



**UFOP**

Universidade Federal  
de Ouro Preto

**Universidade Federal de Ouro Preto  
Instituto de Ciências Exatas e Aplicadas  
Departamento de Computação e Sistemas**

# **Media Tracker: Sistema Inteligente de Acompanhamento de Séries e Filmes com busca Potencializada por LLMs**

**Luisa Laura Linhares**

## **TRABALHO DE CONCLUSÃO DE CURSO**

**ORIENTAÇÃO:**  
Alexandre Magno de Sousa

**Agosto, 2025  
João Monlevade–MG**

**Luisa Laura Linhares**

**Media Tracker: Sistema Inteligente de Acompanhamento de Séries e Filmes com busca Potencializada por LLMs**

Orientador: Alexandre Magno de Sousa

Monografia apresentada ao curso de Engenharia de Computação do Instituto de Ciências Exatas e Aplicadas, da Universidade Federal de Ouro Preto, como requisito parcial para aprovação na Disciplina “Trabalho de Conclusão de Curso II”.

**Universidade Federal de Ouro Preto**

**João Monlevade**

**Agosto de 2025**

## SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

L755m Linhares, Luisa Laura.

Media Tracker [manuscrito]: sistema inteligente de acompanhamento de séries e filmes com busca potencializada por LLMs. / Luisa Laura Linhares. - 2025.

120 f.: il.: color., tab..

Orientador: Prof. Dr. Alexandre Magno Sousa.

Monografia (Bacharelado). Universidade Federal de Ouro Preto. Instituto de Ciências Exatas e Aplicadas. Graduação em Engenharia de Computação .

1. Aplicações Web - desenvolvimento. 2. Catálogos de filmes - Mineração de dados (Computação). 3. Inteligência artificial. 4. Mídia digital. 5. Processamento de linguagem natural (Computação). 6. Software de aplicação - Desenvolvimento. 7. Tecnologia streaming (Telecomunicação). I. Sousa, Alexandre Magno. II. Universidade Federal de Ouro Preto. III. Título.

CDU 004.41:004.8

Bibliotecário(a) Responsável: Flavia Reis - CRB6-2431



## FOLHA DE APROVAÇÃO

**Luisa Laura Linhares**

### **Media Tracker: Sistema Inteligente de Acompanhamento de Séries e Filmes com busca Potencializada por LLMs**

Monografia apresentada ao Curso de Engenharia de Computação da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de bacharel em engenharia de computação.

Aprovada em 4 de setembro de 2025

#### Membros da banca

Prof. Dr. Alexandre Magno de Sousa - Orientador (Universidade Federal de Ouro Preto)  
Prof. Dr. Eduardo da Silva Ribeiro (Universidade Federal de Ouro Preto)  
Prof. Dr. Fernando Bernardes de Oliveira (Universidade Federal de Ouro Preto)

Professor Alexandre Magno de Sousa, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 14/09/2025



Documento assinado eletronicamente por **Alexandre Magno de Sousa, PROFESSOR DE MAGISTERIO SUPERIOR**, em 14/09/2025, às 17:00, conforme horário oficial de Brasília, 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 [http://sei.ufop.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0977712** e o código CRC **9B3BC727**.

*Este trabalho é dedicado à minha querida mãe, pelo apoio incansável, pelos sacrifícios silenciosos e por nunca deixar de acreditar nos meus sonhos. Este trabalho é fruto do seu amor e dedicação.*

# Agradecimentos

Gostaria de expressar meus sinceros agradecimentos, em primeiro lugar, a Deus por ter me sustentado ao longo dessa caminhada, por ter me proporcionado tudo o que foi me necessário e por ter me dado condições de cumprir com minhas obrigações.

A meus pais Maria Aparecida Linhares e José Vicente, e minhas irmãs Joelma Linhares e Júnia Linhares, pelo amor incondicional, carinho, paciência e por todo o apoio durante toda a minha vida.

A minha madrinha Maria José que sempre foi uma segunda mãe para mim e me apoiou durante toda a minha vida.

A todos os meus amigos que de alguma forma estiveram comigo e contribuíram ao longo dessa minha jornada, em especial ao Arthur Miranda, que durante maior parte da minha graduação esteve comigo e me apoiou a todo momento.

Aos professores do Departamento de Engenharia da Computação da UFOP, em especial ao Professor Alexandre Magno de Sousa, por todas recomendações e atenção dedicada durante todo trabalho.

*“Consagre ao Senhor tudo o que você faz, e os seus planos serão bem-sucedidos.”*

Provérbios 16.3

# Resumo

O crescimento acelerado do mercado de streaming trouxe novas possibilidades de consumo de conteúdo audiovisual, mas também desafios relacionados à organização e à descoberta de filmes e séries diante de catálogos cada vez mais extensos. Nesse contexto, este trabalho apresenta o desenvolvimento do *Media Tracker*, uma plataforma web inteligente voltada ao gerenciamento de mídias assistidas e à realização de buscas avançadas com apoio de Inteligência Artificial. O objetivo principal é unificar, em um único ambiente, funcionalidades que permitam ao usuário organizar seu histórico de visualização, registrar progresso e identificar novos conteúdos por meio de descrições textuais ou imagens, utilizando técnicas de processamento de linguagem natural e reconhecimento visual suportadas por *Large Language Models* (LLM). A metodologia envolveu a definição de requisitos funcionais e não funcionais, modelagem do sistema com diagramas *Unified Modeling Language* (UML), prototipação das interfaces, implementação de um *backend* em Spring Boot com autenticação e de um frontend em Angular, além da integração com a API TMDb e módulos de IA para busca multimodal. O sistema resultante oferece uma interface responsiva e intuitiva, permitindo o gerenciamento de coleção pessoal, o acompanhamento de progresso e a identificação de obras a partir de descrições ou capturas de tela. Os testes realizados com usuários evidenciaram boa aceitação, destacando-se a utilidade da busca por imagem e a clareza da organização das informações, embora tenham sido apontadas oportunidades de melhoria em aspectos de performance e ordenação de resultados. Como conclusão, este trabalho demonstrou a viabilidade técnica da integração entre LLMs e APIs externas como estratégia para ampliar e enriquecer a experiência de consumo de mídia digital. Essa integração possibilitou funcionalidades de busca multimodal, permitindo a identificação de filmes e séries tanto por descrições textuais quanto por imagens, além da centralização do gerenciamento de coleção e progresso em uma única plataforma.

**Palavras-chaves** Inteligência Artificial; *Large Language Models*; Busca Multimodal; Media Tracker; Streaming.

# Abstract

The accelerated growth of the streaming market has brought new possibilities for audiovisual content consumption, but also challenges related to the organization and discovery of movies and series within increasingly extensive catalogs. In this context, this work presents the development of Media Tracker, an intelligent web platform designed for managing watched media and performing advanced searches supported by Artificial Intelligence. The main objective is to unify, in a single environment, functionalities that allow users to organize their viewing history, track progress, and identify new content through textual descriptions or images, using natural language processing and visual recognition techniques supported by Large Language Models LLMs. The methodology involved defining functional and non-functional requirements, modeling the system with Unified Modeling Language (UML) diagrams, prototyping interfaces, implementing a backend in Spring Boot with JWT authentication and a frontend in Angular, as well as integrating the TMDb API and AI modules for multimodal search. The resulting system offers a responsive and intuitive interface, enabling personal collection management, progress tracking, and identification of works based on descriptions or screenshots. User testing showed good acceptance, highlighting the usefulness of image-based search and the clarity of information organization, although opportunities for improvement were identified in performance and result ordering. In conclusion, this work demonstrated the technical feasibility of integrating LLMs and external APIs as a strategy to broaden and enrich the digital media consumption experience. This integration enabled multimodal search functionalities, allowing the identification of movies and series both through textual descriptions and images, in addition to the centralized management of collections and progress in a single platform.

**Key-words:** Artificial Intelligence; Large Language Models; Multimodal Search; Media Tracker; Streaming.

# Lista de ilustrações

Figura 1 – Interface da plataforma Trakt. . . . .	34
Figura 2 – Interface da plataforma Letterboxd. . . . .	35
Figura 3 – Interface da plataforma do IMDB. . . . .	36
Figura 4 – Interface da plataforma What is my movie. . . . .	37
Figura 5 – Interface da plataforma Trace moe. . . . .	38
Figura 6 – Diagrama de casos de uso do sistema Media Tracker. . . . .	45
Figura 7 – Diagrama de atividades macro: visão integrada dos fluxos do sistema. . . . .	47
Figura 8 – Diagrama de atividades para o fluxo de login. . . . .	48
Figura 9 – Diagrama de atividades para adicionar itens ao catálogo pessoal. . . . .	49
Figura 10 – Diagrama de atividades para busca de mídia. . . . .	50
Figura 11 – Diagrama de atividades para registro de progresso. . . . .	51
Figura 12 – Diagrama de atividades para visualização da coleção. . . . .	52
Figura 13 – Diagrama de atividades para visualização de detalhes de mídia. . . . .	52
Figura 14 – Diagrama Entidade-Relacionamento do sistema Media Tracker. . . . .	53
Figura 15 – Tela de login do protótipo Media Tracker. . . . .	56
Figura 16 – Tela inicial e funcionalidade de busca. . . . .	58
Figura 17 – Tela de progresso de visualização. . . . .	60
Figura 18 – Arquitetura modular do sistema Media Tracker. . . . .	61
Figura 19 – Prompt de análise de intenção de busca. . . . .	63
Figura 20 – Diagrama de sequência do fluxo de busca inteligente. . . . .	64
Figura 21 – Diagrama de sequência do fluxo de busca por imagem. . . . .	65
Figura 22 – Diagrama de pacotes do backend do sistema Media Tracker . . . . .	68
Figura 23 – Tela de Login do sistema Media Tracker. . . . .	79
Figura 24 – Tela de início do sistema Media Tracker. . . . .	80
Figura 25 – Tela de início do sistema Media Tracker. . . . .	81
Figura 26 – Tela de Busca com filtros avançados no sistema Media Tracker. . . . .	82
Figura 27 – Interação com obras na tela de busca. . . . .	84
Figura 28 – Página de detalhes da obra selecionada. . . . .	84
Figura 29 – Tela de coleção do sistema Media Tracker. . . . .	85
Figura 30 – Tela de progresso do sistema Media Tracker. . . . .	87
Figura 31 – Modal de atualização de progresso para filmes no sistema Media Tracker. . . . .	88
Figura 32 – Modal de Atualização de Progresso para séries no sistema Media Tracker. . . . .	90
Figura 34 – Tela de coleção com visão em linha do sistema Media Tracker. . . . .	107
Figura 33 – Tela de busca com visão em linha do sistema Media Tracker. . . . .	108
Figura 35 – Tela de progresso com itens em andamento do sistema Media Tracker. . . . .	108

