índices fornecidos pelo IBOPE, sobretudo diante da expansão do streaming a partir de 2015 ([BECKER; GAMBARO; FILHO, 2015](#)).

2.1.3 Uso dos Dados de Audiência na TV Tradicional

Os dados de audiência coletados por agências como o IBOPE são utilizados, primordialmente, para orientar decisões estratégicas das emissoras de televisão. Esses dados subsidiam ajustes na

grade de programação, permitindo que conteúdos sejam realocados ou reformulados de acordo com a resposta do público (CASSARO, 2021). Ademais, constituem a base para a negociação de contratos publicitários, uma vez que anunciantes buscam maximizar o alcance de suas campanhas ao selecionar programas e horários com maior audiência (BECKER; GAMBARO; FILHO, 2015).

Os índices também permitem a identificação de tendências de consumo ao longo do tempo, possibilitando que emissoras adaptem seus conteúdos e estratégias de marketing. No entanto, a dependência de métricas agregadas limita a compreensão aprofundada do perfil e do engajamento dos telespectadores, dificultando a adoção de estratégias mais personalizadas e baseadas em comportamento individual (CASSARO, 2021).

2.1.4 Dificuldades no Desligamento do Sinal Analógico e Implementação da TV Digital no Brasil

O processo de desligamento do sinal analógico e a transição para a TV digital no Brasil envolveram desafios técnicos, sociais e econômicos significativos. Um dos principais entraves foi a exigência de assegurar que ao menos 93% dos domicílios brasileiros tivessem acesso ao sinal digital, de modo a evitar a exclusão de parcelas da população, especialmente em regiões menos favorecidas (ZAMBELLI, 2023). A distribuição de kits de conversão digital para famílias de baixa renda enfrentou obstáculos logísticos e dificuldades relacionadas à falta de informação adequada.

A complexidade geográfica e demográfica do país também impactou negativamente o processo. A extensa área territorial e a necessidade de digitalização de um grande número de estações transmissoras tornaram a cobertura total onerosa, sobretudo em áreas de baixa densidade populacional (LIMA, 2021). Adicionalmente, a resistência de emissoras em liberar a faixa de 700 MHz para serviços de telefonia móvel contribuiu para atrasos na implementação (KNEIPP, 2023).

Esses fatores evidenciam que a transição tecnológica da televisão no Brasil extrapola questões puramente técnicas, envolvendo desafios estruturais, sociais e institucionais (ZAMBELLI, 2023; LIMA, 2021; KNEIPP, 2023). A experiência acumulada durante o desligamento do sinal analógico sugere que a adoção plena de novos padrões, como a TV 3.0, tende a ocor-

rer de forma gradual e complexa. Nesse contexto, a necessidade de modelos mais eficientes de interpretação dos dados de audiência da TV linear permanece atual, uma vez que a plena implementação de mecanismos de coleta comparáveis aos das plataformas de streaming pode demandar um período prolongado ([ZAMBELLI, 2023](#); [LIMA, 2021](#); [KNEIPP, 2023](#)).

2.2 Streaming e Coleta de Dados Granulares

2.2.1 Conceito e Evolução do Streaming

A tecnologia de streaming permite a transferência contínua de dados multimídia via internet, possibilitando que usuários assistam a vídeos, ouçam músicas ou acessem outros tipos de conteúdo em tempo real, sem a necessidade de realizar o download completo do arquivo antes do início da reprodução ([BALLERINI; KÜNSCH, 2022](#)). Esse modelo de transmissão representa uma mudança significativa em relação às mídias tradicionais, ao dissociar o consumo de conteúdo da necessidade de armazenamento local e de grades fixas de programação.

Ao longo do processo de evolução tecnológica, a televisão e outras mídias audiovisuais passaram por transformações relevantes, desde a introdução da TV em cores até o surgimento do HD, do controle remoto e de sistemas avançados de áudio. Nesse contexto, a incorporação da internet como meio de transmissão consolidou o streaming como um novo paradigma de consumo audiovisual, caracterizado pela flexibilidade, pela personalização e pelo acesso sob demanda a grandes catálogos de conteúdo ([ALBARDÍA IRATI AGIRREAZKUENAGA ONAINDIA, 2023](#)).

Serviços de streaming, como Netflix e YouTube, alteraram de forma substancial os hábitos de consumo, ao oferecerem bibliotecas extensas de vídeos acessíveis a qualquer momento e em múltiplos dispositivos. Essa mudança conferiu maior autonomia aos usuários, que passaram a decidir o que assistir, quando assistir e em qual dispositivo, redefinindo a relação entre audiência e conteúdo ([HIRTH; SANTOS, 2020](#)). Segundo Rothenberg (1999), citado por Custódio ([CUSTODIO, 2024](#)), a tecnologia de streaming foi desenvolvida por Robert Denis Glaser, possibilitando a transmissão de áudio e vídeo em tempo real via internet e sendo posteriormente incorporada e aprimorada por grandes empresas do setor tecnológico, como Microsoft e Apple.

Nos últimos anos, os serviços de streaming ganharam ampla popularidade, especialmente entre as gerações mais jovens, que valorizam a liberdade de escolha, a autonomia no consumo e a diversidade de opções disponíveis. Esse crescimento acelerado consolidou o streaming como um dos principais meios de acesso a conteúdos audiovisuais na atualidade ([MARTINS LETICIA DE LIMA ALMEIDA, 2023](#)).

2.2.2 Coleta de Dados nos Serviços de Streaming

Diferentemente da televisão linear, os serviços de streaming realizam a coleta de dados de audiência de forma contínua e individualizada, registrando informações detalhadas sobre o comportamento dos usuários. Entre os dados coletados estão o conteúdo assistido, o tempo de visualização, o dispositivo utilizado, as interações realizadas, preferências explícitas, feedbacks e informações demográficas. Esses dados podem ser obtidos tanto de usuários autenticados quanto de usuários não logados, permitindo a construção de perfis comportamentais detalhados ([CUSTODIO, 2024](#); [AMORIM; BARRETO, 2022](#)).

Plataformas como a Netflix, por exemplo, monitoram de maneira sistemática os hábitos de visualização de seus usuários, incluindo padrões como o *binge-watching*, a fim de compreender preferências individuais e ajustar tanto as recomendações quanto a oferta de conteúdos ([OLIVEIRA, 2020](#)). Dados levantados pelo IBGE em 2022 indicam que, em residências com televisão, 43,4% — correspondentes a aproximadamente 31,1 milhões de domicílios — utilizam algum serviço de streaming de vídeo pago, evidenciando a ampla penetração desse modelo no Brasil ([MARTINS LETICIA DE LIMA ALMEIDA, 2023](#)).

A coleta de dados nas plataformas de streaming caracteriza-se pela alta dimensionalidade das informações disponíveis. Cada usuário pode ser descrito por um grande número de atributos relacionados ao consumo de conteúdo, histórico de navegação, padrões temporais de uso e interações explícitas, como avaliações positivas ou negativas. Para lidar com esse volume e diversidade de dados, as plataformas empregam algoritmos de inteligência artificial e técnicas de *deep learning*, capazes de analisar grandes conjuntos de dados e identificar padrões complexos de comportamento ([ALBARDÍA IRATI AGIRREAZKUENAGA ONAINDIA, 2023](#)).

Os dados coletados são utilizados para múltiplas finalidades, com destaque para a

personalização da experiência do usuário. Por meio de modelos computacionais avançados, os serviços de streaming recomendam conteúdos alinhados aos interesses individuais, aumentando a relevância das sugestões apresentadas ([ALBARDÍA IRATI AGIRREAZKUENAGA ONAINDIA, 2023](#)). Adicionalmente, essas informações podem ser utilizadas para fins de segmentação e monetização, incluindo a personalização de recomendações e, em alguns casos, a entrega de comunicações mais relevantes ao perfil do usuário, o que tende a aumentar a probabilidade de engajamento ([ALBARDÍA IRATI AGIRREAZKUENAGA ONAINDIA, 2023](#)).

A Netflix, em particular, utiliza os dados coletados não apenas para aprimorar seus sistemas de recomendação, mas também para orientar decisões estratégicas relacionadas à produção de novos conteúdos e à organização de seu catálogo ([OLIVEIRA, 2020](#)). De forma complementar, os dados possibilitam a melhoria contínua da interface, da navegação e das funcionalidades das plataformas, contribuindo para uma experiência de uso mais eficiente e satisfatória ([ALBARDÍA IRATI AGIRREAZKUENAGA ONAINDIA, 2023](#)).

Esse conjunto de práticas evidencia que o streaming não apenas compete com a TV aberta digital e a TV por assinatura, mas redefine os modelos de consumo audiovisual ao explorar dados individuais, completos e de alta granularidade. A disponibilidade desses dados torna as plataformas mais eficientes tanto na personalização do conteúdo quanto na maximização de oportunidades de monetização, consolidando o streaming como um ambiente privilegiado para a interpretação do engajamento do usuário ([AMORIM; BARRETO, 2022](#); [CUSTODIO, 2024](#)).

2.3 Qualidade dos Dados e Interpretação do Engajamento

O conceito de engajamento do público em mídias audiovisuais está diretamente relacionado à forma como os usuários interagem com os conteúdos consumidos, refletindo níveis distintos de atenção, interesse e envolvimento. A qualidade e a granularidade dos dados coletados exercem papel fundamental na capacidade de interpretar esse engajamento, uma vez que diferentes formas de coleta possibilitam diferentes níveis de observação do comportamento do espectador.

De maneira geral, o engajamento pode ser compreendido a partir de manifestações explícitas e implícitas. O engajamento explícito refere-se a ações diretas realizadas pelo usuário, como avaliações, comentários, curtidas ou compartilhamentos, que indicam de forma clara sua

reação ao conteúdo. Já o engajamento implícito está associado a comportamentos observáveis indiretamente, como o tempo de visualização, a taxa de retenção, a frequência de acesso e os padrões de consumo ao longo do tempo. Esses dois tipos de engajamento fornecem perspectivas complementares sobre a relação do usuário com o conteúdo audiovisual.

A melhoria nos processos de coleta de dados permite uma compreensão mais precisa dos hábitos dos espectadores, viabilizando a criação de conteúdos mais alinhados aos seus interesses e necessidades. Com dados mais detalhados, torna-se possível desenvolver algoritmos de recomendação mais sofisticados, otimizar a programação e, de forma geral, aprimorar a experiência do usuário. Nesse contexto, dados de maior qualidade favorecem a construção de perfis mais representativos, contribuindo para interpretações mais acuradas do engajamento (CUSTODIO, 2024).

Entretanto, existem diferenças significativas entre a interpretação do engajamento na televisão linear e nos serviços de streaming. Na TV tradicional, os dados disponíveis são predominantemente agregados e baseados em amostras estatísticas, o que limita a observação de comportamentos individuais e restringe a análise do engajamento a métricas indiretas e de baixa granularidade. Em contraste, as plataformas de streaming operam com dados individuais, contínuos e de alta dimensionalidade, permitindo a análise simultânea de múltiplos atributos relacionados ao comportamento do usuário.

Essa diferença estrutural implica que, enquanto o streaming possibilita a identificação detalhada de padrões de engajamento explícito e implícito, a TV linear opera majoritariamente com dados reduzidos, nos quais o engajamento precisa ser inferido a partir de informações limitadas. Ainda assim, a integração entre essas abordagens representa uma oportunidade relevante, uma vez que o conhecimento extraído de dados ricos pode auxiliar na interpretação de comportamentos em contextos nos quais apenas dados agregados estão disponíveis.

No contexto brasileiro, iniciativas como a Globoplay ilustram a convergência entre modelos tradicionais e digitais, ao combinar a experiência da televisão com estratégias de coleta e análise de dados típicas do streaming, produzindo conteúdos que dialogam com especificidades culturais da audiência local (HIRTH; SANTOS, 2020). Esse cenário reforça a relevância de investigar métodos capazes de interpretar o engajamento do público a partir de diferentes níveis de disponibilidade e qualidade de dados.

As diferenças estruturais entre os processos de coleta de dados na TV linear e nos serviços de streaming, discutidas nas seções anteriores, podem ser descritas de forma mais precisa por meio de uma modelagem formal dos domínios de dados e das variáveis envolvidas na interpretação do engajamento. A seguir, apresenta-se uma representação matemática simplificada desses domínios, com o objetivo de explicitar o problema computacional investigado neste trabalho.

2.4 Formalização do Problema de Interpretação de Engajamento

2.4.1 Representação dos Domínios

Considere dois domínios distintos de dados de audiência:

- Domínio D_s (Streaming): dados individuais e de alta dimensionalidade
- Domínio D_t (TV Linear): dados agregados e de baixa dimensionalidade

Cada instância no domínio de streaming pode ser representada como:

$$x_s \in R^n, \quad n \gg m$$

onde n representa o número de atributos disponíveis no streaming (interações, tempo de visualização, dispositivo, CTR, retenção etc.).

Já no domínio da TV linear, cada instância é representada por:

$$x_t \in R^m, \quad m \ll n$$

onde m corresponde a atributos agregados como faixa etária, classe social, horário e audiência média.

No caso desta dissertação, x_t inclui variáveis demográficas agregadas e contexto temporal (por exemplo, faixa horária), derivadas de medições em nível de minuto.

2.4.2 Definição Formal de Engajamento

Define-se engajamento como uma variável latente E , estimada a partir de comportamentos observáveis:

$$E = f(x)$$

onde x representa o vetor de atributos observados.

No domínio do streaming:

$$E_s = f_s(x_s)$$

No domínio da TV linear:

$$E_t = f_t(x_t)$$

O objetivo deste trabalho é investigar se é possível aproximar f_t utilizando conhecimento aprendido em f_s , por meio de técnicas de Transfer Learning.

2.4.3 Formulação como Aprendizado Supervisionado

Seja um conjunto de dados de treinamento no domínio do streaming:

$$\mathcal{D}_s = \{(x_s^{(i)}, y^{(i)})\}_{i=1}^N$$

onde $y^{(i)}$ representa uma métrica de engajamento observável.

Nesta pesquisa, y pode representar métricas de engajamento ativo ou passivo, conforme definido no Capítulo de Metodologia.

Treina-se um modelo:

$$\hat{y} = g(x_s; \theta)$$

Posteriormente, busca-se adaptar esse modelo para o domínio da TV:

$$\hat{y}_t = g'(x_t; \theta')$$

onde θ' é obtido por ajuste fino (fine-tuning) ou mapeamento de atributos.

2.4.4 Problema de Transferência entre Regimes

Os domínios apresentam regimes distintos de coleta de dados:

- Regime de observação individual (Streaming): registros granulares em nível de usuário/sessão
- Regime de observação agregada (TV Linear): medidas amostrais e agregadas em nível de minuto/grupo

O problema investigado pode ser descrito como:

$$\text{Aprender } f_s \rightarrow \text{aproximar } f_t$$

sob restrição de redução dimensional:

$$x_s \rightarrow x_t \quad \text{com } m < n$$

Esses termos são utilizados aqui de maneira descritiva para diferenciar contextos de observação individual e contextos baseados em agregações estatísticas. No escopo desta dissertação, essa distinção refere-se ao nível de observação (individual vs. agregado), sem assumir propriedades formais adicionais.

2.4.5 Relação conceitual entre granularidade e potencial informacional

O *potencial informacional observável* pode ser descrito, de forma simplificada, como uma função da dimensionalidade do vetor de atributos disponível para modelagem:

$$I(D) \propto |X|$$

onde $|X|$ representa o número de atributos observáveis no domínio D . Sob essa aproximação, espera-se que $I(D_s) > I(D_t)$, dado que o domínio de streaming disponibiliza mais variáveis descritivas do comportamento de consumo do que a TV linear.

Ressalta-se que essa relação é apenas conceitual: a qualidade efetiva dos dados também depende de fatores como ruído, viés amostral, erros de medição e consistência temporal. O

objetivo desta formulação é destacar o papel da *granularidade observável* como uma das restrições centrais na interpretação do engajamento no domínio da TV linear.

2.5 Aprendizagem de Máquina na Interpretação de Audiência

A aprendizagem de máquina tem sido amplamente empregada na análise de grandes volumes de dados, possibilitando a identificação de padrões e relações complexas que não são facilmente observáveis por meio de métodos tradicionais (HASTIE; TIBSHIRANI; FRIEDMAN, 2009). No contexto da audiência audiovisual, esses modelos são utilizados para interpretar comportamentos de consumo, inferir preferências e estimar níveis de engajamento a partir de conjuntos de dados heterogêneos.

Modelos de aprendizagem supervisionada são particularmente relevantes nesse cenário, uma vez que permitem aprender relações entre atributos observáveis e variáveis de interesse (HASTIE; TIBSHIRANI; FRIEDMAN, 2009), como métricas de engajamento ou audiência. A eficácia desses modelos está diretamente relacionada à qualidade, à quantidade e à diversidade dos atributos disponíveis durante o treinamento. Em ambientes como os serviços de streaming, a abundância de dados individuais e de alta dimensionalidade favorece a aprendizagem de representações mais ricas do comportamento do usuário.

Entretanto, quando esses modelos são aplicados a contextos caracterizados por restrição de atributos, como ocorre na TV linear, surgem desafios adicionais. A redução do número de variáveis disponíveis pode impactar a capacidade de generalização e a precisão dos modelos (HASTIE; TIBSHIRANI; FRIEDMAN, 2009), exigindo estratégias que permitam extrair conhecimento relevante mesmo a partir de dados limitados. Nesse sentido, a transferência de conhecimento entre domínios com diferentes níveis de granularidade de dados emerge como uma abordagem promissora para mitigar as limitações impostas por conjuntos de dados reduzidos.

Assim, a aplicação de aprendizagem de máquina à interpretação da audiência televisiva não se limita ao uso direto de modelos preditivos, mas envolve a investigação de como o conhecimento aprendido em contextos ricos em dados pode ser adaptado e reutilizado em cenários mais restritos. Essa perspectiva fundamenta a proposta deste trabalho, ao explorar a

interpretação do engajamento na TV linear a partir do aprendizado obtido em dados de streaming.

No experimento conduzido neste trabalho, o espaço de atributos harmonizado resultou em 36 variáveis compatíveis entre os domínios, valor que será detalhado no Capítulo de Metodologia, no qual também são descritos o fluxo de processamento e a arquitetura da solução proposta.

2.6 TV 3.0 e Perspectivas de Convergência

A TV 3.0 representa a etapa mais recente no processo evolutivo da televisão digital, propondo a integração mais estreita entre a radiodifusão tradicional e os serviços baseados em internet. Entre seus objetivos centrais estão o aumento da interatividade, a personalização de conteúdos e a ampliação das possibilidades de coleta e interpretação de dados de audiência, aproximando a televisão aberta das características observadas nas plataformas de streaming.

No contexto brasileiro, a TV 3.0 é definida pelo Fórum SBTVD como uma evolução do padrão de transmissão vigente, incorporando requisitos voltados à melhoria da robustez de recepção e ao aumento da taxa de dados, tanto em cenários de recepção fixa quanto móvel. A adoção do padrão Advanced ISDB-T constitui um dos principais avanços técnicos, viabilizando transmissões em ultra alta definição (UHDTV) e oferecendo maior flexibilidade operacional às emissoras, como a possibilidade de sobreposição de transmissões distintas em um mesmo canal (FERNANDES et al., 2022).

Mais do que uma evolução estritamente técnica, a TV 3.0 propõe um novo paradigma conceitual ao integrar conteúdos transmitidos por radiodifusão com serviços providos via internet. Essa convergência possibilita a oferta de experiências audiovisuais mais ricas, com suporte a vídeo em UHD/HDR, áudio imersivo e conteúdos personalizados, além de abrir espaço para novos modelos de negócios no setor televisivo (CUSTODIO, 2024).

2.6.1 Coleta de Dados e Perspectivas da TV 3.0

Do ponto de vista da coleta de dados de audiência, a TV 3.0 é concebida como um ambiente capaz de combinar o amplo alcance da televisão tradicional com a precisão e a granularidade dos dados característicos dos serviços de streaming. Essa integração tem o potencial de ampliar

significativamente a capacidade de interpretação do comportamento do telespectador, permitindo análises mais detalhadas de engajamento e consumo de conteúdo (CUSTODIO, 2024).

Entretanto, a experiência acumulada durante o processo de transição do sinal analógico para o digital no Brasil sugere que a implementação plena de novos padrões tecnológicos tende a ocorrer de forma gradual e heterogênea. Assim, embora a TV 3.0 represente uma perspectiva promissora de convergência entre televisão e internet, sua consolidação pode demandar um período prolongado. Nesse contexto, torna-se relevante investigar abordagens que permitam aprimorar a interpretação dos dados de audiência da TV linear a partir das tecnologias e dos dados atualmente disponíveis, antecipando, em certa medida, as capacidades prometidas pela TV 3.0.

2.7 Síntese Teórica e Implicações para a Pesquisa

A análise dos modelos de coleta e interpretação de dados de audiência discutidos ao longo deste capítulo evidencia diferenças estruturais significativas entre a televisão linear, os serviços de streaming e as perspectivas propostas pela TV 3.0. A televisão linear caracteriza-se por um modelo de medição baseado em amostras estatísticas e dados agregados, o que limita a granularidade das informações disponíveis e restringe a interpretação detalhada do engajamento do público. Em contraste, as plataformas de streaming operam com dados individuais, contínuos e de alta dimensionalidade, possibilitando análises mais precisas do comportamento do usuário e do seu nível de engajamento com os conteúdos consumidos.

A TV 3.0 surge como uma proposta de convergência entre esses dois paradigmas, ao combinar o amplo alcance da radiodifusão tradicional com mecanismos de coleta de dados mais próximos daqueles utilizados pelos serviços baseados em internet. No entanto, a experiência histórica da transição do sinal analógico para o digital no Brasil indica que a implementação plena de novos padrões tecnológicos tende a ocorrer de forma gradual e heterogênea, o que sugere que as capacidades avançadas de coleta e interpretação de dados prometidas pela TV 3.0 podem levar um período significativo para se consolidarem.

Nesse contexto, observa-se uma limitação atual na interpretação do engajamento dos telespectadores da TV linear, decorrente tanto da restrição de atributos disponíveis quanto

da natureza amostral dos dados coletados. Por outro lado, o domínio do streaming dispõe de informações ricas e detalhadas, nas quais modelos de aprendizagem de máquina podem aprender padrões complexos de comportamento e engajamento. Essa assimetria entre os domínios evidencia uma oportunidade relevante de pesquisa: investigar se o conhecimento extraído de dados ricos de streaming pode ser transferido para a interpretação da audiência em cenários caracterizados por dados reduzidos, como ocorre na televisão linear.

Dessa forma, a proposta deste trabalho fundamenta-se na integração conceitual dos elementos discutidos neste capítulo, ao explorar a aplicação de modelos de aprendizagem de máquina capazes de interpretar o engajamento a partir da transferência de conhecimento entre domínios com diferentes níveis de granularidade de dados. A fundamentação teórica apresentada sustenta a necessidade de uma abordagem metodológica que utilize dados completos de streaming para treinar modelos e avalie sua capacidade de generalização quando aplicados a dados compatíveis com o formato da TV linear.

Assim, este capítulo estabelece a base teórica necessária para a metodologia apresentada no capítulo seguinte, na qual são detalhados os procedimentos de construção dos conjuntos de dados, a definição dos atributos de análise e a aplicação dos modelos de aprendizagem de máquina propostos para a interpretação do engajamento da audiência televisiva.

3

TRABALHOS RELACIONADOS

Atualmente, a interpretação de dados de usuários é fundamental para aprimorar a recomendação de anúncios, especialmente nos contextos de TV tradicional, streaming e TV 3.0. Com o avanço das tecnologias e a crescente disponibilidade de dados, novas técnicas têm sido desenvolvidas para interpretar esses dados de forma eficaz e precisa. No entanto, cada plataforma apresenta desafios e oportunidades distintos, refletidos nas técnicas utilizadas para coleta e análise de dados de audiência.

Em TV tradicional, métodos tradicionais de medição de audiência, como os utilizados pelo IBOPE no Brasil, enfrentam desafios significativos, como precisão limitada e falta de flexibilidade. Essas limitações comprometem a eficácia da coleta de dados e reduzem o potencial de personalização de anúncios.

No campo do streaming, a utilização de tecnologias avançadas, como machine learning e big data analytics, permite uma personalização mais eficiente e em tempo real dos anúncios. Este ambiente dinâmico é marcado por uma vasta quantidade de pesquisas e desenvolvimento, evidenciada pela quantidade de artigos encontrados com as palavras-chave relacionadas a streaming. A revisão sistemática identificou um total de 2.963 artigos em 2024 e 3.197 em 2023, que, após a avaliação de títulos e resumos, foram filtrados para 176 e 364 artigos respectivamente.

A TV 3.0, uma evolução da TV tradicional, incorpora tecnologias emergentes como Internet das Coisas (IoT) e Inteligência Artificial (IA), oferecendo novas possibilidades para a coleta e interpretação de dados de usuários. No entanto, as pesquisas nesse campo ainda são relativamente escassas, com apenas 51 artigos relevantes encontrados com as palavras-chave relacionadas a 'TV 3.0 AND Television audience' e 3 artigos relevantes sobre coleta de dados de

usuários usando a tecnologia ROUTE/DASH.

Neste capítulo, são apresentados artigos científicos que utilizam diversas técnicas para a interpretação de dados de usuários, considerando as características e desafios específicos de cada plataforma. A análise crítica dos resultados destaca a predominância de tecnologias como Inteligência Artificial, machine learning e análise de dados, especialmente em streaming, onde essas técnicas são amplamente aplicadas para oferecer recomendações de anúncios mais precisas e personalizadas.

Esta revisão sistemática contribui para o entendimento das diferentes técnicas utilizadas para interpretação de dados de usuários e seu impacto na recomendação de anúncios. Ela fornece uma base sólida para futuras pesquisas e desenvolvimentos na área, sugerindo que estudos comparativos mais detalhados possam fornecer insights valiosos para a indústria, especialmente na aplicação de técnicas de streaming na TV tradicional e TV 3.0.

No artigo de Nikita Jain Nahar, L. K. Vishwamitra e Deepak Sukheja ([NAHAR; VISHWAMITRA; SUKHEJA, 2023](#)), os autores propõem um sistema de recomendação baseado em aprendizado colaborativo para plataformas de streaming de conteúdo, utilizando a técnica de clusterização de Fatoração de Matrizes Não Negativas (Non-Negative Matrix Factorization, NNMFC). A NNMFC decompõe uma matriz de interações usuário-item em duas matrizes menores, facilitando a identificação de padrões latentes, como preferências de usuário por tipos específicos de conteúdo. Além disso, o modelo incorpora a otimização com Enxame de Partículas (Particle Swarm Optimization, PSO), uma técnica inspirada no comportamento social de animais que busca otimizar parâmetros do modelo. A Aprendizagem Colaborativa é utilizada para prever itens que um usuário pode gostar, com base nas preferências de outros usuários semelhantes. O estudo demonstrou que o uso dessas técnicas resultou em um Erro Quadrático Médio (RMSE) de 0.9, indicando alta precisão nas recomendações em comparação com métodos existentes como Filtragem Colaborativa e K-Mean.

Em Gao, Liu e Zhao ([GAO; ZHAO, 2023](#)), um modelo de recomendação denominado "Dynamic Representations for Live Streaming Rooms (DRIVER)" foi desenvolvido para melhorar a experiência dos usuários em plataformas de transmissão ao vivo. O DRIVER utiliza aprendizado de representação dinâmica para recomendar salas com base nos caminhos comportamentais dos

usuários, integrando o Framework Integrado para Modelagem de Caminho do Consumidor e a teoria da afordância social para capturar as características dinâmicas das salas e a interação social em tempo real.

O modelo aborda a necessidade de recomendações mais precisas em plataformas de transmissão ao vivo, onde o comportamento dos usuários e as características das salas são altamente dinâmicos. A tecnologia utilizada, DRIVER, é um sistema de recomendação que integra dados dos caminhos dos usuários ao entrar, permanecer e sair de salas, atualizando dinamicamente as representações de salas e usuários. O DRIVER é eficaz em capturar as mudanças rápidas no comportamento dos usuários e nas características das salas, oferecendo recomendações mais relevantes e personalizadas. Além disso, o modelo considera as interações sociais em tempo real dentro das salas, o que é um diferencial importante para melhorar o engajamento e a experiência do usuário.

No entanto, o estudo também destaca alguns desafios e limitações. Uma análise mais aprofundada das interações sociais em diferentes contextos de transmissão poderia melhorar ainda mais a precisão das recomendações. Além disso, o artigo não aborda diretamente como diferentes tipos de conteúdo podem afetar a eficácia do modelo, o que pode ser uma área a ser explorada em estudos futuros. Esses pontos ressaltam a relevância e a inovação do modelo DRIVER para sistemas de recomendação em plataformas de transmissão ao vivo, ao mesmo tempo em que apontam áreas para potencial melhoria.

O artigo de Heidy Hazem, Ahmed Awad e Ahmed Hassan Yousef ([HAZEM; AWAD; YOUSEF, 2023](#)) aborda o desenvolvimento de um sistema de recomendação em tempo real para fluxos de dados massivos. O problema central identificado é a necessidade de sistemas de recomendação que possam se adaptar rapidamente às mudanças nas preferências dos usuários, processar grandes volumes de dados em tempo real e escalar de forma eficiente. Para solucionar esse problema, os autores propõem uma técnica de "Splitting and Replication" inspirada na arquitetura "shared-nothing", que é comum em sistemas de processamento de big data. Essa técnica foi aplicada a dois algoritmos de recomendação online: fatoração de matriz incremental (ISGD) e filtragem colaborativa baseada em itens (Cosine Similarity).

A tecnologia proposta permite distribuir os algoritmos de recomendação em um cluster, replicando vetores de usuários e itens para diferentes nós de processamento. Isso reduz

a necessidade de sincronização e melhora a escalabilidade. Entre as vantagens destacam-se a melhoria significativa na escalabilidade e eficiência de memória, além do aumento da precisão das recomendações. No entanto, a implementação pode ser complexa e a abordagem pode não ser adequada para todos os cenários, especialmente onde a sincronização entre nós é crítica.

Em Yan Zhao, Shoujin Wang, Yan Wang e Hongwei Liu ([ZHAO SHOUJIN WANG; LIU, 2023](#)) é aborda a criação de um Sistema de Recomendação para Streaming baseado em Multi-Comportamentos, denominado MbSRS. O problema central que ele tenta solucionar é a limitação dos sistemas de recomendação tradicionais que utilizam apenas um único tipo de comportamento (como compra ou visualização) para fazer recomendações, o que resulta em problemas de escassez de dados e recomendações menos precisas.

Para enfrentar esse desafio, os autores propõem a utilização de múltiplos tipos de comportamento (como compras, adições ao carrinho e visualizações) para capturar de forma mais precisa as preferências dos usuários. A tecnologia central utilizada é o MbSRS, que incorpora três componentes principais: o Módulo de Aprendizagem Multi-Comportamento (MbLM), a Rede de Memória Atentiva (AMN) e o Módulo de Fusão de Preferências do Usuário (UPFM).

O MbLM é responsável por aprender as preferências instantâneas dos usuários e as características unificadas dos itens a partir das interações recentes. A AMN mantém as preferências de longo prazo dos usuários, analisando itens históricos que os usuários interagiram, enquanto o UPFM funde as preferências instantâneas e de longo prazo para gerar recomendações mais precisas.

As vantagens dessa tecnologia incluem a capacidade de lidar com o problema de escassez de dados e a possibilidade de fornecer recomendações mais precisas ao considerar múltiplos tipos de comportamento. No entanto, o artigo também aponta algumas desvantagens, como a complexidade adicional introduzida pela necessidade de modelar explicitamente a relação entre diferentes tipos de comportamento e o uso de dependências sequenciais entre interações, o que pode tornar o sistema mais complicado de implementar e otimizar. É apresentado uma abordagem inovadora para a recomendação de streaming ao incorporar interações de múltiplos comportamentos, demonstrando resultados superiores em comparação com sistemas de recomendação tradicionais. Contudo, uma limitação é a necessidade de melhorar o modelamento das relações

entre diferentes tipos de comportamento para obter ainda mais precisão nas recomendações.

Apesar de avançarem na recomendação em streaming, esses trabalhos assumem dados ricos e granulares e não enfrentam diretamente o problema de transferir padrões para um domínio com baixa granularidade e atributos reduzidos, como a TV linear, que é justamente o cenário central desta dissertação.