Figura 36 – Página inicial do formulário com instruções de teste e apresentação da pesquisa. . . . .	111
Figura 37 – Seção “Perfil do Usuário” – questões sobre idade, frequência de uso, experiência prévia e familiaridade tecnológica. . . . .	112
Figura 38 – Seções “Primeira Impressão” e início de “Funcionalidades Específicas” – avaliação de design, navegação e busca por texto. . . . .	113
Figura 39 – Continuação da seção “Funcionalidades Específicas” – avaliação de busca por imagem, coleção pessoal e controle de progresso. . . . .	114
Figura 40 – Seção “Usabilidade” – avaliação de velocidade, organização visual e utilidade dos filtros. . . . .	115
Figura 41 – Seção “Experiência Geral” – funcionalidades mais úteis, pontos de melhoria e intenção de recomendação. . . . .	116
Figura 42 – Avaliação geral em escala numérica e início da seção “Feedback Aberto” com questões dissertativas. . . . .	117
Figura 43 – Finalização do formulário com campo para comentários adicionais e agradecimento aos participantes. . . . .	118

# Lista de tabelas

Tabela 1 – Comparação dos Principais Modelos LLM . . . . .	27
Tabela 2 – Comparação de trabalhos relacionados . . . . .	40
Tabela 3 – Requisitos funcionais da plataforma . . . . .	43
Tabela 4 – Requisitos não funcionais da plataforma . . . . .	44
Tabela 5 – Tecnologias utilizadas no projeto - Versões implementadas. . . . .	75

# Lista de abreviaturas e siglas

API	<i>Interface de Programação de Aplicações</i>
API REST	<i>Representational State Transfer</i>
BPE	<i>Byte-Pair Encoding</i>
CoT	<i>Chain of Thought</i>
CSS	<i>Cascading Style Sheets</i>
ER	<i>Entidade-Relacionamento</i>
HTML	<i>HyperText Markup Language</i>
HTTP	<i>Hypertext Transfer Protocol</i>
IA	<i>Inteligência Artificial</i>
IMDb	<i>Internet Movie Database</i>
JPEG	<i>Joint Photographic Experts Group</i>
JSON	<i>JavaScript Object Notation</i>
JWT	<i>JSON Web Token</i>
LLM	<i>Large Language Model</i>
MCP	<i>Model Context Protocol</i>
MMLU	<i>Massive Multitask Language Understanding</i>
MVC	<i>Model-View-Controller</i>
PNG	<i>Portable Network Graphics</i>
RF	<i>Requisito Funcional</i>
RLHF	<i>Reinforcement Learning from Human Feedback</i>
RNF	<i>Requisito Não Funcional</i>
SOAP	<i>Simple Object Access Protocol</i>
SQL	<i>Structured Query Language</i>
TMDb	<i>The Movie Database</i>
UI	<i>User Interface</i>
UML	<i>Unified Modeling Language</i>
URL	<i>Uniform Resource Locator</i>
UX	<i>User Experience</i>
WEB	<i>World Wide Web</i>

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>16</b>
1.1	Motivação e Justificativa	17
1.2	Definição do Problema	18
1.3	Objetivos Gerais e Específicos	18
1.4	Resultados e Contribuições	19
1.5	Estrutura e Organização da Monografia	20
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>21</b>
2.1	<b>Fundamentos de Large Language Models (LLMs)</b>	<b>21</b>
2.1.1	Arquitetura e Funcionamento de LLMs	21
2.1.2	Técnicas de Prompt Engineering	22
2.1.3	Principais Modelos Disponíveis para Uso em Aplicações	23
2.1.4	Comparativo entre LLMs disponíveis	24
2.1.5	Integração de APIs de LLMs com Serviços de Aplicações	28
2.1.6	Model Context Protocol (MCP)	29
2.2	<b>Trabalhos Relacionados e Aplicações Semelhantes</b>	<b>29</b>
2.3	<b>Considerações Finais</b>	<b>41</b>
<b>3</b>	<b>MODELAGEM E DESENVOLVIMENTO</b>	<b>42</b>
3.1	<b>Definição dos Requisitos</b>	<b>42</b>
3.2	<b>Modelagem dos Casos de Uso</b>	<b>44</b>
3.3	<b>Diagrama de Atividades</b>	<b>45</b>
3.3.1	Visão Integrada dos Fluxos	46
3.3.2	Fluxo de Login	47
3.3.3	Adicionar Item ao Catálogo Pessoal	48
3.3.4	Busca de Mídia	49
3.3.5	Registro de Progresso	50
3.3.6	Visualizar Coleção	51
3.3.7	Visualizar Detalhes de Mídia	52
3.4	<b>Modelo Entidade-Relacionamento</b>	<b>53</b>
3.4.1	Principais Entidades	54
3.5	<b>Protótipo do Sistema</b>	<b>54</b>
3.6	<b>Arquitetura Geral do Sistema</b>	<b>59</b>
3.6.1	Fluxo de Busca Inteligente	61
3.6.2	Prompts e Engenharia de Prompt	62
3.6.3	Diagrama de Sequência do Sistema	63

3.6.4	Diagrama de Sequência - Busca por Imagem . . . . .	64
<b>3.7</b>	<b>Desenvolvimento do Backend . . . . .</b>	<b>65</b>
3.7.1	Diagrama de Pacotes . . . . .	67
<b>3.8</b>	<b>Desenvolvimento do Frontend . . . . .</b>	<b>68</b>
<b>3.9</b>	<b>API de Busca Inteligente Assistida por IA . . . . .</b>	<b>69</b>
<b>3.10</b>	<b>Módulo Servidor Model Context Protocol . . . . .</b>	<b>71</b>
<b>3.11</b>	<b>Banco de Dados e Migrações . . . . .</b>	<b>72</b>
<b>3.12</b>	<b>DevOps e Infraestrutura . . . . .</b>	<b>73</b>
<b>3.13</b>	<b>Tecnologias Utilizadas . . . . .</b>	<b>74</b>
<b>3.14</b>	<b>Considerações finais . . . . .</b>	<b>75</b>
<b>4</b>	<b>RESULTADOS . . . . .</b>	<b>78</b>
<b>4.1</b>	<b>Tela de Login . . . . .</b>	<b>78</b>
<b>4.2</b>	<b>Tela de Início e Sessões de Destaque . . . . .</b>	<b>79</b>
<b>4.3</b>	<b>Tela de Busca . . . . .</b>	<b>82</b>
4.3.1	Filtros de Pesquisa . . . . .	82
4.3.2	Exibição dos Resultados . . . . .	83
4.3.3	Interação com Obras . . . . .	83
<b>4.4</b>	<b>Tela de Coleção . . . . .</b>	<b>84</b>
<b>4.5</b>	<b>Tela de Progresso . . . . .</b>	<b>86</b>
<b>4.6</b>	<b>Análise da Pesquisa com Usuários de Teste . . . . .</b>	<b>90</b>
4.6.1	Perfil dos Usuários Participantes . . . . .	91
4.6.2	Avaliação da Interface e Usabilidade . . . . .	91
4.6.3	Análise das Funcionalidades Específicas . . . . .	92
4.6.4	Experiência Geral e Impacto . . . . .	93
<b>4.7</b>	<b>Considerações Finais . . . . .</b>	<b>94</b>
<b>5</b>	<b>CONCLUSÃO . . . . .</b>	<b>95</b>
<b>5.1</b>	<b>Resultados e Contribuições . . . . .</b>	<b>96</b>
<b>5.2</b>	<b>Limitações do Trabalho . . . . .</b>	<b>97</b>
<b>5.3</b>	<b>Trabalhos Futuros . . . . .</b>	<b>99</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>100</b>
	<b>APÊNDICES . . . . .</b>	<b>106</b>
	<b>APÊNDICE A – MATERIAIS ELABORADOS PELO AUTOR . . . . .</b>	<b>107</b>
<b>A.1</b>	<b>Visão em Linha . . . . .</b>	<b>107</b>
<b>A.2</b>	<b>Tela de Progresso . . . . .</b>	<b>107</b>

	<b>APÊNDICE B – AVALIAÇÃO DA PLATAFORMA MEDIA TRAC- KER – FORMULÁRIO GOOGLE . . . . .</b>	<b>109</b>
<b>B.1</b>	<b>Estrutura do Questionário . . . . .</b>	<b>109</b>
<b>B.2</b>	<b>Apresentação do Formulário . . . . .</b>	<b>110</b>
<b>B.3</b>	<b>Considerações sobre o Questionário . . . . .</b>	<b>119</b>

# 1 Introdução

No cenário atual de consumo de mídia digital, o mercado de streaming aumentou consideravelmente em popularidade nos últimos anos, oferecendo aos consumidores uma ampla gama de opções de entretenimento, desde filmes e séries até músicas e jogos. A multiplicidade de serviços como Netflix, Amazon Prime, Disney+, HBO Max e Globoplay tem transformado a forma como os usuários consomem conteúdo audiovisual. O mercado global de streaming está projetado para atingir valores entre US\$ 1,6 trilhão e US\$ 1,9 trilhão até 2029–2030 segundo estimativas da Grand View Research ([RESEARCH, 2022](#)) e Fortune Business Insights ([INSIGHTS, 2024](#)). Com mais de 1,1 bilhão de assinantes de serviços de streaming em todo o mundo em 2023, a Netflix é a empresa líder com aproximadamente 260 milhões de usuários ([STATISTA, 2024](#)). Essa abundância de conteúdo, embora amplie significativamente as opções de entretenimento, também traz desafios consideráveis para os usuários, por exemplo, como gerenciar de forma eficiente o histórico de visualização e como identificar um filme ou série a partir de uma cena ou descrição textual.

Cada serviço de streaming possui características distintas que atraem diferentes públicos. A Netflix, pioneira no mercado, destaca-se pela produção de conteúdo original e algoritmos de recomendação personalizados ([NETFLIX, 2023](#)). O Amazon Prime Video diferencia-se pela integração com outros serviços Amazon e conteúdo esportivo ao vivo. Já o Disney+ concentra sua estratégia em franquias populares como Marvel e Star Wars ([The Walt Disney Company, 2023](#)), enquanto o HBO Max destaca-se por suas produções premiadas em importantes premiações como o Emmy ([WAYNE, 2023](#)).

Apesar dos diferenciais, todos enfrentam o desafio comum de ajudar seus usuários a descobrirem conteúdo relevante em meio a extensos catálogos. Segundo a Nielsen, 46% dos consumidores relatam dificuldade em encontrar conteúdo desejado devido ao excesso de opções disponíveis ([NIELSEN, 2022a](#)).

Os serviços de streaming e plataformas especializadas em descoberta de conteúdo oferecem diferentes abordagens para facilitar o acesso ao vasto catálogo de filmes e séries disponíveis. Enquanto alguns serviços permitem buscas baseadas em títulos e categorias, outras ferramentas utilizam descrições textuais e reconhecimento de imagens para ajudar os usuários a encontrar conteúdos específicos. Por exemplo, o [Whatismymovie.com \(WHATISMYMOVIE, 2024\)](#) permite buscas por descrições narrativas, enquanto o [Trace.moe \(TRACE.MOE, 2024a\)](#) identifica animes a partir de *screenshots*. Essas soluções representam avanços na interação entre usuário e sistema, mas ainda apresentam limitações que restringem sua aplicabilidade em um contexto mais amplo. No âmbito de gerenciamento e avaliação, plataformas como Letterboxd e TV Time permitem que usuários cataloguem

e avaliem filmes e séries, criando um sistema de recomendação social baseado em avaliações da comunidade (LETTERBOXD, 2023). Contudo, estas plataformas ainda operam com limitações significativas: ou são muito específicas (como o Trace.moe para animes), ou oferecem apenas funcionalidades parciais (como busca textual sem reconhecimento visual), ou carecem de integração entre gerenciamento de conteúdo e recursos avançados de identificação.

É justamente nessas limitações que novas tecnologias de Inteligência Artificial (IA) podem oferecer novas soluções. A evolução da IA, particularmente no campo da visão computacional e dos Modelos de Linguagem de Larga Escala, do inglês, *Large Language Models* (LLM), abre novos caminhos para enriquecer a experiência do usuário (YIN et al., 2024) Tecnologias como o reconhecimento de imagens e Processamento de Linguagem Natural possibilitam interações mais naturais e intuitivas com sistemas de informação, permitindo que usuários identifiquem conteúdos a partir de imagens de cenas ou descrições textuais imprecisas, o que supera as limitações das plataformas atuais (YIN et al., 2024)

Nesse contexto, este trabalho propõe o desenvolvimento de uma plataforma Web integrada que possibilite aos usuários gerenciar seu histórico de mídia assistida e utilizar funcionalidades avançadas como a busca visual por meio de inteligência artificial. A plataforma utilizará tecnologias modernas para o desenvolvimento Web e integrará APIs como TMDb para enriquecimento de dados e uma API para funcionalidades de inteligência artificial baseada em reconhecimento de imagens e textual.

## 1.1 Motivação e Justificativa

A motivação para este trabalho surge da crescente complexidade no consumo de conteúdo audiovisual digital, impulsionada pelo expressivo crescimento do mercado global de streaming. Com projeções de mercado promissoras para os próximos anos, torna-se evidente a necessidade de soluções inovadoras para gerenciar este vasto universo de conteúdo. A justificativa para o desenvolvimento deste projeto se baseia em três pilares principais:

1. **Necessidade de Gerenciamento Eficiente:** com o crescimento exponencial de conteúdo disponível, os usuários enfrentam dificuldades significativas para gerenciar seu histórico de visualização e manter um registro organizado de suas preferências;
2. **Limitações das Soluções Atuais:** embora existam ferramentas no mercado, elas apresentam limitações em termos de funcionalidades avançadas de busca e personalização. A ausência de uma solução que integre gerenciamento de conteúdo com tecnologias modernas de IA e busca visual representa uma lacuna importante no mercado;

- Potencial de Inovação Tecnológica:** a integração de tecnologias emergentes como reconhecimento de imagens e Processamento de Linguagem Natural oferece oportunidades únicas para melhorar a experiência do usuário. A combinação dessas tecnologias com uma interface intuitiva e responsiva pode revolucionar a forma como os usuários interagem com seu conteúdo audiovisual.

Este projeto se justifica ainda pela crescente demanda por soluções que simplifiquem a descoberta e o gerenciamento de conteúdo em um cenário onde múltiplas plataformas de streaming competem pela atenção do usuário. A proposta de desenvolver uma plataforma que unifique estas necessidades em uma única solução representa uma contribuição significativa para a área de gerenciamento de mídia digital.

## 1.2 Definição do Problema

O crescente volume de conteúdo audiovisual disponível em plataformas de *streaming* e catálogos digitais apresenta um desafio para os usuários no que tange organizar seu conteúdo assistido (MEZA; D'URSO, 2024). A abundância de opções, embora positiva por ampliar o acesso ao entretenimento, dificulta a organização do conteúdo já assistido, a descoberta de novos títulos relevantes e o acompanhamento do progresso de visualização (EVENS; HENDERICKX; CONRADIE, 2024). Usuários frequentemente se deparam com a dificuldade de gerenciar suas listas, lembrar em qual episódio parou ou encontrar algo novo que corresponda às suas preferências, resultando em experiências frustrantes e perda de tempo com buscas manuais e decisões incertas (NIELSEN, 2022b).

A falta de funcionalidades inovadoras, como a busca visual baseada em imagens de cenas ou pôsteres, limita a experiência de descoberta e dificulta o acesso a títulos que poderiam ser do interesse do usuário. Além disso, a gestão manual de informações e a falta de integração entre diferentes fontes de dados (e.g. catálogos online ou histórico pessoal) criam barreiras para uma experiência centralizada e personalizada.

A combinação de grande volume de conteúdo, dificuldade de gerenciamento e limitações das ferramentas atuais evidencia a necessidade de soluções que facilitem a organização, a descoberta e o acompanhamento do conteúdo audiovisual, o que pode proporcionar uma experiência mais eficiente e prazerosa para o usuário.

## 1.3 Objetivos Gerais e Específicos

Diante da crescente complexidade do consumo de conteúdo audiovisual digital, este trabalho tem como objetivo principal o desenvolvimento de uma plataforma Web inteligente denominada *Media Tracker*, que será destinada ao gerenciamento de filmes e séries assistidos. A proposta visa unificar, em um único ambiente, funcionalidades

que auxiliem o usuário tanto na organização de seu histórico de visualização quanto na descoberta de novos conteúdos, com destaque para o uso de inteligência artificial aplicada à busca textual e visual.

A plataforma será composta por um módulo de gerenciamento de coleção pessoal e um sistema de busca avançada que permitirá a identificação de filmes e séries por meio de descrições textuais ou imagens (como pôsteres ou capturas de tela), utilizando LLMs e APIs especializadas. Além disso, a ferramenta busca proporcionar uma experiência de uso fluida e intuitiva, com design responsivo e funcionalidades integradas.

Para viabilizar o alcance do objetivo geral, os seguintes objetivos específicos são definidos:

- Desenvolver o módulo de gerenciamento de coleção pessoal, permitindo ao usuário cadastrar, organizar e acompanhar seus filmes e séries;
- Implementar o sistema de busca multimodal, possibilitando a identificação de mídias a partir de descrições textuais e imagens, com apoio de LLMs e APIs especializadas;
- Criar o módulo de acompanhamento de progresso, registrando o avanço do usuário em cada obra consumida;
- Disponibilizar a plataforma em ambiente público para avaliação;
- Analisar a experiência dos usuários, coletando feedback sobre usabilidade, desempenho e relevância dos resultados apresentados.

## 1.4 Resultados e Contribuições

O desenvolvimento da plataforma Web proposta resultou em um sistema funcional que integra gerenciamento de filmes e séries com recursos de busca textual e visual assistidos por Inteligência Artificial. Entre os principais resultados obtidos, destacam-se:

- Implementação de um *frontend* responsivo, desenvolvido em *Angular*, que visa proporcionar uma navegação intuitiva e organizada;
- Desenvolvimento de um *backend* robusto com *Spring Boot*, garantindo segurança via JWT;
- Criação de funcionalidades de busca por imagem e texto utilizando LLMs, permitindo a identificação de obras a partir de descrições ou capturas de tela;
- Disponibilização de recursos para controle de progresso e gerenciamento de coleção pessoal, aumentando a organização do histórico de visualização do usuário.

A pesquisa com usuários evidencia uma boa aceitação da plataforma, além disso, ressalta como pontos positivos a facilidade de uso, a organização das informações e a utilidade da busca por imagem. Também foram identificadas oportunidades de melhoria, como otimização da performance em consultas complexas, aprimoramento na ordenação dos resultados visuais e integração com serviços de streaming para sincronização automática de progresso.