Ref.	Cenário	Dados/sinais	Técnica	Contribuição e lacuna para esta dissertação
(NAHAR; VISHWA-MITRA; SUKHEJA, 2023)	Streaming (VOD)	Matriz usuário-item	NMF + PSO (co-lab.)	Boa base de recomendação com fatoração; assume dados ricos e não discute transferência para TV.
(GAO; ZHAO, 2023)	Live streaming	Trajetórias e interação em salas	DRIVER (re-presentações dinâmicas)	Captura dinâmica temporal e social; não aborda domínio alvo agregado/amostral (TV).
(HAZEM; AWAD; YOUSEF, 2023)	Recomendação online	Fluxo massivo em tempo real	Splitting & Replication + ISGD/Item-CF	Foco em escalabilidade/cluster; pouco foco na adaptação cross-domain.
(ZHAO SHOUJIN WANG; LIU, 2023)	Recomendação multi-sinais	Múltiplos comportamentos	MbSRS (MbLM+AMN+UPFM)	Reforça multi-sinais (implícito/explicito); ainda presume granularidade do streaming.

Tabela 1 – Bloco 1: trabalhos sobre recomendação em streaming e dinâmica comportamental.

Em (FERREIRA, 2024) propõe uma abordagem para medir o engajamento em transmissões ao vivo, adaptando métricas originalmente desenvolvidas para mídias sociais. O trabalho analisa interações de espectadores em plataformas como YouTube, Twitch e Facebook, avaliando recursos como curtidas, comentários e compartilhamentos. Os resultados sugerem que, apesar das métricas adaptadas oferecerem uma visão quantitativa do engajamento, fatores como duração da transmissão e semântica dos comentários ainda precisam ser considerados. Uma limitação apontada é a ausência de integração com aspectos emocionais e comportamentais dos espectadores, o que poderia enriquecer as análises e os resultados.

Em Almeida (MACHADO, 2020) avalia a evolução do comportamento de usuários em serviços de streaming de vídeo em larga escala, comparando dados das transmissões das Copas do Mundo da FIFA de 2014 e 2018. Utilizando métricas de Qualidade de Experiência (QoE), como taxa de interrupções e adaptações de bitrate, o autor analisou o impacto das melhorias na infraestrutura de transmissão sobre o engajamento dos usuários. O estudo revelou um aumento de

165% no público médio e de mais de 300% no tráfego, evidenciando a superioridade do serviço em 2018. Apesar das contribuições significativas, o trabalho depende de dados reconstruídos, o que pode introduzir limitações na precisão das análises.

Thamiris Bastos et al. (BASTOS; MARGOLIS; PROVIDÊNCIA, 2021) analisam o uso de escalas de autorrelato (PANAS e PrEmo) para compreender as experiências emocionais de espectadores em concertos ao vivo transmitidos por streaming (Live Streaming Concerts - LSC). A pesquisa avalia como as ferramentas capturam emoções antes e após a interação com diferentes estilos musicais, mostrando a predominância de afetos positivos e redução de emoções negativas. A metodologia revelou que elementos estéticos e características da interface influenciam o engajamento dos espectadores. Uma limitação do estudo é o uso de trechos gravados, que podem reduzir a representatividade das experiências reais de LSC.

Esses trabalhos discutem “como medir engajamento” no digital, porém não resolvem o desafio de mapear essas medidas para um domínio onde a audiência é amostral e agregada (TV), limitando a interpretação individual e exigindo estratégias de adaptação entre espaços de atributos.

Ref.	Cenário	Dados/sinais	Técnica	Contribuição e lacuna para esta dissertação
(FERREIRA, 2024)	Live streaming	Curtidas, comentários, etc.	Métricas adaptadas de mídias sociais	Alinha com sinais observáveis do streaming; aponta limitações (semântica/duração).
(MACHADO, 2020)	Streaming em larga escala	QoE: interrupções/bitrate	Análise comparativa (2014 vs 2018)	Mostra que engajamento depende de fatores técnicos; não trata transferência para TV.
(BASTOS; MARGOLIS; PROVIDÊNCIA, 2021)	Shows ao vivo (streaming)	Emoções (PANAS/PrEmo)	Autorrelato/escala psicométrica	Sustenta dimensão emocional; menos direto para modelagem ML de audiência agregada.

Tabela 2 – Bloco 2: trabalhos sobre mensuração de engajamento e sinais associados.

Ljubisa Bojic, em seu artigo (BOJIC, 2024), aborda o impacto global dos sistemas de recomendação baseados em algoritmos. O artigo discute como esses sistemas, amplamente utilizados em plataformas online, podem influenciar significativamente a sociedade, incluindo a propagação de desinformação, polarização social, e questões relacionadas à privacidade e vício digital.

O principal problema abordado é a falta de regulação e análise crítica sobre o impacto dessas tecnologias, que são frequentemente projetadas para maximizar o engajamento do usuário, muitas vezes às custas de consequências sociais negativas. A tecnologia utilizada para abordar essas questões é predominantemente baseada em aprendizado de máquina e filtragem colaborativa, onde algoritmos analisam dados de usuário para personalizar o conteúdo apresentado.

Esses sistemas são eficazes em manter os usuários engajados, mas podem levar à formação de "bolhas de filtro" e câmaras de eco, exacerbando a polarização social. Além disso, a coleta de dados extensiva levanta preocupações sobre privacidade, uma vez que os dados pessoais são frequentemente utilizados para otimizar as recomendações sem transparência suficiente para os usuários.

Entre as vantagens desta tecnologia, destaca-se a capacidade de fornecer conteúdo altamente personalizado, o que pode melhorar a experiência do usuário e aumentar a eficiência de campanhas de marketing. No entanto, as desvantagens incluem a possível manipulação de percepções e comportamentos dos usuários, além de uma possível perda de diversidade de informações consumidas, o que pode restringir a exposição a diferentes pontos de vista.

O artigo é forte em destacar a necessidade de uma regulamentação mais robusta e de uma discussão mais ampla entre os stakeholders sobre o alinhamento da IA com os valores sociais. No entanto, pode ser criticado por não oferecer soluções técnicas detalhadas para mitigar os efeitos negativos dos sistemas de recomendação.

A técnica de filtragem colaborativa é amplamente usada em sistemas de recomendação e baseia-se na análise de padrões de comportamento dos usuários para prever preferências futuras. Embora seja eficaz para personalização, essa abordagem pode reforçar preconceitos e limitar a exposição a novas ideias ou produtos.

Bojic conclui que é essencial uma pesquisa contínua e um debate público mais amplo para assegurar que os sistemas de recomendação estejam alinhados com o bem-estar social e ético. Ele sugere que a aplicação de regulamentações algorítmicas poderia ser uma solução potencial para promover a diversidade de conteúdo e facilitar um engajamento democrático mais equilibrado.

Em Ana Rita Gonçalves, Diego Costa Pinto, Saleh Shuqair, Marlon Dalmoro e Anna S. Mattila ([GONÇALVES et al., 2024](#)) exploram as tensões entre a autonomia do consumidor e a

tomada de decisão baseada em inteligência artificial (IA) em plataformas de streaming. O estudo aborda como a IA, ao oferecer recomendações personalizadas, pode diminuir a autonomia do consumidor, impactando negativamente sua satisfação.

O problema central que o artigo aborda é a tensão entre a autonomia do consumidor e a tecnologia de IA, especialmente quando as recomendações da IA não correspondem às preferências dos usuários. A tecnologia utilizada inclui algoritmos de recomendação baseados em IA que analisam o comportamento anterior dos usuários para sugerir conteúdos. Esses algoritmos são projetados para aumentar a eficiência e a satisfação do usuário, mas o estudo revela que podem reduzir a expectativa de desempenho e a satisfação quando não alinham perfeitamente as preferências dos consumidores.

A principal vantagem dessa tecnologia é a capacidade de fornecer recomendações personalizadas, facilitando a navegação em grandes catálogos de conteúdo. No entanto, uma desvantagem significativa é o potencial para limitar a autonomia do usuário, levando à insatisfação quando as recomendações não correspondem às suas preferências.

O artigo é forte na identificação e análise da "tensão autonomia-tecnologia", oferecendo uma visão detalhada de como essa tensão pode afetar a satisfação do consumidor. No entanto, uma limitação é que ele se baseia em cenários experimentais que podem não capturar completamente a complexidade das experiências reais dos usuários com IA em plataformas de streaming.

Ivan Satuf ([SATUF, 2020](#)) explora como os algoritmos de engajamento do Globoplay examinam, preveem e prescrevem comportamentos dos usuários, baseando-se em artigos técnicos de desenvolvedores da plataforma. A pesquisa desmistifica a "caixa-preta" desses algoritmos, revelando seu papel na coleta de dados e na promoção de conteúdos para maximizar o tempo de uso e os acessos. Um ponto positivo é a análise detalhada da interação entre algoritmos e práticas de consumo, que conecta aspectos técnicos a implicações sociopolíticas. Contudo, a crítica reside na falta de transparência dos algoritmos e no potencial risco de controle e manipulação excessiva sobre os usuários.

Em resumo, a técnica de IA utilizada é uma ferramenta de recomendação personalizada que, embora potente, pode gerar efeitos adversos se não for implementada de forma que preserve a autonomia do usuário, destacando a necessidade de equilibrar precisão de recomendação e liberdade de escolha.

Embora não tratem diretamente de transferência entre domínios, esses estudos justificam por que a interpretação de engajamento/audiência não deve ser avaliada apenas por precisão, mas também por implicações de privacidade, autonomia e efeitos sistêmicos.

Ref.	Cenário	Foco	Abordagem	Contribuição e lacuna para esta dissertação
(BOJIC, 2024)	Plataformas online	Impactos sociais/privacidade	Discussão crítica	Justifica riscos (bolhas, privacidade); não oferece método de transferência/mensuração.
(GONÇALVES et al., 2024)	Streaming + IA	Autonomia vs recomendação	Experimentos/ atitude do consumidor	Mostra trade-off entre personalização e autonomia; não foca em TV nem em alinhamento de atributos.
(SATUF, 2020)	Globoplay	Caixa-preta do engajamento	Análise crítica/documental	Sustenta a ideia de engajamento como otimização de plataforma; não é modelo quantitativo cross-domain.

Tabela 3 – Bloco 3: trabalhos sobre impactos, transparência e implicações de sistemas de recomendação/engajamento.

Fernández-Tobías et al. apresentam um levantamento abrangente sobre sistemas de recomendação cross-domain, discutindo como o conhecimento aprendido em um domínio pode ser transferido para outro domínio distinto (FERNÁNDEZ-TOBÍAS et al., 2012). Os autores destacam que a maioria dos sistemas de recomendação tradicionais opera em domínios únicos, o que limita sua capacidade de lidar com cenários nos quais os dados disponíveis são escassos ou heterogêneos. Como solução, o artigo propõe uma taxonomia de abordagens cross-domain, incluindo métodos baseados em conteúdo, filtragem colaborativa e técnicas de aprendizado por transferência.

O estudo é particularmente relevante ao formalizar o conceito de domínio e discutir mecanismos de alinhamento entre domínios com diferentes conjuntos de atributos e distribuições de dados. Essa discussão fundamenta diretamente a proposta desta dissertação, ao demonstrar que é possível explorar dados ricos de um domínio fonte, como o streaming, para aprimorar a interpretação e recomendação em um domínio alvo com dados mais restritos, como a TV linear. Além disso, os autores apontam que abordagens cross-domain são eficazes para mitigar problemas como cold-start e esparsidade de dados, aspectos centrais enfrentados na medição tradicional de audiência televisiva.

Weiss, Khoshgoftaar e Wang apresentam um survey abrangente sobre aprendizagem por

transferência, definindo formalmente os conceitos de domínio, tarefa e distribuição de dados (WEISS; KHOSHGOFTAAR; WANG, 2016). Os autores demonstram que métodos tradicionais de aprendizagem de máquina assumem que os dados de treinamento e teste pertencem ao mesmo domínio e seguem distribuições semelhantes, o que raramente ocorre em cenários reais. A aprendizagem por transferência surge, assim, como uma estratégia para melhorar o desempenho de modelos em um domínio alvo a partir do conhecimento adquirido em um domínio fonte relacionado.

O artigo classifica as abordagens de transferência em homogêneas e heterogêneas, além de discutir estratégias baseadas em instâncias, atributos, parâmetros e representações latentes. Um ponto central do trabalho é a discussão sobre o risco de transferência negativa, que ocorre quando o conhecimento transferido prejudica o desempenho do modelo no domínio alvo. Essa análise fornece base teórica direta para a metodologia desta dissertação, que investiga a transferência de padrões de engajamento aprendidos em dados ricos de streaming para dados reduzidos de audiência da TV linear, respeitando as limitações impostas pelas diferenças de distribuição e granularidade entre os domínios.

Pan et al. discutem a aprendizagem por transferência como uma extensão natural da aprendizagem de máquina tradicional, especialmente em cenários nos quais os dados rotulados no domínio alvo são escassos (PAN; YANG, 2010). Os autores introduzem conceitos fundamentais como adaptação de domínio e transferência indutiva, transdutiva e não supervisionada, destacando como o alinhamento entre espaços de atributos e distribuições é essencial para o sucesso da transferência.

O trabalho reforça que a eficácia da aprendizagem por transferência depende da existência de relações semânticas ou estatísticas entre os domínios envolvidos, mesmo quando os conjuntos de atributos não são idênticos. Essa perspectiva sustenta teoricamente a abordagem adotada nesta dissertação, na qual dados detalhados de engajamento provenientes do streaming são utilizados para auxiliar a interpretação de audiências de TV linear, caracterizadas por menor granularidade e menor diversidade de atributos.

Esses surveys fornecem base teórica para a transferência entre domínios, mas não especificam uma instância concreta do problema “dados de engajamento ricos (streaming) → audiência reduzida (TV)”, o que motiva a contribuição desta dissertação.

Ref.	Cenário	Conceitos-chave	Tipo	Contribuição e lacuna para esta dissertação
(FERNÁNDEZ-TOBIÁS et al., 2012)	Recomendação	Domínios, alinhamento, esparsidade	Survey cross-domain RS	Base conceitual direta para usar streaming como fonte e TV como alvo.
(WEISS; KHOSHGOFTAAR; WANG, 2016)	Transfer learning	Domínio/tarefa; negative transfer	Survey TL	Fundamenta escolhas metodológicas e cuidados com diferença de distribuição.
(PAN; YANG, 2010)	Transfer learning	Adaptação de domínio; modos de TL	Survey TL clássico	Formaliza TL e cenários (indutivo/transdutivo etc.) para posicionar sua abordagem.

Tabela 4 – Bloco 4: surveys fundamentais de transferência e recomendação cross-domain.

Os autores Mehdi Elahi, Danial Khosh Kholgh, Mohammad Sina Kiarostami, Mourad Oussalah e Soroush Saghari apresentam a criação de um sistema de recomendação híbrido que integra a análise de sentimentos dos comentários de produtos como parte do processo de recomendação ([ELAHI DANIAL KHOSH KHOLGH; SAGHARI, 2023](#)).

O problema que o artigo tenta solucionar é a limitação dos sistemas de recomendação tradicionais que geralmente dependem apenas de avaliações (ratings) dos usuários, o que pode não representar totalmente as preferências dos mesmos. A solução proposta é a incorporação de sentimentos extraídos de comentários, utilizando técnicas avançadas de análise de sentimentos e aprendizado profundo, como o modelo BERT (Bidirectional Encoder Representations from Transformers). BERT é uma tecnologia de processamento de linguagem natural (NLP) que entende o contexto das palavras em uma sentença para gerar representações textuais ricas e contextuais.

O modelo de recomendação híbrido desenvolvido no estudo utiliza embeddings gerados pelo BERT, seguido de redução de dimensionalidade com PCA (Análise de Componentes Principais), para capturar os sentimentos dos comentários dos usuários. Essas representações são então integradas a modelos de recomendação como o YoutubeRanker e o DeepFM, que são algoritmos de aprendizado profundo voltados para classificação multiclasse e fatoração de matrizes, respectivamente.

As vantagens dessa abordagem incluem uma compreensão mais completa das preferências dos usuários, uma vez que os sentimentos podem fornecer informações complementares ou alternativas às avaliações tradicionais. Além disso, o modelo demonstrou melhoria significativa na precisão das recomendações em dois cenários de avaliação. Contudo, uma desvantagem

observada é a possível inconsistência na correlação entre sentimentos e avaliações, especialmente em domínios como música digital, onde a correlação é mais fraca.

O artigo destaca-se pela proposta inovadora de incluir dados de sentimentos na avaliação de sistemas de recomendação, mostrando um avanço significativo na precisão das recomendações. No entanto, uma limitação é a complexidade da implementação e a necessidade de grandes volumes de dados para treinar modelos como o BERT de forma eficaz.