As principais contribuições deste trabalho são:

1. Implementação de uma solução unificada que combina gerenciamento de mídia e busca multimodal assistida por IA;
2. Exploração prática da integração entre APIs especializadas e LLMs, enriquecendo a experiência do usuário ao permitir buscas em linguagem natural ou por imagens, com resultados mais relevantes, personalizados e acessíveis;
3. Demonstração da viabilidade técnica de aplicar reconhecimento visual e Processamento de Linguagem Natural em um sistema de consumo de mídia digital;
4. Fornecimento de um protótipo funcional que pode servir como base para pesquisas e aplicações futuras na área.

Esses resultados e contribuições reforçam a relevância da solução proposta e seu potencial de adoção, tanto em contextos acadêmicos quanto no mercado de consumo de mídia digital.

## 1.5 Estrutura e Organização da Monografia

Esta trabalho está estruturados conforme descrito a seguir. O próximo capítulo aborda a fundamentação teórica necessária para o desenvolvimento do trabalho, apresentando conceitos sobre LLMs e aspectos de integração com APIs. O capítulo também apresenta uma análise de trabalhos relacionados e aplicações semelhantes relevantes para o projeto. Por sua vez, o Capítulo 3 detalha a modelagem do sistema, apresentando os diagramas UML utilizados para o desenvolvimento do projeto, incluindo casos de uso, diagramas de sequência e diagramas de atividades. São também apresentados os protótipos desenvolvidos. O Capítulo 4 apresenta os resultados obtidos com o desenvolvimento do sistema, incluindo as funcionalidades implementadas, testes realizados. O Capítulo 5 traz as conclusões deste projeto e os trabalhos futuros.

## 2 Fundamentação Teórica

Este capítulo apresenta os fundamentos teóricos importantes para o desenvolvimento da plataforma Web proposta, abordando conceitos relacionados a LLMs, técnicas de processamento de linguagem natural e integração de APIs. A compreensão destes elementos é importante para o desenvolvimento de uma solução que combine gerenciamento de conteúdo audiovisual com recursos avançados de inteligência artificial. São explorados desde os princípios básicos dos LLMs até suas aplicações práticas para a busca de conteúdo.

O capítulo está organizado em sete seções principais: inicialmente, são apresentados os fundamentos dos LLMs, seguidos por uma discussão sobre técnicas de engenharia de *prompt*. Na sequência, é realizado um comparativo entre diferentes LLMs disponíveis no mercado, seguido pela apresentação de técnicas para sua utilização. Também são abordados aspectos relacionados à integração de APIs de LLMs com serviços de aplicações. Por fim, os trabalhos relacionados com a proposta deste projeto são apresentados.

### 2.1 Fundamentos de Large Language Models (LLMs)

Esta seção aborda os principais fundamentos teóricos relacionados aos LLMs, com ênfase em sua arquitetura, funcionamento e técnicas de utilização. Além disso, são discutidos modelos disponíveis no mercado e estratégias de integração em diferentes contextos de aplicação. A compreensão desses aspectos é essencial para sustentar o desenvolvimento do sistema proposto, visto que os LLMs representam a base tecnológica para a implementação de mecanismos avançados de busca textual e por imagem.

#### 2.1.1 Arquitetura e Funcionamento de LLMs

Os LLMs representam um avanço no campo da Inteligência Artificial, especialmente no processamento de linguagem natural. Baseados na arquitetura transformer, introduzida em 2017 no artigo “Attention Is All You Need” (VASWANI et al., 2017), estes modelos são fundamentais para sistemas de recomendação e assistentes virtuais modernos.

A arquitetura dos LLMs é composta por elementos como tokenização, que converte texto em unidades processáveis utilizando algoritmos como Byte-Pair Encoding (BPE) (SENNRICH; HADDOW; BIRCH, 2015), camadas de *embedding* para representação vetorial, e blocos *transformer* com mecanismos de Multi-Head Attention (VASWANI et al., 2017). Estes componentes permitem que o modelo processe e compreenda contextos complexos, fundamental para gerar recomendações personalizadas e interagir naturalmente com usuários.

O funcionamento destes LLMs ocorre em duas fases principais: o pré-treinamento em grandes volumes de dados textuais para predição do próximo token e o ajuste fino para tarefas específicas. O ajuste fino utiliza técnicas como Reinforcement Learning from Human Feedback (RLHF) (OUYANG et al., 2022), que emprega um processo de três etapas (i.e., *supervised fine-tuning*, treinamento de modelo de recompensa e otimização de política) para melhorar o desempenho e alinhar o modelo com preferências humanas.

Recentes avanços em LLMs incluem capacidades multimodais, permitindo o processamento conjunto de texto e imagens, como demonstrado em modelos como Flamingo (ALAYRAC et al., 2022) e PaLM-E (DRIESS et al., 2023). Esta capacidade de compreensão multimodal permite que sistemas computacionais extraiam informações tanto de conteúdo textual quanto visual simultaneamente, superando limitações de abordagens que processam essas modalidades separadamente. A integração dessas modalidades possibilita análises mais ricas e contextualizadas, onde elementos visuais complementam informações textuais para uma compreensão mais abrangente do conteúdo.

### 2.1.2 Técnicas de Prompt Engineering

De acordo com Brown et al. (2020), no artigo seminal sobre o GPT-3, a formulação de *prompts* é importante para extrair o desempenho máximo de LLMs. Os autores demonstram que *prompts* bem estruturados podem melhorar significativamente a capacidade do modelo em generalizar para tarefas específicas sem necessidade de treinamento adicional. Nesse sentido, Liu et al. (2023) reforçam que a engenharia de *prompt* representa uma abordagem de baixo custo para adaptar LLMs a diferentes tarefas, evitando o dispendioso ajuste fino (*fine-tuning*).

Pesquisas como a de Wei et al. (2022) destacam a importância de *prompts* que solicitam raciocínio passo a passo. Essa técnica, conhecida como *Chain-of-Thought* (CoT), incentiva o modelo a decompor problemas complexos em etapas intermediárias, o que resulta em maior acurácia em tarefas de raciocínio lógico e matemático. Por exemplo, em vez de solicitar diretamente “Qual é o resultado de  $15 \times 23$ ?”, um *prompt* CoT poderia ser formulado da seguinte forma: “Para calcular  $15 \times 23$ , divida o problema em etapas: primeiro, multiplique 15 por 20, depois 15 por 3, e some os resultados. Mostre cada passo.”

Radford et al. (2019) e Brown et al. (2020) exploram o *zero-shot* e *few-shot learning*, nos quais o *prompt* fornece contexto sem ou com poucos exemplos. No *zero-shot*, o *prompt* descreve diretamente a tarefa, por exemplo: “Traduza o seguinte texto do inglês para o português: [texto].” Já no *few-shot*, alguns exemplos são incluídos para guiar o modelo, como demonstrado no trabalho de Brown et al. (2020): “Exemplo 1: ‘Hello’  $\rightarrow$  ‘Olá’; Exemplo 2: ‘World’  $\rightarrow$  ‘Mundo’; Traduza: ‘Friend’.” Estudos mostram que o *few-shot* tende a melhorar o desempenho em tarefas específicas, embora exija *prompts* calibrados para evitar ambiguidades.

Conforme demonstrado por [Tan et al. \(2024\)](#), a atribuição de papéis ou personas específicas ao modelo de linguagem pode influenciar significativamente suas capacidades de raciocínio. Os autores evidenciam que *prompts* como “*Você é um professor de história explicando para alunos do ensino médio*” podem melhorar a clareza e adequação das respostas para tarefas que exigem tom ou nível de expertise específicos. No entanto, [Kim, Yang e Jung \(2024\)](#) alertam que a seleção adequada da persona é crucial, pois o desempenho dos modelos é extremamente sensível à formulação específica dos *prompts* de papel.

[Reynolds e McDonell \(2021\)](#) sugerem o uso de *prompts* iterativos como técnica de refinamento de resultados. Esse processo envolve ajustar o *prompt* com base nas respostas iniciais do modelo, incorporando *feedback* implícito ou explícito. Por exemplo, se a resposta inicial for genérica, o *prompt* pode ser reformulado para incluir restrições, como: “*Forneça uma explicação concisa em no máximo 100 palavras.*”

Conforme [Lester, Al-Rfou e Constant \(2021\)](#), *prompts* com instruções claras e restrições explícitas, como, por exemplo, “*Responda em tópicos*” ou “*Utilize apenas linguagem formal*” reduzem ambiguidades e alinham as respostas às expectativas do usuário. [Kojima et al. \(2022\)](#) corroboram essa ideia ao demonstrarem que palavras-chave como “*explique*”, “*detalhe*” ou “*liste*” orientam o modelo a produzir respostas mais estruturadas.

A aplicação integrada dessas técnicas favorece a geração de respostas mais precisas, eficientes e adequadas ao contexto da aplicação, contribuindo tanto para otimizar o desempenho quanto para reduzir o custo das interações com LLMs.

### 2.1.3 Principais Modelos Disponíveis para Uso em Aplicações

Os LLMs disponíveis em 2025 apresentam uma diversidade em termos de capacidades, acessibilidade e escala. Estes modelos podem ser categorizados principalmente em dois grupos: modelos acessíveis via API e modelos *open-source* ([ZHAO et al., 2023](#)).

Entre os modelos disponíveis via API, destacam-se: (a) o GPT (OpenAI), com capacidades multimodais incluindo processamento de texto, voz e visão ([OPENAI, 2024](#)); (b) o Gemini (Google), conhecido por sua alta velocidade e raciocínio avançado ([DEEPMIND, 2024](#)); (c) o Claude (Anthropic), especializado em conversação e automação empresarial ([Anthropic, 2024a](#)); (d) e o Command (Cohere), que oferece processamento de longo contexto com 256.000 tokens ([COHERE, 2024](#)).

No âmbito *open-source*, podem ser citados modelos como: (a) Llama (Meta) com até 405 bilhões de parâmetros e janela de contexto de 128.000 tokens ([META, 2024](#)); (b) DeepSeek-R1 com 671 bilhões de parâmetros ([Fireworks AI, 2024](#)); (c) e Mistral Small 3 com 24 bilhões de parâmetros ([Mistral AI, 2024](#)) oferecem alternativas robustas para implementação local; (d) o Qwen, desenvolvido pela Alibaba, destaca-se por seu suporte multilíngue e capacidades de raciocínio matemático ([TEAM, 2024](#)).