Gale M. Lucas e colaboradores ([LUCAS JONATHAN GRATCH, 2017](#)) exploram o uso de análise de sentimentos para entender como as emoções dos fãs se manifestam durante eventos esportivos, especificamente na Copa do Mundo de 2014. O estudo investiga como essas emoções são influenciadas por fatores contextuais e como podem ser analisadas para testar teorias emocionais.

O problema central abordado é compreender como as emoções dos fãs podem ser quantificadas e analisadas em tempo real durante eventos esportivos. Para isso, os autores utilizam a tecnologia de análise de sentimentos, que classifica textos em categorias emocionais como positivas, negativas ou neutras. A metodologia envolve a análise de um grande volume de tweets, coletados durante os jogos, para identificar padrões emocionais e testar a hipótese da incerteza do resultado (UOH), que sugere que jogos mais disputados são considerados mais emocionantes.

A análise de sentimentos aplicada neste estudo baseia-se em métodos supervisionados, que utilizam léxicos afetivos para avaliar o conteúdo emocional das palavras nos tweets. Essa tecnologia permite uma avaliação precisa e detalhada das emoções expressas pelos fãs, fornecendo insights sobre a dinâmica emocional durante os jogos.

Os autores destacam que, embora a análise de sentimentos seja eficaz para captar grandes volumes de dados e fornecer uma visão imediata das emoções do público, existem desafios, como a necessidade de adaptação dos léxicos afetivos ao contexto específico do esporte. A linguagem utilizada pelos fãs em tweets pode ser muito específica e variar significativamente, o que pode afetar a precisão das classificações emocionais.

O artigo de Lucas et al. oferece uma abordagem inovadora ao utilizar análise de sentimentos para estudar as reações emocionais dos fãs durante eventos esportivos. Ele contribui para o entendimento de como as emoções se manifestam e são influenciadas em contextos de alta

emoção, como jogos de futebol, proporcionando uma nova perspectiva sobre a interação entre eventos esportivos e o público.

Lim, Hwang, Kim, e Biocca (2015) ([LIM et al., 2015](#)) investigam como o engajamento nas redes sociais durante eventos esportivos, como os Jogos Olímpicos de Inverno de Sochi 2014, pode aumentar a lealdade aos canais esportivos. Eles destacam que o engajamento funcional (interação direta), emocional (expressão de sentimentos) e comunitário (senso de comunidade) contribuem para uma maior presença social e comprometimento com o canal. A pesquisa utiliza modelos de equações estruturais para analisar essas relações, sugerindo que o engajamento emocional e comunitário são cruciais para construir lealdade ao canal. As vantagens incluem o fortalecimento da comunidade de telespectadores, enquanto a complexidade das interações pode ser uma desvantagem.

Maria Bastos, Mijail Naranjo-Zolotov, e Manuela Aparício exploram o fenômeno do binge-watching, especificamente focando na interação entre a utilidade percebida, o hábito e o arrependimento associados a essa prática ([BASTOS; NARANJO-ZOLOTOV; APARÍCIO, 2024](#)). O artigo investiga como esses fatores influenciam a intenção contínua de assistir compulsivamente séries de televisão.

O problema central abordado é entender os determinantes que levam as pessoas a se engajarem continuamente no binge-watching, um comportamento amplamente difundido, especialmente entre os jovens. Para abordar esse problema, os autores utilizam um modelo teórico que inclui a influência social, utilidade percebida, hábito e arrependimento como variáveis-chave.

A tecnologia utilizada para a análise dos dados foi a modelagem de equações estruturais (SEM), que permite investigar as relações entre múltiplas variáveis latentes. Essa técnica é eficaz para integrar variáveis não observáveis e fornecer uma compreensão mais ampla dos fenômenos em estudo. No contexto deste artigo, a SEM foi usada para testar as hipóteses relacionadas ao impacto do hábito, utilidade percebida e arrependimento na intenção contínua de binge-watching.

Os autores encontraram que o hábito é o fator mais forte na determinação do comportamento de binge-watching, superando a intenção consciente de continuar a assistir. A utilidade percebida, ou a crença de que o binge-watching é uma forma eficaz de entretenimento, também mostrou ter um impacto significativo, embora menor que o hábito. Por outro lado, o arrependimento teve uma influência negativa na intenção contínua, indicando que sentimentos

de culpa podem diminuir a vontade de continuar a prática, mas não necessariamente impedir o comportamento.

O estudo é forte na medida em que utiliza uma amostra adequada e uma metodologia robusta para explorar um fenômeno contemporâneo relevante. No entanto, uma limitação é a generalização dos resultados, uma vez que a amostra foi retirada de um único país europeu, o que pode não representar toda a diversidade de comportamentos globais de binge-watching. Além disso, a faixa etária dos participantes foi predominantemente jovem, o que pode influenciar os resultados.

Em resumo, o artigo fornece uma visão abrangente dos fatores que contribuem para o comportamento de binge-watching, destacando a importância do hábito e da utilidade percebida, enquanto também considera as implicações emocionais, como o arrependimento, que podem afetar essa prática.

Em conjunto, esses artigos exploram sinais semânticos, emocionais e subjetivos do engajamento dos usuários, tais como sentimentos expressos em textos, respostas emocionais durante eventos ao vivo, interações sociais e comportamentos habituais como o binge-watching. Esses estudos demonstram que o engajamento vai além de métricas puramente quantitativas, incorporando dimensões afetivas, sociais e cognitivas que influenciam significativamente o consumo de conteúdo audiovisual.

Entretanto, apesar de avançarem na compreensão qualitativa do engajamento, esses trabalhos dependem fortemente de dados ricos, individuais e não estruturados, como textos, autorrelatos e interações em redes sociais. Nenhum deles aborda o desafio de transferir ou reinterpretar esses sinais subjetivos para domínios com dados agregados, amostrais e de baixa dimensionalidade, como ocorre na medição tradicional de audiência da TV linear.

Nesse contexto, esta dissertação se diferencia ao não depender de sinais semânticos diretos, mas ao explorar dados estruturados e quantitativos provenientes do streaming como fonte de conhecimento, buscando mapear padrões de engajamento aprendidos nesse domínio rico para um domínio-alvo restrito, a TV linear. Dessa forma, a proposta contribui para aproximar interpretações subjetivas de engajamento de um cenário onde tais sinais não estão explicitamente disponíveis.

A análise dos trabalhos relacionados evidencia que a interpretação de dados de audiência

Ref.	Cenário	Sinais/dados	Técnica	Contribuição e lacuna para esta dissertação
(ELAHI DANIAL KHOSH KHOLGH; SAGHARI, 2023)	Recomendação (produtos)	Comentários + avaliações	BERT + PCA + modelos de recomendação	Introduz sinal semântico (texto/sentimento) para enriquecer preferências; não aborda mapeamento para domínio agregado como TV.
(LUCAS JO-NATHAN GRATCH, 2017)	Esporte	Tweets durante jogos	Análise de sentimentos (léxico/supervisionado)	Mostra extração de emoção em tempo real por texto; distante do seu cenário de TV/streaming com atributos estruturados.
(LIM et al., 2015)	TV + redes sociais	Engajamento social/emocional	Modelagem de Equações Estruturais (SEM)	Liga sinais sociais a lealdade/presença social; pouco alinhado a pipelines de ML cross-domain e dados de audiência agregados.
(BASTOS; NARANJO-ZOLOTOV; APARÍCIO, 2024)	Streaming (VOD)	Hábito/utilidade	SEM	Explica engajamento como comportamento e hábito; útil como suporte teórico, mas não fornece técnica de transferência entre domínios.

Tabela 5 – Bloco 5: trabalhos sobre sinais semânticos e subjetivos (texto, emoção, engajamento social e hábito).

e engajamento tem avançado de forma desigual entre os diferentes domínios analisados. No contexto do streaming, observa-se um amplo uso de técnicas de aprendizagem de máquina, dados de alta granularidade e múltiplos sinais comportamentais, permitindo recomendações altamente personalizadas. Em contraste, a TV tradicional ainda opera majoritariamente com dados agregados e amostrais, o que limita a capacidade de interpretar padrões individuais de engajamento.

Os trabalhos organizados nos Blocos 1 e 2 demonstram que, embora existam métodos sofisticados para recomendação e mensuração de engajamento no streaming, esses modelos assumem a disponibilidade de dados ricos e não enfrentam diretamente o problema da restrição de atributos. O Bloco 3 amplia a discussão ao evidenciar impactos sociais, éticos e comportamentais dos sistemas de recomendação, reforçando a importância de interpretações responsáveis e transparentes do engajamento. Já o Bloco 5 explora dimensões subjetivas e semânticas do engajamento, destacando a complexidade do fenômeno, mas sem propor mecanismos de adaptação para domínios com dados reduzidos.

O Bloco 4, por sua vez, fornece a base teórica mais diretamente relacionada à proposta desta dissertação, ao tratar da aprendizagem por transferência e de sistemas de recomendação cross-domain. Esses trabalhos demonstram que é possível transferir conhecimento entre domínios

distintos, desde que haja algum grau de relação semântica ou estrutural entre eles, ao mesmo tempo em que alertam para riscos como a transferência negativa.

Diante desse cenário, identifica-se uma lacuna clara na literatura: a ausência de abordagens que investiguem explicitamente a transferência de padrões de engajamento aprendidos em dados ricos de streaming para dados reduzidos de audiência da TV linear. Esta dissertação se posiciona justamente nesse espaço, propondo uma estratégia de interpretação de engajamento baseada na adaptação entre domínios com diferentes níveis de granularidade e disponibilidade de atributos, conectando diretamente os avanços do streaming às limitações históricas da TV tradicional.

Ref.	Bloco	Domínio	Sinais/dados	Técnica	Conexão com esta dissertação
(NAHAR; VISHWA-MITRA; SUKHEJA, 2023)	1	Streaming	usuário-item	NMF + PSO	Recomendação com fatoração; não resolve transferência para TV.
(GAO; ZHAO, 2023)	1	Live streaming	trajetórias + social	DRIVER	Dinâmica temporal; lacuna em domínio agregado/amostral (TV).
(HAZEM; AWAD; YOUSEF, 2023)	1	Streaming/Big data	fluxo em tempo real	Splitting/Replication + ISGD/Item-CF	Escalabilidade; não trata alinhamento de atributos streaming→TV.
(ZHAO SHOU-JIN WANG; LIU, 2023)	1	Streaming	multi-comportamentos	MbSRS	Sustenta uso de múltiplos sinais; assume alta granularidade.
(FERREIRA, 2024)	2	Live streaming	likes/comments/shares	métricas adaptadas	Base de engajamento observável no streaming; falta ponte para TV.
(MACHADO, 2020)	2	Streaming	QoE (bi-trate/interrupções)	análise comparativa	Mostra engajamento influenciado por QoE; reforça riqueza do domínio fonte.
(BASTOS; MARGOLIS; PROVIDÊNCIA, 2021)	2	Streaming	emoções (autorrelato)	PANAS/PrEmo	Dimensão emocional; pouco direto para transferência computacional.
(BOJIC, 2024)	3	Geral	impactos sociais/privacidade	discussão crítica	Motiva debate ético/regulatório; não é método de transferência.
(GONÇALVES et al., 2024)	3	Streaming	autonomia/satisfação	experimento	Trade-off personalização vs autonomia; contextualiza riscos da IA.
(SATUF, 2020)	3	Streaming (Globoplay)	lógica algorítmica/engajamento	análise crítica/documental	Contextualiza caixa-preta e otimização de engajamento; sem mapeamento para TV.
(FERNÁNDEZ-TOBÍAS et al., 2012)	4	Recomendação	domínios/alinhamento/esparsidade	survey	Base direta para cross-domain streaming→TV.
(WEISS; KHOSHGOFTAAR; WANG, 2016)	4	ML	domínio/tarefa/distribuições	survey	Fundamenta TL e risco de transferência negativa.
(PAN; YANG, 2010)	4	ML	adaptação de domínio	survey	Formaliza cenários de TL para posicionar seu método.
(ELAHI DANIAL KHOSH KOLGH; SAGHARI, 2023)	5	Recomendação (texto)	comentários/sentimento	BERT + PCA + recomendação	Sinal semântico para preferências; não endereça TV agregada.
(LUCAS JO-NATHAN GRATCH, 2017)	5	Social media (esporte)	tweets/emoções	sentiment analysis	Extração emocional por texto; distante do seu pipeline principal.
(LIM et al., 2015)	5	TV + social	engajamento social/emocional	SEM	Engajamento social e lealdade; suporte teórico, não cross-domain.
(BASTOS; NARANJO-ZOLOTOV; APARÍCIO, 2024)	5	Streaming (VOD)	hábito/utilidade/arrependimento	SEM	Explica binge-watching como fenômeno; apoio teórico, não técnico.

Tabela 6 – Tabela geral de comparação dos trabalhos relacionados.

4

SOLUÇÃO PROPOSTA

Este trabalho propõe uma solução baseada em aprendizagem de máquina para interpretar dados de audiência da TV linear a partir do conhecimento extraído de dados granulares provenientes de plataformas de streaming. A proposta fundamenta-se na hipótese de que os dados de streaming, por apresentarem maior riqueza semântica e comportamental, podem ser utilizados como domínio fonte para o aprendizado de padrões de engajamento do público, os quais podem ser posteriormente transferidos para o domínio da TV linear, caracterizado por dados agregados e menor granularidade.

4.1 Visão Geral da Solução

A solução proposta parte da premissa de que o comportamento do público pode ser interpretado a partir de padrões observáveis de consumo audiovisual, mesmo quando os dados disponíveis apresentam diferentes níveis de granularidade. Nesse contexto, plataformas de streaming são consideradas fontes ricas de informação, pois permitem observar múltiplos sinais explícitos e implícitos de engajamento, enquanto a TV linear opera com dados agregados e amostrais.

A utilização de técnicas de *Transfer Learning* é motivada pela assimetria entre os domínios analisados (PAN; YANG, 2010). O streaming é adotado como domínio fonte, responsável por fornecer representações comportamentais mais completas, enquanto a TV linear é tratada como domínio alvo, no qual se busca inferir padrões semelhantes a partir de dados reduzidos.

Diferentemente de abordagens que buscam a transferência direta de modelos, esta proposta enfatiza a compatibilização conceitual dos atributos e das definições de engajamento,

preservando o significado comportamental dos dados ao longo do processo de aprendizado (FERNÁNDEZ-TOBIÁS et al., 2012).

4.2 Arquitetura da Solução e Pipeline Metodológico

A solução proposta é estruturada a partir de uma arquitetura em camadas que organiza os principais componentes envolvidos no processo de interpretação de engajamento entre os domínios de streaming e TV linear.

Dentro dessa arquitetura, o fluxo de processamento dos dados é descrito por meio de um pipeline conceitual, composto por três etapas principais: entrada de dados, processamento e aprendizado, e geração de inferências.

Na etapa de entrada, são considerados dois domínios distintos: dados de streaming, caracterizados por alta granularidade e riqueza semântica, e dados de TV linear, caracterizados por agregação temporal e amostral. Esses domínios não são tratados como semanticamente equivalentes, mas como observações complementares do comportamento coletivo do público.

A etapa de processamento é responsável pela harmonização conceitual dos dados, garantindo compatibilidade estrutural entre os domínios. Esse processo envolve a abstração de atributos, a padronização de categorias de conteúdo e a definição de variáveis observáveis em ambos os contextos.

Na etapa de aprendizado, modelos de aprendizagem de máquina são utilizados para capturar padrões de engajamento a partir do domínio de streaming e transferir esse conhecimento para o domínio da TV linear. Por fim, a saída do pipeline consiste em inferências sobre o comportamento do público televisivo, permitindo interpretações mais ricas a partir de dados tradicionalmente limitados.

A arquitetura da solução define a organização dos componentes envolvidos no processo de interpretação de engajamento, estruturando-os em camadas que incluem fontes de dados, processamento, modelagem e geração de inferências.

O fluxo de processamento dos dados é posteriormente detalhado por meio de um pipeline, no qual são descritas as etapas específicas de transformação, harmonização e aprendizado.




Figura 1 – Arquitetura da solução proposta, organizada em camadas de dados, modelo e aplicação, evidenciando a separação entre fontes de dados, processamento e geração de inferências.

A Figura 1 apresenta a visão estrutural da solução proposta, organizada em camadas funcionais.

A partir dessa organização, o fluxo de processamento dos dados é detalhado por meio de um pipeline conceitual, ilustrado na Figura 2, no qual são explicitadas as etapas de transformação, harmonização e aprendizado entre os domínios.




Figura 2 – Pipeline proposto de aprendizagem entre domínios. A estrutura de engajamento é aprendida a partir de sinais granulares do domínio de streaming (origem) e adaptada para o domínio da TV linear (alvo) sob restrições de atributos, por meio de harmonização de características e transferência de aprendizado.

4.3 Definição Conceitual dos Atributos

4.3.1 Atributos de Perfil

Os atributos de perfil representam características agregadas do público, tais como distribuição etária, gênero e outros aspectos demográficos. No domínio do streaming, esses atributos podem ser observados de forma mais detalhada, enquanto na TV linear são disponibilizados de maneira agregada ou inferida a partir de amostras estatísticas.

Na solução proposta, os atributos de perfil são tratados como descritores do comportamento coletivo do público, permitindo a identificação de padrões gerais de consumo sem a necessidade de informações individuais.

4.3.2 Atributos de Conteúdo

Os atributos de conteúdo descrevem as características semânticas do material audiovisual consumido, como tema ou tipo de programa. Esses atributos são fundamentais para estabelecer relações entre preferências do público e tipos de conteúdo exibidos.

A solução proposta adota uma representação abstrata dos conteúdos, permitindo a equivalência conceitual entre programas de TV e vídeos de streaming. Essa abstração viabiliza a análise conjunta dos domínios, preservando o significado editorial dos conteúdos.

4.3.3 Atributos Temporais

Os atributos temporais representam a dimensão do tempo associada ao consumo audiovisual, incluindo períodos do dia e janelas temporais de observação. Na TV linear, o consumo ocorre de forma síncrona e programada, enquanto no streaming o consumo é assíncrono e sob demanda.

A solução considera essa diferença estrutural por meio de representações temporais compatíveis, evitando a introdução de informações artificiais e preservando a coerência conceitual entre os domínios.

4.3.4 Implicações para Aprendizagem de Máquina

A definição adequada dos atributos é essencial para garantir a eficácia dos modelos de aprendizagem de máquina. Representações incompatíveis ou semanticamente incorretas podem introduzir vieses e comprometer o processo de aprendizado.

Ao adotar atributos conceitualmente alinhados entre os domínios, a solução proposta permite que os modelos aprendam padrões comportamentais transferíveis, independentemente do meio de origem dos dados.

4.4 Definição Conceitual de Engajamento

4.4.1 Engajamento Ativo

O engajamento ativo refere-se às interações explícitas realizadas pelo público em relação ao conteúdo audiovisual, como comentários, avaliações ou outras formas de participação voluntária. Esse tipo de engajamento é característico de plataformas digitais, nas quais os usuários dispõem de múltiplos mecanismos de interação.

4.4.2 Engajamento Passivo

O engajamento passivo está associado ao consumo silencioso do conteúdo, refletindo a permanência e a atenção do público ao longo do tempo. Na TV linear, esse tipo de engajamento é predominante, sendo inferido por métricas de audiência e exposição.

4.4.3 Diferenças entre TV e Streaming

Enquanto o streaming permite observar simultaneamente engajamento ativo e passivo, a TV linear depende majoritariamente de indicadores indiretos de engajamento passivo. Essa diferença impõe desafios ao aprendizado de máquina, exigindo estratégias capazes de lidar com sinais comportamentais de naturezas distintas.

4.5 Estratégia de Aprendizado

4.5.1 Por que Regressão

A tarefa de aprendizado proposta envolve a estimativa de níveis contínuos de engajamento, o que caracteriza naturalmente um problema de regressão. Essa abordagem permite capturar variações graduais no comportamento do público, ao invés de classificações discretas.

4.5.2 Escolha dos Modelos SVR e MLP

Foram considerados modelos de *Support Vector Regression* (SVR) e redes neurais do tipo *Perceptron Multicamadas* (MLP) devido à sua capacidade de modelar relações não lineares e lidar com dados heterogêneos. Esses modelos representam abordagens complementares, permitindo comparar métodos clássicos e baseados em redes neurais.

4.5.3 Uso de Transfer Learning

O *Transfer Learning* é empregado como estratégia para reaproveitar o conhecimento adquirido no domínio de streaming e auxiliar o aprendizado no domínio da TV linear. Essa transferência ocorre por meio do compartilhamento de representações aprendidas, respeitando as limitações estruturais de cada domínio.

4.5.4 Estratégias Avaliadas

Foram consideradas diferentes estratégias de aprendizado, incluindo treinamento direto no domínio da TV linear e abordagens baseadas em pré-treinamento no domínio de streaming seguido de adaptação. Essas estratégias permitem analisar, de forma conceitual, o impacto da transferência de conhecimento entre domínios com diferentes níveis de informação.

4.6 Configuração dos Modelos e Definição de Hiperparâmetros

4.6.1 Pré-processamento dos Dados

Os atributos foram normalizados utilizando o método *StandardScaler*, baseado na padronização z-score. O ajuste do scaler foi realizado exclusivamente sobre os dados de treinamento do domínio de streaming, sendo posteriormente aplicado aos demais conjuntos de dados, incluindo TV linear.

Essa estratégia evita vazamento de informação e garante consistência na representação

dos atributos entre os domínios.

4.6.2 Configuração do SVR

O modelo SVR foi configurado com kernel do tipo RBF, permitindo a modelagem de relações não lineares entre os atributos e o engajamento. O parâmetro C foi mantido em 1.0, equilibrando a penalização de erros e a regularização do modelo. O parâmetro epsilon foi definido como 0.1, estabelecendo uma margem de tolerância para erros, enquanto gamma foi configurado como “scale”, ajustando automaticamente a largura do kernel com base na variância dos dados.

Esse conjunto de parâmetros foi mantido conforme a configuração padrão da biblioteca Scikit-learn, não sendo realizado ajuste fino (tuning) de hiperparâmetros neste trabalho.

4.6.3 MLP Baseline (Scikit-learn)

O modelo MLP baseline foi implementado utilizando a biblioteca Scikit-learn, sendo adotado como modelo de referência (baseline) para comparação com as abordagens baseadas em transferência de aprendizado, com duas camadas ocultas de 128 e 64 neurônios, respectivamente. A função de ativação ReLU foi utilizada nas camadas ocultas, enquanto a camada de saída emprega ativação linear, adequada para tarefas de regressão. O treinamento foi realizado com otimizador Adam, função de perda MSE e regularização L2 padrão ($\alpha = 0.0001$). O tamanho do batch foi definido automaticamente pela biblioteca, sendo proporcional ao número de amostras disponíveis.

4.6.4 MLP com Transfer Learning

Para a abordagem com transferência de aprendizado, foi utilizado um modelo MLP implementado em Keras, mantendo a mesma estrutura de camadas do modelo baseline. O treinamento foi realizado em duas etapas: pré-treino com dados de streaming e posterior ajuste fino com dados da TV linear.

Durante o ajuste fino, parte das camadas iniciais foi mantida fixa, com o intuito de

preservar as representações aprendidas no domínio de origem, enquanto as demais camadas foram atualizadas com base nos dados do domínio alvo.

4.6.5 Estratégia de Treinamento

O treinamento do modelo com transferência foi realizado em duas fases. Na etapa de pré-treino, foi utilizado uma taxa de aprendizado (learning rate) de 0.001, enquanto na etapa de ajuste fino o learning rate foi reduzido para 0.0005, visando preservar os padrões aprendidos e evitar sobreajuste. O treinamento foi conduzido por 50 épocas, com tamanho de lote (batch size) de 32 e função de perda baseada no erro quadrático médio (MSE).

A redução da taxa de aprendizado no ajuste fino visa preservar os padrões aprendidos no domínio de origem, evitando grandes atualizações nos pesos e reduzindo o risco de sobreajuste ao domínio alvo.

4.6.6 Estratégia de Validação

Foi utilizada uma estratégia de validação do tipo hold-out, com divisão dos dados em conjuntos de treino e teste por meio da função *train_test_split*. Não foi adotada validação cruzada k-fold, pois esse procedimento envolve a mistura aleatória dos dados, o que poderia comprometer a separação entre os domínios de streaming e TV linear, especialmente no contexto de transferência de aprendizado.

4.6.7 Complexidade Computacional

O modelo MLP utilizado possui aproximadamente 13 mil parâmetros treináveis, considerando 36 atributos de entrada e duas camadas ocultas. Esse número caracteriza o modelo como de baixa complexidade para padrões de deep learning.

Do ponto de vista computacional, o SVR apresenta complexidade aproximada de $O(n^2)$ durante o treinamento, enquanto o MLP possui complexidade proporcional ao número de amostras, parâmetros e épocas de treinamento. No contexto deste trabalho, o modelo apresentou

custo computacional reduzido e viável para experimentação. Além disso, o modelo final mostrou-se adequado para cenários com restrição de dados, como a TV linear, apresentando maior capacidade na ordenação relativa (ranking) de conteúdos do que na estimativa precisa dos valores absolutos de engajamento.

Tabela 7 – Principais hiperparâmetros utilizados nos modelos

Parâmetro	SVR	MLP (Baseline + Transfer)
Kernel	RBF	—
C	1.0	—
Epsilon	0.1	—
Gamma	scale	—
Camadas ocultas	—	(128, 64)
Ativação	—	ReLU
Otimizador	—	Adam
Taxa de aprendizado	—	0.001 / 0.0005
Batch size	—	32 (Keras) / padrão do sklearn
Épocas	—	50 (Keras) / até 500 iterações (sklearn)
Função de perda	—	MSE
Regularização	—	L2 (alpha = 0.0001)

5

EXPERIMENTOS E RESULTADOS

Este capítulo apresenta as bases de dados empregadas, o processo de preparação e harmonização entre os domínios de TV linear e *streaming*, a definição operacional das variáveis-alvo de engajamento e os modelos utilizados. Em seguida, descreve-se o protocolo experimental adotado e são apresentados os resultados obtidos, incluindo a comparação entre abordagens *TV-only* e estratégias com *Transfer Learning* (streaming $\rightarrow$ TV).

5.1 Bases de Dados

Foram utilizadas três bases principais, contemplando dois domínios: TV linear (anos de 2023 e 2024) e *streaming* (YouTube). A Tabela 8 resume o volume de registros por base.

Tabela 8 – Resumo das bases utilizadas.

Base	Nº de registros
Streaming (YouTube)	1127
TV linear (2023)	7141
TV linear (2024)	7141

5.1.1 TV linear (2023 e 2024)

As bases de TV linear são organizadas em janelas temporais discretas (minutos), representando observações agregadas de audiência em diferentes contextos de exibição. Cada registro incorpora informações temáticas (relacionadas à grade), variáveis temporais (dia da semana e período

do dia) e distribuição demográfica agregada (gênero, faixas etárias e classes socioeconômicas). Por se tratar de um domínio com dados amostrais e agregados, não há sinais explícitos de interação; assim, a variável-alvo é construída como um proxy de engajamento passivo, conforme a Seção 5.3.

Adicionalmente, ressalta-se que os dados de audiência da TV linear são provenientes de um painel amostral composto por aproximadamente 200 famílias, conforme metodologia tradicional de medição de audiência televisiva. Assim, cada registro não representa medições individuais diretas, mas sim estimativas agregadas de comportamento populacional, inferidas a partir desse painel. Esse aspecto reforça a natureza indireta do engajamento no domínio da TV, em contraste com o streaming, onde há sinais explícitos de interação dos usuários.

5.1.2 Streaming (YouTube)

A base de *streaming* foi construída a partir de relatórios do YouTube (Data API e Analytics), sendo cada registro correspondente a um vídeo do canal analisado. Além de metadados e categorização temática, a base contém métricas de desempenho e consumo, como visualizações, tempo assistido e retenção média, além de sinais explícitos de interação (curtidas e comentários). Esses sinais permitem a construção de alvos de engajamento ativo e passivo no domínio de *streaming*.

Cabe destacar que, embora a base de streaming seja composta por 1127 registros (cada um correspondente a um vídeo), esses registros agregam um volume significativamente maior de interações. O canal analisado possui aproximadamente 869.634 visualizações acumuladas, que constituem a base de geração das métricas utilizadas neste estudo (como visualizações, tempo assistido, curtidas e comentários). Dessa forma, cada instância representa um comportamento agregado de consumo, refletindo padrões de engajamento derivados de um volume expressivo de interações reais dos usuários.

5.2 Preparação e Harmonização dos Dados

Para viabilizar a comparação e o *Transfer Learning* entre os domínios, foi necessário construir uma representação comum de atributos. O objetivo desta etapa foi alinhar as *features* sem impor equivalência artificial entre os meios, preservando a interpretação comportamental de cada variável.

5.2.1 Harmonização temática e *one-hot encoding*

Originalmente, os domínios apresentavam granularidades temáticas distintas: a TV linear possuía um conjunto reduzido de temas editoriais associados à grade, enquanto o *streaming* possuía uma taxonomia mais extensa. Para reduzir o desalinhamento semântico, foi definido um conjunto de 10 macro-temas canônicos (Informação, Entretenimento, Esporte, Ficção, Educação & Ciência, Cultura & Sociedade, Comportamento & Vida Pessoal, Religião & Espiritualidade, Mistério & Exploração, Tecnologia & Games), aplicável a ambos os domínios.

Após o mapeamento de temas de cada domínio para o tema canônico correspondente, foi aplicado *one-hot encoding*. Assim, cada instância passou a ser representada por um vetor binário de temas, evitando hierarquia artificial entre categorias e permitindo que os modelos aprendam padrões de engajamento condicionados ao conteúdo.

5.2.2 Variáveis temporais e categoria “Desconhecido”

No domínio da TV linear, o consumo é síncrono à grade de programação, e o contexto temporal é representado por dia da semana e período do dia (manhã, tarde e noite), também codificados por *one-hot encoding*. No domínio de *streaming*, entretanto, não existe uma grade fixa equivalente: ainda que os vídeos possuam horário de publicação, esse horário não representa a janela de consumo e, portanto, não deve ser utilizado como proxy de período do dia.

Assim, para preservar coerência conceitual e evitar a introdução de sinal artificial, os registros de *streaming* foram codificados com `Periodo_Desconhecido = 1` e `Periodo_Manha = Periodo_Tarde = Periodo_Noite = 0`, enquanto na TV linear utiliza-se `Periodo_Desconhecido = 0`. Estratégia análoga foi adotada para o dia da semana quando ausente

(Dia_Desconhecido).

5.2.3 Padronização demográfica e conjunto final de *features*

As variáveis demográficas (gênero, faixas etárias e classes) foram convertidas para proporções no intervalo $[0, 1]$, garantindo estabilidade numérica e compatibilidade de escala. Ao final do processo, os três conjuntos de dados passaram a compartilhar o mesmo conjunto de colunas, incluindo variáveis temáticas, temporais, demográficas, além das colunas Engajamento e Ano. Essa padronização permite comparar modelos *TV-only* com modelos pré-treinados em *streaming* sem divergência estrutural de entrada.

5.3 Definição das Variáveis-Alvo

Nesta pesquisa, o engajamento é operacionalizado em duas famílias: engajamento ativo (interações explícitas) e engajamento passivo (consumo/atenção). A escolha do alvo mostrou-se determinante para a estabilidade da transferência entre domínios, uma vez que definições com distribuições muito distintas podem induzir *transferência negativa* por desalinhamento do *target*.

5.3.1 Engajamento ativo no streaming

Foram conduzidos testes exploratórios para definir uma medida ativa mais eficaz e comparável. A forma inicial (não normalizada) do engajamento ativo foi definida como:

$$E_a(i) = \frac{L_i + C_i}{V_i},$$

(5.1) em que L representa curtidas (*likes*), C comentários e V visualizações do vídeo.

Em seguida, visando tornar a medida comparável entre conteúdos com dinâmicas distintas, adotou-se uma versão normalizada por tema canônico. Seja $t(i)$ o tema do vídeo i e $\mu_{E_a, t(i)}$ a média de E_a para esse tema, define-se:

$$E_a^{(\text{norm})}(i) = \frac{E_a(i)}{\mu_{E_a, t(i)}}. \quad (5.2)$$

Essa normalização estabelece uma interpretação relativa: valores maiores que 1 indicam desempenho acima do esperado para o tema, enquanto valores menores que 1 indicam desempenho abaixo do esperado.

5.3.2 Engajamento passivo no streaming: evolução e escolha do *z-score*

O engajamento passivo no *streaming* foi construído a partir de sinais de consumo, particularmente métricas baseadas em retenção (por exemplo, percentual médio assistido). Diferentes definições foram avaliadas antes da escolha final.