Uma característica notável é a variação nas janelas de contexto, com modelos como Llama e Command oferecendo capacidade de processamento de até 256.000 tokens, permitindo análise de textos extensos (Vellum AI, 2024). Além disso, diversos modelos apresentam capacidades multimodais, essenciais para aplicações que integram processamento de texto e imagem.

A escolha do modelo mais adequado para uma aplicação específica deve considerar fatores como necessidade de processamento local versus acesso via API, requisitos de janela de contexto, capacidades multimodais e tipo de licença disponível.

### 2.1.4 Comparativo entre LLMs disponíveis

Os LLMs disponíveis em 2025 apresentam diversidades em suas características e capacidades, tornando importante fazer uma análise comparativa detalhada para escolhas informadas em projetos de desenvolvimento.

A evolução dos modelos da família GPT demonstra um progresso consistente em capacidades e desempenho:

- **GPT-3.5:** representa o modelo base, com janela de contexto de 16.384 tokens e Massive Multitask Language Understanding (MMLU)<sup>1</sup> de 70–80% (TEAM et al., 2024). Ideal para tarefas básicas de processamento de linguagem e interações simples;
- **GPT-4:** marca um avanço significativo, expandindo a janela de contexto para 128.000 tokens e MMLU de 80–90% (ACHIAM et al., 2023). Adequado para tarefas mais complexas e raciocínio avançado;
- **GPT-4V:** introduz capacidades multimodais mantendo o alto desempenho do GPT-4, permitindo processamento integrado de texto e imagens (OpenAI, 2023);
- **GPT-4o:** representa um modelo multimodal avançado, com janela de contexto de 128.000 tokens e MMLU de aproximadamente 88–90% (OpenAI, 2024);
- **GPT-5:** a versão mais recente, com contexto de 400.000 tokens e alto desempenho em inteligência geral, MMLU acima de 90% em variantes (CHADHA, 2025).

A abordagem escalonada do Google oferece opções com o Gemini para diferentes necessidades:

---

<sup>1</sup> MMLU é um *benchmark* usado para avaliar o desempenho de LLMs em diversas tarefas. Ele testa a capacidade do modelo de aprender e aplicar conhecimento em diferentes áreas, desde matemática e ciências até humanidades e profissões. O MMLU é importante porque ajuda a medir a generalização e o raciocínio dos modelos, em vez de simplesmente avaliar sua capacidade de memorização.

- **Gemini 2.5 Flash-Lite:** Otimizado para velocidade, com parâmetros não especificados, janela de contexto de até 1 milhão de tokens, MMLU de 81–84%. Adequado para dispositivos com recursos limitados ([Google DeepMind, 2024](#));
- **Gemini 2.5 Flash:** Modelo intermediário com suporte multimodal, janela de contexto de 1 milhão de tokens, MMLU de 85–88% ([Google DeepMind, 2024](#));
- **Gemini 2.5 Pro:** O mais avançado, com capacidades multimodais nativas (incluindo áudio e vídeo), janela de contexto de 1 milhão de tokens, MMLU de 89% ([Google DeepMind, 2024](#)).

Por sua vez, a Anthropic apresenta duas variantes principais do Claude:

- **Claude 3 Sonnet:** Oferece uma extensa janela de contexto de 200.000 tokens com MMLU de aproximadamente 79%, focando em eficiência e velocidade ([Anthropic, 2024b](#));
- **Claude 3 Opus:** Mantém a janela de contexto de 200.000 tokens, mas eleva o desempenho para MMLU de 86.8%, ideal para tarefas que exigem maior precisão ([Anthropic, 2024b](#)).

Para realizar uma análise comparativa em termos de capacidade, deve-se levar em consideração a janela de contexto que está diretamente relacionada a quantidade de tokens. A janela varia significativamente entre os modelos, desde 16.384 tokens no GPT-3.5 até 1 milhão de tokens nos modelos Gemini 2.5, impactando diretamente a capacidade de processar textos longos e manter contexto em conversas extensas ([IBM, 2024](#)).

Além disso, também deve-se levar em consideração a capacidades multimodal. Estão presentes em modelos específicos tais como: (a) GPT-4V, GPT-4o GPT-5 ([IBM, 2024](#)); (b) Gemini 2.5 Flash e Pro ([Cursor IDE, 2025](#)); (c) Claude 3 ([Anthropic, 2024b](#)). A característica de multimodalidade é particularmente relevante para aplicações que necessitam processar diferentes tipos de mídia.

Em termos de desempenho, as LLMs são avaliadas em *benchmarks* MMLU e cada um dos tipos de modelo são classificados em diferentes níveis:

- **Modelos básicos:** 70–80% (e.g. GPT-3.5) ([CAROLAN; FENNELLY; SMEATON, 2024](#));
- **Intermediários:** 79–85% (e.g. Claude 3 Sonnet, Gemini Pro) ([TEAM et al., 2024](#));
- **Avançados:** 86–90% (e.g. GPT-4o, Gemini Ultra, Claude 3 Opus) ([TEAM et al., 2024](#)).

Em se tratando de disponibilidade e integração, todos os modelos são acessíveis via API, facilitando a integração em aplicações ([Artificial Analysis, 2024](#)). No entanto, aspectos importantes a considerar incluem custos de utilização (geralmente em dólares), limites de requisições, latência de resposta e requisitos de infraestrutura ([Artificial Analysis, 2024](#)).

Cada um dos modelos existentes aqui listados tem um desempenho melhor dependendo do contexto específico, assim, a seguir são apresentadas algumas recomendações por caso de uso:

- **Aplicações de Uso Geral:** GPT-4o ou Gemini 2.5 Flash: Bom equilíbrio entre custo e desempenho ([Google DeepMind, 2024](#));
- **Processamento de Documentos Longos:** Claude 3 Sonnet ou Gemini 2.5 Pro: Maior janela de contexto ([Anthropic, 2024](#));
- **Aplicações Multimodais:** GPT-4V ou Gemini 2.5 Pro: Capacidades avançadas de processamento de imagem e texto ([OpenAI, 2024](#)).

O desenvolvimento dos LLMs mostra tendências claras: *(i)* aumento das janelas de contexto, *(ii)* integração de capacidades multimodais, *(iii)* melhoria contínua em *benchmarks* de desempenho e, por fim, *(iv)* diversificação de modelos para diferentes casos de uso ([Helicone, 2024](#)). Todas essas informações devem ser levadas em consideração para uma análise comparativa e demonstra a riqueza de opções disponíveis de LLMs no mercado, o que permite escolhas informadas baseadas em requisitos específicos de cada projeto, considerando fatores como capacidade de processamento, necessidades multimodais, extensão de contexto e desempenho em *benchmarks*.

A Tabela 1 apresenta de forma consolidada as principais características dos modelos de LLM disponíveis em 2025, incluindo seus pontos fortes, limitações, capacidades especiais, especificações técnicas e casos de uso ideais. Essa visão comparativa auxilia na seleção do modelo mais adequado para diferentes cenários, equilibrando custo, desempenho e funcionalidades.

Tabela 1 – Comparação dos Principais Modelos LLM

Modelo	Pontos Fortes	Limitações	Capacidades Especiais	Características Técnicas	Casos de Uso Ideais
GPT-3.5	<ul style="list-style-type: none"> <li>Janela de 16.384 tokens</li> <li>MMLU 70-80%</li> <li>Baixo custo</li> </ul>	<ul style="list-style-type: none"> <li>Sem multimodalidade</li> <li>Precisão limitada</li> <li>Obsoleto para tarefas avançadas</li> </ul>	<ul style="list-style-type: none"> <li>Processamento de texto básico</li> <li>Interações rápidas</li> </ul>	<ul style="list-style-type: none"> <li>16.384 tokens</li> <li>Arquitetura transformer</li> <li>API OpenAI</li> </ul>	<ul style="list-style-type: none"> <li>Chatbots simples</li> <li>Tarefas básicas de NLP</li> </ul>
GPT-4 / GPT-4V / GPT-4o	<ul style="list-style-type: none"> <li>Janela até 128K</li> <li>MMLU 80-90%</li> <li>Multimodal (imagem, áudio)</li> <li>Alto desempenho</li> </ul>	<ul style="list-style-type: none"> <li>Custo elevado</li> <li>Latência variável</li> <li>Apenas via API</li> </ul>	<ul style="list-style-type: none"> <li>Raciocínio complexo</li> <li>Processamento multimodal</li> <li>Análise contextual</li> </ul>	<ul style="list-style-type: none"> <li>128K tokens</li> <li>Multimodalidade avançada</li> <li>API OpenAI</li> </ul>	<ul style="list-style-type: none"> <li>Assistentes inteligentes</li> <li>Análise multimídia</li> <li>Desenvolvimento de software</li> </ul>
GPT-5	<ul style="list-style-type: none"> <li>Contexto até 400K</li> <li>MMLU &gt;90%</li> <li>IA geral avançada</li> </ul>	<ul style="list-style-type: none"> <li>Acesso restrito</li> <li>Alto custo</li> </ul>	<ul style="list-style-type: none"> <li>Multimodalidade completa</li> <li>Processamento em larga escala</li> </ul>	<ul style="list-style-type: none"> <li>400K tokens</li> <li>Última geração OpenAI</li> <li>API estável</li> </ul>	<ul style="list-style-type: none"> <li>Pesquisa avançada</li> <li>Projetos empresariais críticos</li> </ul>
Gemini 2.5 Flash-Lite	<ul style="list-style-type: none"> <li>Alta velocidade</li> <li>Contexto até 1M</li> <li>MMLU 81-84%</li> </ul>	<ul style="list-style-type: none"> <li>Parâmetros não divulgados</li> <li>Capacidades reduzidas</li> </ul>	<ul style="list-style-type: none"> <li>Eficiência em dispositivos leves</li> </ul>	<ul style="list-style-type: none"> <li>1M tokens</li> <li>API Google Cloud</li> </ul>	<ul style="list-style-type: none"> <li>Aplicações móveis</li> <li>Respostas rápidas</li> </ul>
Gemini 2.5 Flash	<ul style="list-style-type: none"> <li>Multimodal</li> <li>Contexto até 1M</li> <li>MMLU 85-88%</li> </ul>	<ul style="list-style-type: none"> <li>Custo intermediário</li> <li>Requisitos computacionais</li> </ul>	<ul style="list-style-type: none"> <li>Processamento multimodal</li> <li>Escalabilidade</li> </ul>	<ul style="list-style-type: none"> <li>1M tokens</li> <li>API Google Cloud</li> </ul>	<ul style="list-style-type: none"> <li>Aplicações empresariais médias</li> <li>Chatbots multimodais</li> </ul>
Gemini 2.5 Pro	<ul style="list-style-type: none"> <li>Multimodal completo (texto, imagem, áudio, vídeo)</li> <li>Contexto até 1M</li> <li>MMLU ~89%</li> </ul>	<ul style="list-style-type: none"> <li>Custo elevado</li> <li>Complexidade de integração</li> </ul>	<ul style="list-style-type: none"> <li>Multimodalidade nativa</li> <li>Raciocínio avançado</li> </ul>	<ul style="list-style-type: none"> <li>1M tokens</li> <li>Arquitetura Google DeepMind</li> <li>API Google Cloud</li> </ul>	<ul style="list-style-type: none"> <li>Pesquisa avançada</li> <li>Aplicações multimodais completas</li> </ul>
Claude Sonnet 3	<ul style="list-style-type: none"> <li>Contexto 200K</li> <li>Eficiência e velocidade</li> <li>MMLU ~79%</li> </ul>	<ul style="list-style-type: none"> <li>Sem multimodalidade</li> <li>Precisão inferior</li> </ul>	<ul style="list-style-type: none"> <li>Processamento de documentos longos</li> </ul>	<ul style="list-style-type: none"> <li>200K tokens</li> <li>Constitucional AI</li> <li>API Anthropic</li> </ul>	<ul style="list-style-type: none"> <li>Documentos extensos</li> <li>Processamento rápido</li> </ul>
Claude Opus 3	<ul style="list-style-type: none"> <li>Contexto 200K</li> <li>MMLU ~87%</li> <li>Alta precisão</li> </ul>	<ul style="list-style-type: none"> <li>Sem multimodalidade</li> <li>Custo elevado</li> </ul>	<ul style="list-style-type: none"> <li>Raciocínio estruturado</li> <li>Análise detalhada</li> </ul>	<ul style="list-style-type: none"> <li>200K tokens</li> <li>API Anthropic</li> <li>Otimização para precisão</li> </ul>	<ul style="list-style-type: none"> <li>Pesquisa acadêmica</li> <li>Análises complexas</li> </ul>

### 2.1.5 Integração de APIs de LLMs com Serviços de Aplicações

Segundo [Yang et al. \(2025\)](#), a integração de APIs de LLMs com serviços de aplicações representa um avanço significativo na incorporação de inteligência artificial em sistemas de software. Os autores destacam que essa integração possibilita que aplicações web e móveis aproveitem capacidades avançadas de processamento de linguagem natural, como geração de texto, análise semântica e automação de tarefas, de forma escalável e eficiente. Além disso, enfatizam que a sinergia entre LLMs e bases de conhecimento externas é fundamental para aplicações reais, uma vez que aborda desafios técnicos e operacionais, além de favorecer maior contextualização dos dados e precisão dos resultados.

De acordo com [Bucioni et al. \(2025\)](#), a integração de APIs de LLMs envolve conectar modelos de linguagem com serviços de aplicação por meio de interfaces programáticas, tipicamente baseadas em protocolos como HTTP/REST ou GraphQL. Os LLMs, acessíveis via APIs de provedores como OpenAI, Google ou Anthropic, atuam como intermediários que traduzem solicitações de aplicações em processamento de linguagem natural (NLP/NLU) e retornam respostas compreensíveis pela aplicação.

O funcionamento básico segue o fluxo de solicitação-resposta ([TAO; FAN; YANG, 2024](#)):

- A aplicação envia uma requisição à API do LLM, geralmente na forma de um *prompt* ou entrada de usuário;
- O LLM processa o *input*, interpretando a intenção e analisando o contexto;
- O LLM gera uma resposta adequada e a envia de volta à aplicação;
- A aplicação utiliza a resposta para executar tarefas, fornecer informações ao usuário ou interagir com outros serviços.

Essa abordagem é essencial para cenários como chatbots, assistentes virtuais e análise de dados, nos quais os LLMs enriquecem interações com contexto e personalização. *Frameworks* avançados permitem que entradas em linguagem natural sejam convertidas automaticamente em chamadas de APIs externas, automatizando fluxos de trabalho ([TAO; FAN; YANG, 2024](#)). Além disso, integrações multimodais, combinando texto com imagens ou áudio, expandem as capacidades para aplicações mais complexas.

Para uma integração eficaz, recomenda-se adotar estratégias modulares e escaláveis. Por exemplo, abstrair protocolos variados por meio de interfaces unificadas facilita manutenção e atualização sem impactar o sistema principal. *Frameworks* especializados podem gerenciar autenticação, controle de versão e tráfego de requisições, garantindo escalabilidade e segurança ([DING; STEVENS, 2025](#)).

Abordagens inovadoras incluem a geração automática de microsserviços a partir de especificações RESTful usando LLMs ([CHAUHAN et al., 2025](#)) e a implementação de agentes baseados em LLMs que superam limitações de contexto e eficiência em ambientes móveis e empresariais ([HAU; HASSAN; ZHOU, 2025](#)).

Tendências recentes indicam crescimento na adoção de integrações via APIs, com foco em privacidade e eficiência computacional. A evolução para LLMs multimodais (MLLMs), combinando texto com processamento visual, representa um passo importante em direção à inteligência artificial mais geral ([YIN et al., 2024](#)).

### 2.1.6 Model Context Protocol (MCP)

O Model Context Protocol (MCP) é um protocolo aberto e padrão desenvolvido pela empresa Anthropic, lançado em novembro de 2024. Ele foi criado para facilitar a integração segura e bidirecional entre aplicações de IA, especialmente em LLMs, e fontes externas de dados ou ferramentas. Em essência, o MCP atua como uma "porta USB-C para IA", padronizando a forma como aplicativos fornecem contexto aos modelos de IA, permitindo que eles acessem informações de repositórios de conteúdo, ferramentas empresariais e ambientes de desenvolvimento de forma unificada e segura. Isso resolve problemas comuns, como silos de informação e sistemas legados que isolam os modelos de IA de dados relevantes, enabling respostas mais precisas e contextuais ([ANTHROPIC, 2024](#)).

O funcionamento do MCP envolve a criação de servidores MCP que expõem dados de sistemas como *Google Drive*, *Slack*, *GitHub*, *PostgreSQL*, ou clientes MCP que se conectam a esses servidores. Desenvolvedores podem implementar conexões rapidamente, e o protocolo é *open-source*, com repositórios disponíveis no *GitHub* para colaboração comunitária. Seus benefícios incluem a simplificação de integrações fragmentadas, a manutenção de contexto ao alternar entre ferramentas, e o aprimoramento de capacidades de IA em cenários como desenvolvimento de código, onde agentes de IA podem recuperar informações relevantes e gerar resultados mais eficientes ([ANTHROPIC, 2024](#)).

## 2.2 Trabalhos Relacionados e Aplicações Semelhantes

Nesta seção, são apresentados trabalhos relevantes que fornecem embasamento teórico e tecnológico para o desenvolvimento desta proposta, será realizada uma análise de algumas plataformas de streaming de vídeo que serviram como referência para o desenvolvimento do catálogo de filmes Web proposto. Cada plataforma será explorada quanto à sua finalidade, funcionalidades principais, interfaces e experiência do usuário. Além disso, serão apresentados alguns estudos que exploram o uso de LLMs e técnicas de

inteligência artificial para melhorar a experiência do usuário, seja por meio da análise de imagens, recomendação baseada em narrativa ou integração de múltiplas fontes de dados.

Johnson et al. (2023) analisa a capacidade do GPT-4 em lidar com elementos visuais diversos, como imagens, fluxogramas, gráficos e diagramas. Para avaliar a eficácia do GPT-4, foi utilizado um conjunto de amostras variados que incluía imagens em diversas categorias. O estudo empregou ChatGPT-4 e técnicas avançadas de processamento de imagem, destacando-se por uma análise robusta, testes abrangentes e comparação sistemática com a intuição humana. O GPT-4 foi submetido à um conjunto de perguntas específicas relacionadas à análise de imagens, com avaliadores humanos servindo como pontos de referência para comparação, oferecendo um padrão qualitativo para avaliar a eficácia do modelo. Os resultados demonstraram a habilidade do GPT-4 em fornecer informações precisas e detalhadas. O modelo demonstrou capacidade não apenas de reconhecer o conteúdo visual, mas também de compreender a natureza e o propósito específicos da imagem. No entanto, foram identificadas limitações significativas, principalmente em reconhecimento facial por questões de privacidade, foco restrito à análise visual sem implementação prática, e forte dependência da qualidade das imagens de entrada. O estudo também destaca o potencial do modelo na identificação de objetos dentro de imagens, abrindo portas para aplicações em detecção de objetos, embora a ausência de uma arquitetura definida seja notada como uma limitação adicional.