Primeiramente, foi testado o uso direto da retenção como alvo passivo. Em seguida, foi avaliada uma forma relativa por tema baseada em diferença:

$$E_p^{(\text{dif})}(i) = R_i - \mu_{R,t(i)}, \quad (5.3)$$

bem como uma forma por razão, visando aproximar semanticamente o proxy utilizado na TV:

$$E_p^{(\text{raz})}(i) = \frac{R_i}{\mu_{R,t(i)}}. \quad (5.4)$$

Entretanto, a estabilidade numérica e a robustez a variações de escala mostraram-se mais adequadas na padronização por *z-score*. Assim, a definição principal de engajamento passivo no *streaming* adotada nesta pesquisa foi:

$$E_p^{(z)}(i) = \frac{R_i - \mu_{R,t(i)}}{\sigma_{R,t(i)}}, \quad (5.5)$$

em que $\mu_{R,t(i)}$ e $\sigma_{R,t(i)}$ correspondem, respectivamente, à média e ao desvio padrão da retenção R dentro do tema canônico do vídeo i . Essa escolha foi motivada por maior estabilidade frente a dispersões distintas entre temas e pela redução de problemas de escala observados nas alternativas anteriores, mantendo comportamento consistente nos resultados comparativos.

5.3.3 Engajamento passivo na TV: proxy contextual por razão

No domínio da TV linear, o engajamento é predominantemente passivo e é observado indiretamente por audiência/exposição. Para evitar distorções causadas por diferenças de contexto (por

exemplo, manhã versus noite) e por variações sistemáticas entre dias da semana, foi adotado um proxy de engajamento contextual baseado na razão entre a audiência do minuto e a audiência média do seu contexto editorial-temporal.

Seja A_j a audiência observada no minuto j , e seja $\mu_{A,g(j)}$ a audiência média no grupo $g(j)$ definido pela combinação *Tema Canônico + Período do dia + Dia da semana*. Define-se:

$$E_{TV}(j) = \frac{A_j}{\mu_{A,g(j)}}. \quad (5.6)$$

Essa definição é estável e defensável para o conjunto de dados, pois evita comparar diretamente contextos naturalmente incomparáveis (por exemplo, jornal da manhã versus conteúdo do horário nobre) e não depende de identificação de programa individual, inexistente nas bases utilizadas.

5.4 Modelos Utilizados

5.4.1 SVR

O Support Vector Regression (SVR) foi empregado como *baseline* por sua capacidade de modelar relações não lineares por meio de kernels e por ser um método clássico em regressão com *features* heterogêneas. Utilizou-se o kernel RBF. Os demais hiperparâmetros foram mantidos nos valores padrão da implementação ($C=1.0$, $\epsilon=0.1$, $\gamma='scale'$). As *features* foram padronizadas com *StandardScaler* antes do treinamento, devido à sensibilidade do SVR à escala das variáveis.

5.4.2 MLP

Redes neurais do tipo Perceptron Multicamadas (MLP) foram utilizadas devido à flexibilidade para capturar relações não lineares complexas entre atributos temáticos, temporais e demográficos e o engajamento. O MLP foi avaliado tanto no regime *TV-only* quanto no regime com pré-treinamento em *streaming*.

A arquitetura do MLPRegressor foi definida como duas camadas ocultas com o parâmetro `hidden_layer_sizes=(128, 64)` na execução principal, sendo utilizada tanto no regime *TV-only* quanto no regime com pré-treinamento em *streaming*.

5.4.3 Transfer Learning (streaming $\rightarrow$ TV)

O *Transfer Learning* foi aplicado por meio do pré-treinamento do MLP no domínio de *streaming* e subsequente adaptação (*fine-tuning*) no domínio da TV. Essa estratégia busca reutilizar representações aprendidas a partir de sinais mais ricos para auxiliar a estimação de engajamento em um domínio com dados agregados.

Como medida de controle de sobreajuste durante o *fine-tuning*, foi avaliado o congelamento de camadas densas iniciais, preservando parte da representação aprendida no domínio de *streaming*.

5.5 Protocolo Experimental

5.5.1 Estratégias de treino/teste e avaliação temporal

Foram avaliadas estratégias de treino e teste que permitem comparar: (i) modelos treinados exclusivamente no domínio da TV, e (ii) modelos com pré-treinamento em *streaming* e adaptação na TV. Estratégias temporais foram consideradas para reduzir risco de vazamento e aproximar o cenário de uso real, em que se aprende com dados passados para inferir comportamentos em períodos futuros.

5.5.2 Métricas

A avaliação foi conduzida por métricas típicas de regressão, incluindo MSE, MAE, R^2 e correlação, permitindo analisar simultaneamente erro, explicação de variância e relação linear entre valores previstos e reais.

5.6 Resultados Experimentais

5.6.1 Modelos interpretáveis: Árvore de Decisão e Floresta Aleatória

Antes de discutir os modelos principais (SVR, MLP e Transfer Learning), foram considerados modelos baseados em árvores por dois motivos: (i) fornecer uma interpretação direta sobre quais atributos mais influenciam a predição do engajamento e (ii) apoiar decisões de seleção/validação de atributos para a etapa de modelagem principal. Neste trabalho, a Árvore de Decisão (*Decision Tree*) representa o caso mais simples e altamente interpretável, enquanto a Floresta Aleatória (*Random Forest*) representa uma versão mais robusta (agregada) que reduz a variância do ajuste quando comparada a uma única árvore.

A importância das variáveis pode ser obtida diretamente pelos modelos (por exemplo, via *feature importance*), permitindo analisar quais grupos de atributos (temas `Tema_*`, período do dia `Periodo_*`, variáveis demográficas, etc.) tendem a contribuir mais para a estimativa de engajamento. Esse diagnóstico é especialmente útil neste estudo, pois há uma forte diferença de natureza entre os domínios (TV linear vs. streaming): embora as bases sejam alinhadas por um conjunto comum de **36 features**, os mecanismos geradores do engajamento e a escala do alvo (*target*) podem ser bastante distintos, o que afeta diretamente a generalização.

Em síntese, Árvore e Floresta não foram utilizadas como foco de desempenho final, mas como instrumentos para interpretação e apoio metodológico: elas ajudam a justificar, dentro do texto, (a) por que certas variáveis são preservadas no alinhamento entre domínios e (b) por que o modelo principal deve ser avaliado não apenas por erro absoluto, mas também por medidas de ordenação (*ranking*), discutidas a seguir.

5.6.2 Configuração do modelo principal e protocolo experimental

O modelo principal foi executado utilizando três conjuntos de dados: streaming, TV 2023 e TV 2024. Os dados foram alinhados para compartilhar o mesmo conjunto de *features* de entrada, criando colunas ausentes com zero e reordenando-as de forma consistente, totalizando **36 features** alinhadas.

Para evitar inconsistências de escala e permitir que os domínios possam ser comparados, aplicou-se normalização com *StandardScaler*. O *scaler* foi ajustado apenas no conjunto de treino do streaming e aplicado posteriormente em TV 2023 e TV 2024, mantendo uma referência de escala única aprendida no domínio de streaming.

Foram avaliadas quatro abordagens:

1. **SVR (TV-only)**: baseline treinado apenas com TV 2024.
2. **MLPRegressor (TV-only)**: baseline treinado apenas com TV 2024.
3. **Transfer Learning — Estratégia 1**: pré-treino no streaming e *fine-tuning* em TV 2024, com avaliação em TV 2024.
4. **Transfer Learning — Estratégia 2**: pré-treino no streaming, *fine-tuning* em TV 2023 e teste em TV 2024.

As métricas reportadas incluem MSE, MAE, RMSE, R^2 e correlação de Pearson. Além disso, foi incorporada a correlação de Spearman (ρ) para avaliar **capacidade de ranking**, já que em muitos cenários de recomendação/interpretação o que importa é ordenar corretamente quem engaja mais/menos, mesmo quando a escala absoluta do valor é difícil de reproduzir entre domínios.

5.6.3 Resultados — Engajamento Ativo

A Tabela 9 resume os resultados do engajamento ativo (apresenta os resultados médios de três execuções independentes do experimento, a fim de reduzir efeitos de inicialização e variação estocástica do treinamento.).

Observa-se que o MLP (TV-only) obteve o melhor desempenho absoluto entre os baselines, enquanto o Transfer Learning da Estratégia 1 obteve desempenho competitivo, porém sem superar o MLP treinado diretamente em TV 2024. A Estratégia 2 apresentou forte degradação da capacidade de generalização, produzindo erro extremamente alto e R^2 fortemente negativo, indicando que o modelo se desajustou ao transferir conhecimento de TV 2023 para prever TV 2024.

Tabela 9 – Modelo principal — Engajamento Ativo (teste em TV 2024).

Modelo	MSE	MAE	RMSE	R^2	Pearson	Spearman
SVR (TV-only)	0.036400	0.144014	0.190789	0.148069	0.397439	0.3279
MLPRegressor (TV-only)	0.023377	0.111172	0.152895	0.452879	0.695772	0.5809
Transfer (Estratégia 1)	0.027006	0.119455	0.164335	0.367944	0.625465	0.6101
Transfer (Estratégia 2)	0.543396	0.592064	0.737154	-11.717861	0.107261	—

Pela ótica de ranking (Spearman), apresentada na Tabela 9, observa-se que, embora nem sempre o valor absoluto seja estimado com máxima precisão, os modelos conseguem ordenar as instâncias de forma coerente. Destaca-se que o Transfer Learning (Estratégia 1) obteve o melhor desempenho em termos de ordenação, seguido pelo MLP (TV-only), enquanto o SVR apresentou desempenho inferior nesse critério.

Além disso, ao congelar duas camadas densas no *fine-tuning* do Transfer Learning (preservando mais conhecimento do streaming), obteve-se um resultado mais próximo do baseline MLP, com $R^2 \approx 0.4320$, Pearson ≈ 0.6725 e Spearman ≈ 0.5693 . Isso sugere que a regularização estrutural (congelamento) ajuda a reduzir o afastamento do modelo em relação às representações úteis aprendidas no streaming, mantendo capacidade de generalização no domínio TV. Essa variação foi exploratória e não constitui etapa central do protocolo.

Não foi reportado o coeficiente de Spearman para a Estratégia 2, pois o modelo apresentou comportamento degenerado, com forte perda de capacidade preditiva, inviabilizando uma análise consistente de ordenação.

Um aspecto relevante observado é que, embora o engajamento ativo não tenha apresentado o melhor desempenho em termos de erro absoluto, ele demonstrou maior capacidade de preservar a ordenação relativa entre as instâncias, conforme evidenciado pelos valores apresentados na Tabela 9.

Esse comportamento pode ser interpretado à luz da natureza dos dados: o engajamento ativo é originado no domínio de streaming, onde há interações explícitas dos usuários (curtidas e comentários). Ao transferir esse conhecimento para o domínio da TV, que não possui interações diretas, o modelo passa a capturar padrões relativos de interesse, funcionando de forma mais eficaz para ordenação (ranking) do que para estimativa precisa dos valores absolutos.

Assim, o engajamento ativo atua como um complemento informacional ao engajamento passivo da TV, permitindo ao modelo inferir preferências relativas mesmo na ausência de sinais

explícitos de interação.




Figura 3 – Engajamento ativo (TV 2024): dispersão y_{true} vs. y_{pred} para SVR (TV-only).




Figura 4 – Engajamento ativo (TV 2024): dispersão y_{true} vs. y_{pred} para MLPRegressor (TV-only).




Figura 5 – Engajamento ativo (TV 2024): dispersão y_{true} vs. y_{pred} para Transfer Learning (Estratégia 1).




Figura 6 – Engajamento ativo (TV 2024): dispersão y_{true} vs. y_{pred} para Transfer Learning (Estratégia 2).




Figura 7 – Engajamento ativo (TV 2024): histograma dos resíduos do MLPRegressor (TV-only).




Figura 8 – Engajamento ativo (TV 2024): histograma dos resíduos do Transfer Learning (Estratégia 1).

A análise dos gráficos de dispersão (y_{true} vs. y_{pred}) permite observar o comportamento dos modelos além das métricas agregadas. No caso do SVR, observa-se maior dispersão dos

pontos em relação à diagonal ideal, indicando menor capacidade de ajuste fino dos valores de engajamento.

O MLP (TV-only) apresenta maior concentração dos pontos próximos à diagonal, evidenciando melhor ajuste global e maior capacidade de capturar relações não lineares entre as variáveis.

Já o modelo com Transfer Learning (Estratégia 1) apresenta comportamento intermediário, mantendo uma tendência de alinhamento com os valores reais, porém com maior dispersão quando comparado ao MLP puro. Isso sugere que o conhecimento transferido do domínio de streaming contribui parcialmente, mas não substitui completamente o aprendizado direto no domínio da TV.

Por outro lado, a Estratégia 2 apresenta forte dispersão e ausência de alinhamento, evidenciando falha de generalização, consistente com os valores negativos de R^2 observados anteriormente.

A análise dos histogramas de resíduos indica que o MLP apresenta distribuição mais concentrada próxima de zero, enquanto o Transfer Learning apresenta maior variabilidade, indicando maior erro residual e menor estabilidade nas previsões.

5.6.4 Resultados — Engajamento Passivo

Antes da análise dos resultados, é importante destacar que os modelos *TV-only* utilizados nos experimentos de engajamento ativo e passivo são idênticos, pois são treinados exclusivamente com dados da TV linear, sem acesso às definições de engajamento do domínio de *streaming*.

Dessa forma, como o conjunto de entrada e o alvo no domínio da TV permanecem os mesmos, os valores obtidos para os modelos SVR e MLP (TV-only) são iguais em ambas as análises. A distinção entre engajamento ativo e passivo torna-se relevante apenas no contexto do *Transfer Learning*, em que diferentes definições de engajamento são aprendidas no domínio de *streaming* e posteriormente transferidas para a TV.

Isso também garante comparabilidade direta entre os cenários, isolando o efeito da transferência de conhecimento como única fonte de variação entre os resultados.

A Tabela 10 resume os resultados do engajamento passivo no mesmo protocolo (teste em

TV 2024). O padrão se repete: baselines TV-only são fortes, o Transfer Learning da Estratégia 1 permanece competitivo, e a Estratégia 2 novamente apresenta instabilidade (com R^2 negativo), ainda que menos catastrófica do que no caso do engajamento ativo em sua rodada mais extrema.

Por outro lado, o engajamento passivo apresentou melhor desempenho em métricas de escala, como R^2 e correlação de Pearson, indicando maior capacidade de estimar os valores absolutos do alvo.

Esse resultado é consistente com o fato de que o proxy de engajamento passivo na TV é construído a partir de audiência, que é uma medida diretamente relacionada ao consumo, assim como as métricas de retenção utilizadas no streaming. Dessa forma, há maior compatibilidade estatística entre os domínios.

No entanto, essa maior compatibilidade em escala não implica necessariamente melhor capacidade de ordenação, o que reforça a importância de avaliar simultaneamente métricas de erro e métricas de ranking no problema estudado.

Tabela 10 – Modelo principal — Engajamento Passivo (teste em TV 2024).

Modelo	MSE	MAE	RMSE	R^2	Pearson	Spearman
SVR (TV-only)	0.036400	0.144014	0.190789	0.148069	0.397439	0.3279
MLPRegressor (TV-only)	0.023377	0.111172	0.152895	0.452879	0.695772	0.5809
Transfer (Estratégia 1)	0.025918	0.118522	0.160991	0.393399	0.642309	0.5119
Transfer (Estratégia 2)	18.389931	2.047767	4.288348	-429.405676	0.055190	—

Pela ótica de ranking (Spearman), apresentada na Tabela 10, observa-se que o MLP (TV-only) apresentou o melhor desempenho em termos de ordenação, seguido pelo Transfer Learning (Estratégia 1) e pelo SVR. Esses resultados indicam que, embora o engajamento passivo apresente boa capacidade de ajuste em escala, a preservação da ordenação relativa das instâncias não é necessariamente superior à observada no engajamento ativo.

Ao aplicar o congelamento de duas camadas densas no Transfer Learning, observou-se melhora relevante, com $R^2 \approx 0.4373$, Pearson ≈ 0.6756 e Spearman ≈ 0.5724 . Esse comportamento sugere que, mesmo no engajamento passivo, preservar representações aprendidas no domínio de streaming contribui para reduzir o risco de sobreajuste durante o *fine-tuning*, mantendo a capacidade de ordenação.

Não foi reportado o coeficiente de Spearman para a Estratégia 2, pois o modelo apresentou comportamento instável, com perda significativa de capacidade preditiva, inviabilizando uma

análise consistente de ordenação.




Figura 9 – Engajamento passivo (TV 2024): dispersão y_{true} vs. y_{pred} para SVR (TV-only).




Figura 10 – Engajamento passivo (TV 2024): dispersão y_{true} vs. y_{pred} para MLPRegressor (TV-only).




Figura 11 – Engajamento passivo (TV 2024): dispersão y_{true} vs. y_{pred} para Transfer Learning (Estratégia 1).




Figura 12 – Engajamento passivo (TV 2024): dispersão y_{true} vs. y_{pred} para Transfer Learning (Estratégia 2).




Figura 13 – Engajamento passivo (TV 2024): histograma dos resíduos do MLPRegressor (TV-only).




Figura 14 – Engajamento passivo (TV 2024): histograma dos resíduos do Transfer Learning (Estratégia 1).

Os padrões observados nos gráficos de engajamento passivo seguem tendência seme-

lhante aos do engajamento ativo, porém com diferenças importantes. Nota-se que os modelos apresentam melhor alinhamento global dos valores preditos, refletindo os resultados superiores em métricas como R^2 e correlação de Pearson.

O MLP (TV-only) mantém o melhor ajuste, com maior concentração de pontos próximos à diagonal. O Transfer Learning (Estratégia 1) apresenta desempenho competitivo, indicando que o engajamento passivo possui maior compatibilidade estrutural entre os domínios de streaming e TV linear.

Entretanto, mesmo com melhor ajuste em escala, observa-se que a dispersão ainda é significativa em regiões extremas, indicando dificuldade na estimativa precisa de valores mais altos ou mais baixos de engajamento.

A Estratégia 2 novamente apresenta comportamento instável, reforçando a sensibilidade do modelo a mudanças de distribuição temporal entre os anos analisados.

5.6.5 Discussão: vazamento temporal, diferença de escala e falha da Estratégia 2

Do ponto de vista metodológico, a Estratégia 2 é, em princípio, a mais alinhada à boa prática temporal (treinar no passado e testar no futuro). No entanto, os resultados mostram que ela pode falhar drasticamente quando há mudança de distribuição entre TV 2023 e TV 2024, quando há desalinhamento de escala do alvo (*target*) ou quando o *fine-tuning* força o modelo a se adaptar a um subconjunto de padrões que não generaliza para o ano seguinte. Isso explica a ocorrência de R^2 negativo e erros elevados.

Já a Estratégia 1, apesar de potencialmente misturar adaptação e avaliação no mesmo ano (TV 2024), serviu como uma referência prática de quanto o conhecimento do streaming pode ser reaproveitado ao adaptar o modelo ao domínio TV. A adoção de métricas de ranking (Spearman) fortalece a interpretação dos resultados, pois evidencia que o modelo pode ser mais eficaz para **ordenar** padrões de engajamento do que para reproduzir exatamente os valores absolutos, especialmente quando os domínios possuem escalas e mecanismos geradores distintos.

5.6.6 Análise de temas no período noturno (TV 2024)

Como leitura adicional, foi realizada uma análise contrafactual simples ativando/desativando variáveis `Tema_*` para estimar o efeito relativo previsto pelo modelo no período noturno. Para o engajamento ativo, os cinco temas com maior efeito relativo no período da noite foram: `Tema_Cultura_Sociedade`, `Tema_Ficcao`, `Tema_Esporte`, `Tema_Educacao_Ciencia` e `Tema_Entretenimento`. Para o engajamento passivo, os cinco temas com maior ganho relativo no período noturno foram: `Tema_Religiao`, `Tema_Misterio`, `Tema_Comportamento_Vida`, `Tema_Info` e `Tema_Esporte`. Essa diferença entre ativo e passivo sugere que os dois alvos capturam dimensões distintas de comportamento do público, o que reforça a necessidade de avaliá-los separadamente no estudo.

Os valores completos estimados para todos os temas encontram-se apresentados no Apêndice A.

5.7 Síntese dos Resultados

Os resultados indicam que modelos *TV-only* são capazes de aprender padrões a partir das *features* agregadas disponíveis, enquanto a eficácia do *Transfer Learning* depende criticamente da compatibilidade do alvo entre domínios. Observou-se que a definição de engajamento passivo no *streaming* baseada em *z-score* apresentou maior estabilidade numérica e comportamento consistente em comparação às alternativas testadas, contribuindo para uma avaliação mais robusta do impacto da transferência de conhecimento.

Esses resultados reforçam que a escolha do alvo de engajamento influencia diretamente não apenas o desempenho preditivo, mas também o tipo de informação que pode ser transferida entre domínios, evidenciando que a transferibilidade depende da natureza estatística do fenômeno modelado.

6

DISCUSSÃO E CONCLUSÕES

Este capítulo discute criticamente os resultados obtidos, relacionando-os aos objetivos e à hipótese do trabalho. Também são apresentadas limitações, contribuições e direções futuras, com ênfase na compatibilização entre os domínios de TV linear e streaming.

6.1 Discussão dos Resultados

Os experimentos indicam que modelos treinados exclusivamente no domínio de TV (*TV-only*) conseguem aprender padrões relevantes de variação do engajamento a partir de um conjunto limitado de atributos agregados, especialmente quando empregadas funções não lineares (MLP). Esse comportamento sugere que, mesmo com menor granularidade informacional, os dados de audiência da TV linear preservam sinais estatísticos suficientes para estimar variações relativas de engajamento em diferentes contextos temporais e demográficos.

No cenário de *Transfer Learning*, a estratégia baseada em pré-treino no streaming seguido de *fine-tuning* na TV 2024 apresentou desempenho competitivo em relação ao melhor baseline, sobretudo quando consideradas métricas de correlação e consistência de ordenação. Em particular, a avaliação por Spearman mostrou-se relevante para este problema, pois a aplicação prática frequentemente depende mais da capacidade de priorizar e ranquear condições de maior engajamento (por tema, período e perfil) do que de estimar com exatidão o valor absoluto do alvo.

Um aspecto adicional observado é que a eficácia da transferência varia conforme a dimensão do engajamento considerada. Nos experimentos, o engajamento passivo apresentou

desempenho ligeiramente superior em métricas de escala (R^2 e correlação de Pearson), sugerindo maior compatibilidade na magnitude do fenômeno entre streaming e TV linear. Por outro lado, o engajamento ativo obteve melhores resultados em termos de ordenação (Spearman), indicando maior preservação da estrutura relativa de interesse entre instâncias. Esse comportamento sugere que diferentes regimes de engajamento transferem aspectos distintos do comportamento do público: o passivo tende a manter compatibilidade estatística de intensidade, enquanto o ativo preserva mais fortemente relações hierárquicas de preferência. Tal evidência reforça que a transferibilidade não é uniforme, mas dependente da natureza do alvo modelado.

Um ponto central observado nos resultados é a complementaridade entre os diferentes tipos de engajamento. Enquanto o engajamento passivo apresenta maior compatibilidade em termos de magnitude entre os domínios, o engajamento ativo demonstra maior capacidade de preservar relações relativas de interesse entre conteúdos.

Esse comportamento pode ser explicado pelo fato de que a TV linear mede predominantemente consumo passivo, sem registrar interações explícitas dos usuários. Já o streaming captura tanto consumo quanto interação ativa, permitindo que o modelo aprenda estruturas mais ricas de preferência.

Assim, ao transferir conhecimento do engajamento ativo para o domínio da TV, o modelo não necessariamente melhora a estimativa absoluta, mas contribui para enriquecer a interpretação relativa do engajamento, funcionando como um complemento ao sinal passivo disponível.

Por outro lado, a estratégia temporalmente mais conservadora (pré-treino no streaming, *fine-tuning* na TV 2023 e teste na TV 2024) apresentou degradação acentuada. Embora essa abordagem seja conceitualmente apropriada para reduzir risco de vazamento temporal, os resultados são compatíveis com a presença de *non-stationarity* e *domain shift* entre 2023 e 2024. Isso sugere que a relação entre as variáveis explicativas e o proxy de engajamento pode se modificar ao longo do tempo, possivelmente refletindo mudanças no perfil do público e/ou no padrão de consumo em TV linear. Assim, o desempenho negativo não deve ser interpretado exclusivamente como falha metodológica, mas como evidência empírica de sensibilidade temporal e de incompatibilidade parcial entre períodos.

Os resultados obtidos incluem evidências claras de transferência negativa, especialmente na Estratégia 2, na qual o conhecimento prévio aprendido no domínio de streaming e ajustado

em TV 2023 comprometeu a capacidade de generalização para TV 2024. Esse comportamento indica que, sob incompatibilidade estrutural do alvo e mudanças de distribuição temporal, o conhecimento prévio pode atuar como viés prejudicial, degradando o desempenho em vez de melhorá-lo.

Em conjunto, esses achados sugerem que o engajamento não é apenas um fenômeno quantitativo dependente da disponibilidade de dados, mas uma estrutura estatística cujo significado depende do regime de observação em que é medido. Enquanto o domínio de streaming captura interações individuais ricas e contínuas, a TV linear opera sob observações agregadas e discretizadas, o que implica que os modelos aprendem representações semanticamente distintas do mesmo conceito aparente. A ocorrência de degradação acentuada em cenários temporalmente consistentes indica que a transferência entre esses regimes não é apenas um problema de regularização ou de tamanho de amostra, mas de compatibilidade estrutural entre os mecanismos geradores dos dados.

A comparação qualitativa entre os domínios reforça que o streaming apresenta maior heterogeneidade entre conteúdos, com forte disparidade de consumo mesmo sob condições semelhantes (tema, criador e janela temporal), enquanto a TV linear é fortemente condicionada pela grade de programação e pelo contexto de rotina do domicílio. Nesse sentido, parte das variações observadas no engajamento da TV pode estar associada à disponibilidade social em horários específicos (por exemplo, transições de rotina doméstica), e não exclusivamente ao interesse temático, diferindo do comportamento típico em plataformas sob demanda, nas quais a escolha é mais individual e assíncrona.

No streaming, embora o horário de publicação possa influenciar o desempenho inicial e a exposição do conteúdo (por efeito de disponibilidade do público e mecanismos de recomendação), o conteúdo permanece acessível de forma contínua, de modo que o engajamento tende a refletir uma combinação de fatores cumulativos ao longo do tempo. Na TV, por contraste, o consumo é mais rigidamente ancorado na grade e, portanto, variáveis temporais podem assumir papel mais determinante na explicação do proxy de engajamento.

6.2 Implicações metodológicas sobre o alvo e compatibilidade entre domínios

Os resultados deste trabalho evidenciam que a transferência de modelos entre domínios com diferentes regimes de observação exige cuidados metodológicos que vão além da escolha do algoritmo de aprendizado. Em particular, destaca-se que a definição do alvo (proxy de engajamento) desempenha papel central na compatibilidade entre domínios. Embora os dados de streaming e TV linear possam compartilhar variáveis descritivas semelhantes (tema, janela temporal, perfil demográfico), o significado estatístico do engajamento medido em cada domínio é influenciado pelo mecanismo gerador dos dados e pelo grau de agregação da observação.

No streaming, métricas explícitas de engajamento (curtidas e comentários) representam interações voluntárias e diretas do usuário. Na TV linear, a ausência de métricas explícitas motivou o uso de um proxy de engajamento baseado em audiência observada em janelas temporais e contextos editoriais.

Nesse contexto, a simples correspondência estrutural de atributos não garante a transferibilidade do conhecimento aprendido. A ocorrência de degradação acentuada de desempenho em cenários temporalmente consistentes indica que diferenças semânticas do alvo e variações de distribuição ao longo do tempo podem comprometer a generalização, caracterizando casos de transferência negativa. Assim, recomenda-se que estudos de Transfer Learning entre domínios heterogêneos incluam análises explícitas de compatibilidade do alvo, testes de estabilidade temporal e avaliação de *dataset shift*, em vez de assumir equivalência automática entre proxies de fenômenos aparentemente semelhantes.

Além disso, os resultados sugerem que métricas baseadas em ordenação (como Spearman) podem constituir evidência complementar relevante em cenários nos quais a preservação de relações relativas entre instâncias é mais importante do que a precisão numérica absoluta. Essa perspectiva é particularmente pertinente em aplicações de priorização, recomendação ou planejamento de grade, nas quais a hierarquia de engajamento entre condições é operacionalmente mais significativa do que o valor exato estimado.

Por fim, a análise reforça a importância de protocolos temporais bem definidos. Estratégias que respeitam a ordem temporal dos dados podem expor instabilidades que permaneceriam ocultas em divisões aleatórias, evidenciando mudanças de distribuição entre períodos. Assim,

recomenda-se que pesquisas envolvendo dados comportamentais longitudinais adotem validações temporais explícitas como parte integrante da avaliação metodológica.

6.3 Limitações do Trabalho

Embora os resultados obtidos forneçam evidências relevantes sobre a transferência de conhecimento entre os domínios de streaming e TV linear, este trabalho apresenta limitações que delimitam o escopo de generalização das conclusões.

Primeiramente, a análise foi conduzida com um conjunto específico de dados de audiência de TV linear e um conjunto particular de dados de streaming, o que implica que os padrões observados podem refletir características contextuais desses recortes (perfil regional, grade de programação e tipo de conteúdo). Estudos com outras emissoras, períodos históricos e plataformas digitais podem apresentar comportamentos distintos, especialmente em contextos com maior ou menor interatividade.

Em segundo lugar, o proxy de engajamento na TV linear foi necessariamente indireto, baseado em medidas de audiência agregadas. Embora essa abordagem seja coerente com a disponibilidade de dados no domínio, ela não captura interações explícitas individuais, como ocorre no streaming. Dessa forma, parte da incompatibilidade observada entre domínios pode decorrer de limitações intrínsecas à mensuração, e não apenas de diferenças comportamentais.

Adicionalmente, a avaliação concentrou-se em um conjunto restrito de atributos compartilhados entre os domínios, de modo a viabilizar a comparação estrutural. Essa restrição, embora metodologicamente necessária para investigar a transferência sob compatibilidade parcial, limita o potencial expressivo dos modelos, especialmente no domínio de streaming, onde variáveis contextuais adicionais poderiam enriquecer a representação do engajamento.

Do ponto de vista temporal, a análise envolveu dois anos consecutivos de dados de TV linear. Embora isso permita observar indícios de instabilidade temporal e *domain shift*, séries mais longas poderiam oferecer uma caracterização mais robusta da variabilidade interanual e dos ciclos de consumo.

Por fim, o estudo concentrou-se em modelos supervisionados de regressão e em estratégias clássicas de *Transfer Learning*. Abordagens mais avançadas de adaptação de domínio,

aprendizado auto-supervisionado ou modelagem causal não foram exploradas, e podem oferecer perspectivas complementares sobre a compatibilidade entre regimes de observação.

Do ponto de vista técnico, na estratégia de *fine-tuning* na TV 2024, o monitoramento do treinamento utilizou o próprio conjunto de teste como referência, o que não representa a prática ideal de separação entre validação e avaliação final. Estudos futuros devem empregar uma partição de validação dedicada ou esquemas de validação temporal cruzada para reduzir possíveis vieses de ajuste.

6.4 Contribuições da Pesquisa

As principais contribuições desta pesquisa incluem: (i) Demonstração empírica de que a transferência direta de modelos de engajamento do domínio de streaming para a TV linear, sob restrição de atributos, é estruturalmente instável, incluindo casos observados de transferência negativa, revelando um limite fundamental da adaptação entre regimes de observação com diferentes granularidades de dados; (ii) a proposta de uma abstração baseada em janelas temporais de observação que permite tratar TV linear e streaming sob um arcabouço comum de aprendizado estatístico; (iii) a definição e avaliação de proxies de engajamento em domínios com diferentes níveis de observabilidade; (iv) a análise comparativa de modelos *TV-only* e estratégias de *Transfer Learning* em um cenário temporal realista; (v) a incorporação de métricas de ranking (Spearman) como evidência complementar à avaliação tradicional de regressão.

6.5 Trabalhos Futuros

A partir das limitações identificadas e dos resultados obtidos, diversos caminhos de investigação podem ser explorados para aprofundar a compreensão da transferência de conhecimento entre domínios com diferentes regimes de observação.

Um primeiro eixo envolve a ampliação e diversificação dos conjuntos de dados, incluindo outros períodos históricos, emissoras e plataformas digitais. A análise de séries temporais mais longas pode permitir uma caracterização mais robusta da variabilidade interanual e da presença de mudanças estruturais no comportamento de consumo, contribuindo para o desenvolvimento

de modelos mais estáveis frente a *domain shift*.

Outro desdobramento relevante consiste na investigação de proxies alternativos de engajamento na TV linear, incorporando, sempre que disponíveis, sinais adicionais de interação (por exemplo, dados de segunda tela, métricas de retorno ou padrões de permanência). Isso pode reduzir a distância semântica entre os domínios e permitir avaliar em que medida a maior compatibilidade do alvo favorece a transferência de conhecimento.