Eberhard, Ruprechter e Helic (2024) investigou a aplicabilidade de LLMs em sistemas de recomendação baseados em narrativas, nos quais os usuários expressam preferências por filmes por meio de descrições textuais livres. O estudo se destacou por realizar uma avaliação abrangente de 38 LLMs diferentes, incluindo modelos de código aberto e fechado, utilizando tecnologias como ChatGPT e outras implementações de LLMs, além de ferramentas estatísticas avançadas e técnicas de processamento de linguagem natural. A metodologia incluiu diferentes estratégias de *prompting* (*zero-shot*, identidade e *few-shot*), com validação robusta utilizando um *dataset* padrão ouro, do inglês, *gold-standard*. Os experimentos demonstraram que os LLMs conseguem gerar recomendações contextualmente relevantes, superando métodos tradicionais de recomendação como *doc2vec*, que é um algoritmo de aprendizado não supervisionado que gera representações vetoriais densas para sentenças, parágrafos ou documentos inteiros (LE; MIKOLOV, 2014). Um aspecto notável foi a descoberta de que o *prompting zero-shot* se mostrou tão eficaz quanto abordagens mais complexas, e que modelos de código aberto de porte médio foram competitivos em relação a modelos maiores e fechados. No entanto, o estudo identificou limitações importantes, como o foco restrito ao domínio de recomendação de filmes, ausência de implementação multimodal, e forte dependência da qualidade dos dados de treinamento. O trabalho também abordou questões como *data leakage* e identificou um viés de recência nos LLMs, indicando uma tendência desses modelos a recomendar filmes mais recentes. Essas descobertas tornaram esse trabalho particularmente relevante para pesquisadores e

profissionais interessados na integração de LLMs em sistemas de recomendação, fornecendo *insights* valiosos sobre seu potencial e limitações.

Dornelles (2017) propôs o desenvolvimento de um aplicativo Android para auxiliar colecionadores de filmes no manuseio e gerenciamento de suas coleções. O projeto utilizou um conjunto robusto de tecnologias, incluindo Java para o desenvolvimento principal, PostgreSQL para o banco de dados, Web Services (implementados com a biblioteca KSOAP2, que é uma biblioteca de terceiros voltada para o consumo de serviços *Simple Object Access Protocol* (SOAP) em plataformas Android.) para integração, além de ferramentas como PgAdmin, Android Studio, NetBeans e Astah para suporte ao desenvolvimento. A arquitetura seguiu o padrão Model View Controller (MVC), garantindo uma estrutura bem organizada e manutenível. O sistema se destacou por sua interface intuitiva e fácil de usar, implementação eficiente de Web Services para integração, e uma documentação detalhada que incluía diagramas de classes e casos de uso completos. Um diferencial importante foi a realização de testes com um colecionador de filmes real, permitindo validar as funcionalidades em um contexto prático. O aplicativo permite aos usuários visualizar informações, adicionar ou remover filmes e cadastrar anúncios de venda de filmes. Entre os pontos fortes, destacaram-se a funcionalidade do aplicativo que atendeu as expectativas e a possibilidade de acesso remoto à coleção. Contudo, foram identificadas limitações significativas, como a necessidade de popular o banco de forma manual para obter a lista de filmes disponíveis, a falta de um sistema de recuperação de conta, ausência de integração com sites especializados de venda, testes limitados a um único usuário e dependência de conexão com Internet. Os resultados mostraram que o aplicativo foi desenvolvido com sucesso, atendendo aos requisitos principais de gerenciamento de coleção de filmes e recebendo feedback positivo do usuário de teste, embora necessitando melhorias em funcionalidades específicas.

Qi (2024) propôs o VSM-LLM, um *framework* multimodal inovador para análise e classificação de gênero de filmes, combinando análise visual e de fala. O projeto utilizou um conjunto sofisticado de tecnologias, incluindo Visual-Speech LLM, Whisper ASR para reconhecimento de fala, InstructBLIP para processamento visual, e a arquitetura MGC Q-Former, sendo executado em hardware NVIDIA RTX-3090. O trabalho se destacou pela integração inovadora de análise visual e de fala, por meio de um desenvolvimento de um *framework* multimodal robusto, implementação de uma técnica eficiente de amostragem de frames e a arquitetura MGC Q-Former avançada. O sistema foi validado em *datasets* grandes e estabelecidos, demonstrando sua eficácia em condições reais. A arquitetura VSM-LLM com MGC Q-Former permitiu um alinhamento temporal preciso de características audiovisuais, além de empregar uma estratégia otimizada de amostragem de frames, reduzindo a carga computacional sem comprometer a precisão da classificação. No entanto, foram identificadas limitações significativas, incluindo forte dependência da qualidade do áudio e vídeo de entrada, alta complexidade computacional, limitações no processamento de

vídeos muito longos, necessidade de sincronização temporal precisa e restrições significativas de hardware. Os experimentos demonstraram que o VSM-LLM supera modelos unimodais e outros *frameworks* multimodais, alcançando resultados notáveis: 40,3% e 55,3% em macro e micro recall@0.5 no *dataset* MovieNet — o que representa ganhos de até 141,4% e 192,6% sobre o Whisper-v2, e de 97,5% e 133,1% sobre o InstructBLIP. No *dataset* Condensed Movies, o modelo obteve 43,5% e 53,5%, com melhorias de até 227,1% e 240,1% sobre o Whisper-v2, e de 119,7% e 130,6% sobre o InstructBLIP. Esses resultados ressaltam a importância da integração de diferentes modalidades na análise de vídeos, permitindo que o modelo extraia informações linguísticas e visuais de forma autônoma, representando um avanço significativo para sistemas de recomendação baseados em IA.

Carvalho (2023) abordou o desenvolvimento *front-end* de um catálogo de filmes Web, explorando boas práticas e tecnologias atuais no campo da programação Web. O projeto implementou um conjunto abrangente de tecnologias modernas, incluindo Vue3 para o *framework* principal, Vuex para gerenciamento de estado, Vue Router para navegação, HTML5/CSS3 e JavaScript para desenvolvimento Web, MySQL para banco de dados, Node.js para o *backend*, e *Figma* para design e prototipação. A arquitetura seguiu o padrão MVC com ênfase em criação de componentes, garantindo modularidade e reusabilidade. O trabalho se destacou por seu design intuitivo e responsivo, implementação eficiente de componentes, integração robusta com a API TMDb, documentação abrangente e uma arquitetura modular altamente escalável. A metodologia empregada enfatizou a importância de uma interface amigável e facilidade de navegação, com foco particular na experiência do usuário. Os resultados ressaltaram a relevância de uma arquitetura modular e design intuitivo. No entanto, foram identificadas várias limitações importantes, incluindo a necessidade de autenticação para acesso a recursos completos, dependência de API externa para dados de filmes, limitações significativas na personalização do perfil do usuário, ausência de criptografia de dados sensíveis e falta de recursos de acessibilidade. O sistema foi implementado com sucesso, oferecendo uma interface intuitiva e funcional para catalogação de filmes, demonstrando como a combinação de práticas de programação avançadas e um design centrado no usuário pode resultar em plataformas digitais eficazes e atraentes. O trabalho também identificou potencial para expansões futuras e melhorias em aspectos de segurança e acessibilidade.

A seguir serão apresentadas as funcionalidades de sistemas semelhantes ao que estamos explorando neste estudo. A análise visa fornecer um contexto para o projeto em questão, permitindo uma melhor compreensão de suas características e do diferencial em relação a soluções existentes. Os sistemas analisados são: Trakt.tv<sup>2</sup>, Letterboxd<sup>3</sup>, IMDb<sup>4</sup>,

<sup>2</sup> Disponível em: <<https://trakt.tv>>. Acesso em: 28 ago. 2025.

<sup>3</sup> Disponível em: <<https://letterboxd.com>>. Acesso em: 28 ago. 2025.

<sup>4</sup> Disponível em: <<https://www.imdb.com>>. Acesso em: 28 ago. 2025.

Whatismymovie.com<sup>5</sup> e Trace.moe<sup>6</sup>.

O [Trakt...](#) (2025) configura-se como uma plataforma digital dedicada ao acompanhamento, descoberta e compartilhamento de conteúdos audiovisuais, com ênfase em filmes e séries de televisão. A plataforma se destaca por oferecer um conjunto abrangente de funcionalidades. No âmbito catalográfico, o [Trakt.tv](#) apresenta um extenso acervo de títulos cinematográficos e televisivos, fornecendo informações detalhadas que incluem elenco, equipe técnica, sinopses, trailers e datas de lançamento. Seu sistema de avaliação permite que usuários classifiquem obras em uma escala de zero a dez, além de possibilitar a elaboração de críticas e comentários.

A plataforma do [Trakt.tv](#) se diferencia por suas ferramentas de organização, permitindo a criação de listas personalizadas, públicas ou privadas, que podem ser utilizadas para diversos propósitos, desde o acompanhamento de séries em andamento até o planejamento de futuras visualizações. Também possui um recurso de mecanismo de recomendação, que utiliza algoritmos para sugerir conteúdos baseados no histórico e preferências individuais de cada usuário.

A dimensão social do [Trakt.tv](#) é igualmente significativa, possibilitando interações entre usuários por meio do compartilhamento de listas, avaliações e históricos de visualização. A plataforma promove uma experiência colaborativa de descoberta e apreciação de conteúdos audiovisuais. Em termos tecnológicos, a plataforma se destaca pela capacidade de integração com múltiplas plataformas de streaming como Netflix, Hulu e Amazon Prime Video e pela disponibilização de APIs que permitem o desenvolvimento de aplicações e extensões complementares.