Do ponto de vista metodológico, futuros estudos podem explorar técnicas mais avançadas de adaptação de domínio e regularização no *fine-tuning*, incluindo congelamento seletivo de camadas, penalizações para preservação de representações pré-treinadas e abordagens baseadas em alinhamento de distribuições. Métodos de aprendizado auto-supervisionado e modelagem causal também constituem direções promissoras para investigar a estrutura do engajamento de forma menos dependente de proxies específicos.

Além disso, recomenda-se a aplicação de testes formais de mudança de distribuição (*dataset shift*) e protocolos temporais mais rigorosos, incluindo validação cruzada temporal e avaliação prospectiva, de modo a fortalecer a robustez metodológica em cenários longitudinais.

Por fim, a evolução para ambientes mais interativos, como contextos associados à TV 3.0 e à integração com dispositivos conectados, pode reduzir a diferença de granularidade entre os domínios e oferecer um cenário natural para reavaliar a viabilidade da transferência de conhecimento sob maior compatibilidade observacional.

Em termos operacionais, essas direções podem ser implementadas por meio de protocolos experimentais que combinem séries temporais ampliadas, validação temporal cruzada e estratégias de adaptação de domínio mais robustas no *fine-tuning*.

6.6 Considerações Finais

Esta dissertação investigou a viabilidade da transferência de conhecimento entre domínios de observação com diferentes granularidades informacionais, tomando como estudo de caso a interpretação do engajamento em TV linear a partir de modelos pré-treinados em dados de streaming. Os resultados mostraram que, mesmo sob restrição de atributos, modelos treinados exclusivamente no domínio de TV são capazes de capturar variações relativas de engajamento,

indicando que sinais estatísticos relevantes permanecem presentes em dados agregados.

A aplicação de estratégias de *Transfer Learning* revelou que o conhecimento aprendido em streaming pode contribuir de forma parcial, especialmente na preservação de relações ordinais entre condições de engajamento. Contudo, observou-se que a transferência direta não é garantida: diferenças semânticas do alvo, mudanças de distribuição ao longo do tempo e incompatibilidades estruturais entre regimes de observação podem resultar em degradação de desempenho e em casos de transferência negativa.

Esses achados reforçam que o engajamento não deve ser tratado como uma variável universal independente do contexto de medição, mas como uma representação estatística cujo significado depende do mecanismo gerador dos dados e do nível de agregação da observação. Assim, a principal contribuição deste trabalho reside em demonstrar empiricamente os limites e as condições sob as quais a transferência entre domínios heterogêneos é plausível, oferecendo evidências de que a compatibilidade do alvo e a estabilidade temporal são fatores críticos para a generalização.

De forma mais ampla, os resultados sugerem que abordagens de aprendizado de máquina aplicadas a fenômenos comportamentais devem considerar explicitamente o regime de observação como parte integrante da modelagem. Assim, a principal contribuição deste trabalho está em delimitar, de forma empírica e metodologicamente justificável, os limites e as condições sob as quais a transferência entre domínios heterogêneos é plausível, contribuindo para uma compreensão mais fundamentada da adaptação de modelos entre contextos com diferentes níveis de observabilidade.

REFERÊNCIAS

- ALBARDÍA IRATI AGIRREAZKUENAGA ONAINDIA, S. P. F. M. S. Educomunicación en la era de la hiperconectividad: Educación libertadora para fomentar la ciudadanía crítica. *Comunicação, Mídia e Consumo*, ESPM, v. 20, n. 58, p. 179–198, 2023. [31](#), [32](#), [33](#)
- AMORIM, V. E. A.; BARRETO, D. de M. The growth of streaming service on open and subscription tv. *Revista de Administração do UNIFATEA - RAF*, v. 24, n. 01, p. 127–138, Jan-Jun 2022. [32](#), [33](#)
- BALLERINI, F.; KÜNSCH, D. A. O poder suave das telenovelas na era do streaming: Os novos desafios da tv globo frente ao formato das séries de hollywood. *Revista Comunicando*, v. 11, n. 1, p. 1–18, 2022. [31](#)
- BASTOS, M.; NARANJO-ZOLOTOV, M.; APARÍCIO, M. Binge-watching uncovered: Examining the interplay of perceived usefulness, habit, and regret in continuous viewing. *Heliyon*, Elsevier, v. 10, p. e27848, 2024. [54](#), [56](#), [58](#)
- BASTOS, T.; MARGOLIS, I.; PROVIDÊNCIA, B. A utilização de escalas de autorrelato na avaliação emocional do espectador de live streaming concert. In: *Design Centrado no Usuário: concepções, práticas e soluções*. Curitiba: Editora Insight, 2021. p. 24–39. [47](#), [58](#)
- BECKER, V.; GAMBARO, D.; FILHO, G. L. S. O impacto das mídias digitais na televisão brasileira: queda da audiência e aumento do faturamento. *Palavra Chave*, v. 18, n. 2, p. 341–373, 2015. [22](#), [24](#), [28](#), [29](#), [30](#)
- BOJIC, L. Ai alignment: Assessing the global impact of recommender systems. *Futures*, Elsevier, v. 160, p. 103383, 2024. [47](#), [50](#), [58](#)
- CASSARO, V. M. Várias tvs dentro de uma tv: Novos conceitos de televisão e o consumo da ficção narrativa. *Rev. Sítio Novo*, v. 5, n. 1, p. 31–43, 2021. Data de submissão: 18/7/2020. Data de aprovação: 28/9/2020. [29](#), [30](#)
- CASTELLANO, M.; MEIMARIDIS, M. A "televisão do futuro"? netflix qualidade e neofilia no debate sobre tv. *Matrizes*, v. 15, n. 1, p. 195–222, 2021. [22](#), [23](#)
- CUSTODIO, M. *O STREAMING COMO MODELO DE NEGÓCIO NA TV ABERTA BRASILEIRA: Desafios e Oportunidades*. Dissertação (Mestrado) — Universidade Estadual Paulista, Faculdade de Arquitetura, Artes, Comunicação e Design, Programa de Pós-Graduação em Mídia e Tecnologia, Bauru, 2024. Dissertação de Mestrado apresentada ao programa de Pós-Graduação em Mídia e Tecnologia (PPGMIT) – FAAC – UNESP – Bauru para obtenção do

título de Mestre em Mídia e Tecnologia, sob a orientação do Prof. Dr. Francisco Machado Filho. [31](#), [32](#), [33](#), [34](#), [39](#), [40](#)

ELAHI DANIAL KHOSH KHOLGH, M. S. K. M. O. M.; SAGHARI, S. Hybrid recommendation by incorporating the sentiment of product reviews. *Information Sciences*, Elsevier, v. 625, p. 738–756, 2023. [52](#), [56](#), [58](#)

FERNANDES, N. C. et al. Recepção móvel na tv 3.0: um caso de estudo com a tecnologia advanced isdb-t. *SET EXPO PROCEEDINGS*, v. 8, 2022. ISSN 2447-0481 (Print), 2447-049X (Online). Disponível em: <https://dx.doi.org/10.18580/setep.2022.47.6>. [39](#)

FERNÁNDEZ-TOBIÁS, I. et al. Cross-domain recommender systems: A survey of the state of the art. *Knowledge-Based Systems*, Elsevier, v. 34, p. 1–17, 2012. [50](#), [52](#), [58](#), [60](#)

FERREIRA, P. V. da S. *A live bombou? Avaliando métricas para engajamento em live streaming*. Dissertação (Mestrado) — Universidade Federal do Amazonas, Manaus, ago 2024. Orientador: Prof. Dr. Bruno Freitas Gadelha; Coorientador: Prof. Me. Genildo Gomes. [46](#), [47](#), [58](#)

GAO, H. L. G.; ZHAO, K. Live streaming recommendations based on dynamic representation learning. *Decision Support Systems*, Elsevier B.V., v. 169, p. 113957, 2023. [43](#), [46](#), [58](#)

GONÇALVES, A. R. et al. Artificial intelligence vs. autonomous decision-making in streaming platforms: A mixed-method approach. *International Journal of Information Management*, Elsevier, v. 76, p. 102748, 2024. [48](#), [50](#), [58](#)

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. *The Elements of Statistical Learning*. 2. ed. [S.l.]: Springer, 2009. [38](#)

HAZEM, H.; AWAD, A.; YOUSEF, A. H. A distributed real-time recommender system for big data streams. *Ain Shams Engineering Journal*, Elsevier, v. 14, p. 102026, 2023. [44](#), [46](#), [58](#)

HIRTH, C. C. L.; SANTOS, A. T. dos. A netflix como catalisadora da era pós-televisão: como a rede globo se reinventou após a febre dos streamings no brasil. In: *Intercom – Sociedade Brasileira de Estudos Interdisciplinares da Comunicação, 43º Congresso Brasileiro de Ciências da Comunicação*. VIRTUAL: [s.n.], 2020. p. 1–14. IJ04 – Comunicação Audiovisual, da Intercom Júnior – XVI Jornada de Iniciação Científica em Comunicação. [31](#), [34](#)

KNEIPP, V. A. P. *Trajetória da Televisão no Rio Grande do Norte: O Processo de Digitalização*. Mossoró, RN: Edições UERN; FAPERN, 2023. Disponível como E-book. ISBN 978-85-7621-464-9. [21](#), [24](#), [30](#), [31](#)

LIM, J. S. et al. How social media engagement leads to sports channel loyalty: Mediating roles of social presence and channel commitment. *Computers in Human Behavior*, Elsevier, v. 46, p. 158–167, 2015. [54](#), [56](#), [58](#)

LIMA, K. R. *Estimação e Mapeamento do Nível de Potência Recebida do Sinal Digital de TV na Região Urbana da Cidade de Mossoró – RN Utilizando Métodos de Interpolação Espacial*. Dissertação (Dissertação de Mestrado) — Universidade Federal Rural do Semi-Árido, Mossoró, RN, 2021. Orientador: Humberto Dionísio de Andrade, Coorientador: Antônio Sérgio Bezerra Sombra. [21](#), [24](#), [30](#), [31](#)

LUCAS JONATHAN GRATCH, N. M. E. S. E. F. J. N. G. M. Goaalll!: Using sentiment in the world cup to explore theories of emotion. *Image and Vision Computing*, Elsevier B.V., v. 65, p. 58–65, 2017. [53](#), [56](#), [58](#)

- MACHADO, B. A. dos S. R. *Evolução do Comportamento dos Usuários em Serviços de Streaming de Vídeo em Larga Escala*. Dissertação (Mestrado) — Universidade Federal de Juiz de Fora, Juiz de Fora, nov 2020. Orientador: Prof. Dr. Alex Borges Vieira; Coorientador: Prof. Dr. Ítalo Fernando Scotá Cunha. 46, 47, 58
- MARTINS LETICIA DE LIMA ALMEIDA, L. C. C. d. N. J. S. A. A. d. S. S. F. F. Streaming x tv por assinatura: Uma análise estatística comparativa da demanda. *Revista Tópicos*, 2023. Disponível em: <<https://revistatopicos.com.br/artigos/streaming-x-tv-por-assinatura-uma-analise-estatistica-comparativa-da-demanda>>. 32
- NAHAR, N. J.; VISHWAMITRA, L. K.; SUKHEJA, D. Collaborative learning based recommendation system for content streaming platform using non-negative matrix factorization clustering. *Procedia Computer Science*, Elsevier B.V., v. 230, p. 427–435, 2023. 43, 46, 58
- OLIVEIRA, P. B. d. *Plataformas Streaming e as Reconfigurações no Modo de Assistir TV: O Caso Netflix*. Dissertação (Dissertação (Mestrado)) — Universidade Tuiuti do Paraná, Curitiba, March 2020. Orientador: Prof. Dr. Carlos Eduardo Marquioni. 32, 33
- PAN, S. J.; YANG, Q. A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, IEEE, v. 22, n. 10, p. 1345–1359, 2010. 51, 52, 58, 59
- SATUF, I. Examinar, prever e prescrever comportamentos: como atuam os “algoritmos de engajamento” no globoplay. *Revista Fronteiras – Estudos Midiáticos*, Unisinos, Juazeiro do Norte, v. 22, n. 3, p. 29–40, dez 2020. 49, 50, 58
- SVARTMAN, R. *A telenovela e o futuro da televisão brasileira*. Rio de Janeiro, Brasil: Editora Cobogó, 2023. ISBN 978-65-5691-101-4. 21, 22, 28
- WEISS, K.; KHOSHGOFTAAR, T. M.; WANG, D. A survey of transfer learning. *Journal of Big Data*, Springer, v. 3, n. 1, p. 1–40, 2016. 51, 52, 58
- ZAMBELLI, W. I. K. Dissertação de Mestrado. *Digitalização do Sinal da Televisão Terrestre Brasileira: Principais Fatores que Transformaram o Projeto em um Caso de Sucesso*. Rio de Janeiro, RJ: [s.n.], 2023. Orientador: Dr. Cesar Zucco Jr. 21, 24, 30, 31
- ZHAO SHOUJIN WANG, Y. W. Y.; LIU, H. Mbsrs: A multi-behavior streaming recommender system. *Information Sciences*, Elsevier, v. 631, p. 145–163, 2023. 45, 46, 58

A

PRIMEIRO APÊNDICE

A.1 Análise Contrafactual de Temas — Engajamento Ativo
(Período Noturno, TV 2024)

Tabela 11 – Efeito relativo previsto pelo modelo para cada tema no período noturno — engajamento ativo (TV 2024).

Tema	ON vs Base	ON vs OFF	Tema ON	Base Noite
Tema_Cultura_Sociedade	0.069 883	0.069 883	0.324 623	0.254 739
Tema_Ficcao	0.029 244	0.064 850	0.283 983	0.254 739
Tema_Esporte	0.024 671	0.026 233	0.279 410	0.254 739
Tema_Educacao_Ciencia	-0.030 333	-0.030 333	0.224 406	0.254 739
Tema_Entretenimento	-0.057 852	-0.062 280	0.196 887	0.254 739
Tema_Religiao	-0.060 330	-0.060 330	0.194 410	0.254 739
Tema_Info	-0.081 980	-0.101 573	0.172 760	0.254 739
Tema_Tecnologia_Games	-0.106 945	-0.106 945	0.147 794	0.254 739
Tema_Comportamento_Vida	-0.328 779	-0.328 779	-0.074 040	0.254 739
Tema_Misterio	-1.030 059	-1.030 059	-0.775 320	0.254 739

As colunas da tabela devem ser interpretadas da seguinte forma. *Tema* identifica a variável temática avaliada. *ON vs Base* representa a diferença entre o engajamento previsto quando o tema está ativado e o engajamento previsto para o vetor médio das características observadas nos dados da TV no período noturno, utilizado como referência contrafactual, indicando o ganho ou a perda relativa associada à presença do tema. *ON vs OFF* expressa a diferença entre o engajamento previsto com o tema ativado e o valor previsto com o tema desativado, mantendo as demais variáveis constantes, correspondendo ao efeito isolado da variável temática no modelo. A coluna *Tema ON* apresenta o valor absoluto de engajamento previsto quando o tema está ativo, enquanto *Base Noite* corresponde ao valor de referência do engajamento previsto para o perfil

médio do período noturno, utilizado como base de comparação. Essa interpretação é válida tanto para o engajamento ativo quanto para o engajamento passivo.

A.2 Análise Contrafactual de Temas — Engajamento Passivo (Período Noturno, TV 2024)

Tabela 12 – Efeito relativo previsto pelo modelo para cada tema no período noturno — engajamento passivo (TV 2024).

Tema	ON vs Base	ON vs OFF	Tema ON	Base Noite
Tema_Religiao	0.723 897	0.723 897	2.120 682	1.396 785
Tema_Misterio	0.228 578	0.228 578	1.625 363	1.396 785
Tema_Comportamento_Vida	0.090 204	0.090 204	1.486 989	1.396 785
Tema_Info	0.076 923	0.102 193	1.473 708	1.396 785
Tema_Esporte	0.019 002	0.019 690	1.415 787	1.396 785
Tema_Ficcao	-0.001 418	-0.002 942	1.395 367	1.396 785
Tema_Educacao_Ciencia	-0.021 346	-0.021 346	1.375 439	1.396 785
Tema_Entretenimento	-0.076 376	-0.103 546	1.320 409	1.396 785
Tema_Tecnologia_Games	-0.129 426	-0.129 426	1.267 359	1.396 785
Tema_Cultura_Sociedade	-0.147 804	-0.147 804	1.248 981	1.396 785