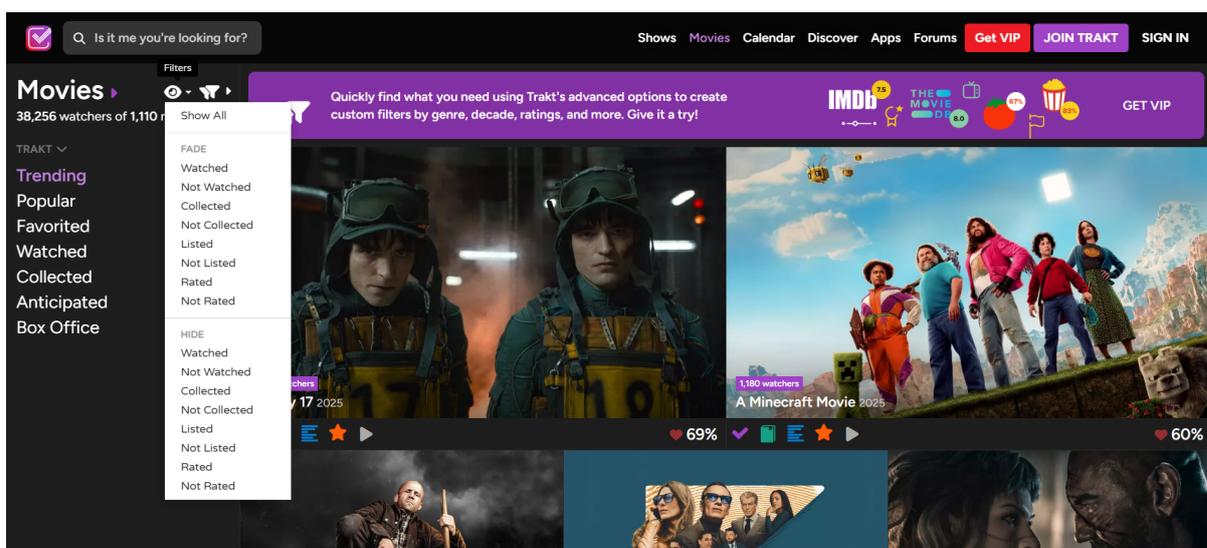
A Figura 1 ilustra a interface principal da plataforma [Trakt.tv](#), destacando sua organização visual e os recursos disponíveis para o usuário. À esquerda, o menu lateral exibe categorias como “Trending”, “Popular” e “Watched”, permitindo acesso rápido a listas personalizadas e ao histórico de visualização. Na parte superior, a barra de busca e o botão de filtros possibilitam localizar conteúdos e personalizar a exibição de resultados com base em critérios como assistidos, não assistidos ou coletados. A área central apresenta os filmes e séries em destaque, com informações como título, ano de lançamento e percentual de aprovação, além de ícones interativos para adicionar à coleção, marcar como assistido ou avaliar.

O [Letterboxd](#) (2023) é uma rede social voltada para amantes do cinema, que permite aos usuários registrar os filmes que assistiram, classificá-los, escrever críticas e compartilhar suas opiniões com amigos e outros cinéfilos. A plataforma se destaca por seu catálogo extensivo de filmes, que fornece informações detalhadas, incluindo elenco, equipe técnica, sinopses e dados de lançamento. Seu sistema de avaliação permite uma

<sup>5</sup> Disponível em: <<https://www.whatismymovie.com>>. Acesso em: 28 ago. 2025.

<sup>6</sup> Disponível em: <<https://trace.moe>>. Acesso em: 28 ago. 2025.

Figura 1 – Interface da plataforma Trakt.



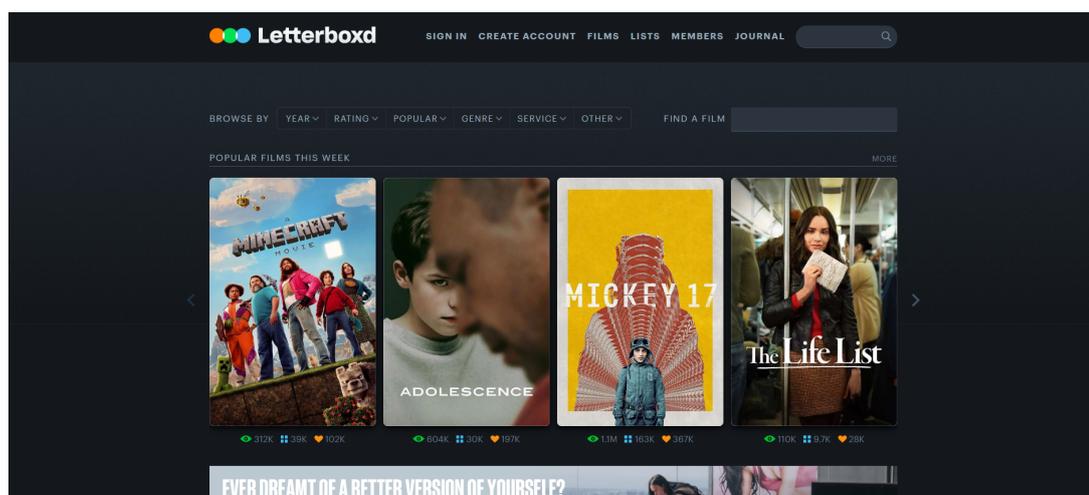
Fonte: Retirado de (TRAKT..., 2025).

abordagem personalizada e subjetiva, com classificações que variam de 0,5 a 5 estrelas, possibilitando aos usuários atribuir significados individuais às suas avaliações.

Os recursos de organização do Letterboxd são particularmente sofisticados, permitindo a criação de listas personalizadas, públicas ou privadas, e um diário de filmes que registra não apenas as obras assistidas, mas também as datas específicas de visualização. Essa funcionalidade oferece aos usuários uma ferramenta abrangente para documentar e compartilhar sua jornada cinematográfica. A dimensão social da plataforma é central em sua proposta, incentivando a interação entre usuários por meio de seguimentos, compartilhamento de críticas e discussões. Os mecanismos de recomendação utilizam algoritmos que analisam preferências individuais e padrões de usuários com gostos semelhantes, facilitando a descoberta de novos títulos cinematográficos. Tecnicamente, o Letterboxd se diferencia pela capacidade de integração com outras plataformas de mídia social como o X e o Facebook e pelo potencial de análise de dados, permitindo que os usuários compartilhem e exportem suas preferências cinematográficas, tornando-se não apenas um registro pessoal, mas uma ferramenta colaborativa de descoberta e apreciação cinematográfica.

A Figura 2 apresenta a interface principal da plataforma Letterboxd, destacando sua organização visual e os recursos disponíveis para os usuários. Na barra superior, encontram-se opções de navegação como login, criação de conta e acesso a seções como "Films", "Lists" e "Journal". Logo abaixo, estão disponíveis filtros avançados, como ano de lançamento, avaliação, popularidade e gênero, que permitem refinar os resultados de busca. A área principal exibe os filmes mais populares da semana, com informações como título, número de visualizações, curtidas e favoritos. Cada filme é representado por um cartaz destacado,

Figura 2 – Interface da plataforma Letterboxd.



Fonte: Retirado de (LETTERBOXD, 2023).

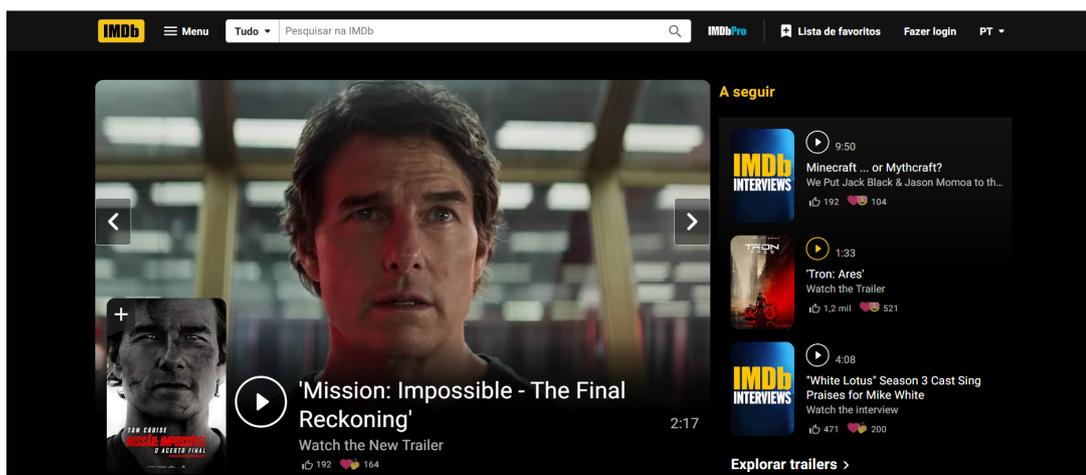
acompanhado de métricas que incentivam o engajamento social.

O Internet Movie Database [IMDB \(2025\)](#) é um banco de dados online que contém informações sobre filmes, programas de TV, videogames e outras produções de mídia abrangente dedicada ao registro e análise de produções audiovisuais, configurando-se como um repositório global de informações sobre os mesmos. A plataforma se destaca por sua arquitetura informacional que integra múltiplas funcionalidades para entusiastas e profissionais do entretenimento. Seu catálogo extensivo oferece informações detalhadas sobre produções, incluindo elenco, equipe técnica, sinopses e elementos contextuais. O sistema de avaliação permite que usuários classifiquem títulos em uma escala de 1 a 10, gerando classificações médias que se tornam referência para outros usuários e consumidores de mídia. As ferramentas de organização, como a “*watchlist*” e listas personalizadas, proporcionam aos usuários mecanismos sofisticados de acompanhamento e planejamento de visualizações. O IMDbPro adiciona camadas profissionais a essas funcionalidades, oferecendo recursos avançados para profissionais da indústria cinematográfica.

Os mecanismos de descoberta do IMDb utilizam algoritmos que analisam preferências individuais e padrões de consumo, gerando recomendações personalizadas e facilitando a exploração de novos conteúdos. A dimensão social da plataforma permite comparações entre usuários, compartilhamento de listas e participação em comunidades de discussão. Tecnicamente, o IMDb se diferencia pela capacidade de integração com plataformas de streaming como Amazon Prime Video e pela robustez de seu sistema de recomendação, tornando-se um conjunto completo de informação e descoberta audiovisual.

A Figura 3 apresenta a interface principal da plataforma IMDb, destacando seu foco em conteúdos audiovisuais, como trailers e entrevistas. Na barra superior, encontram-se opções de navegação, como o menu “Tudo”, que organiza categorias como filmes e séries,

Figura 3 – Interface da plataforma do IMDB.



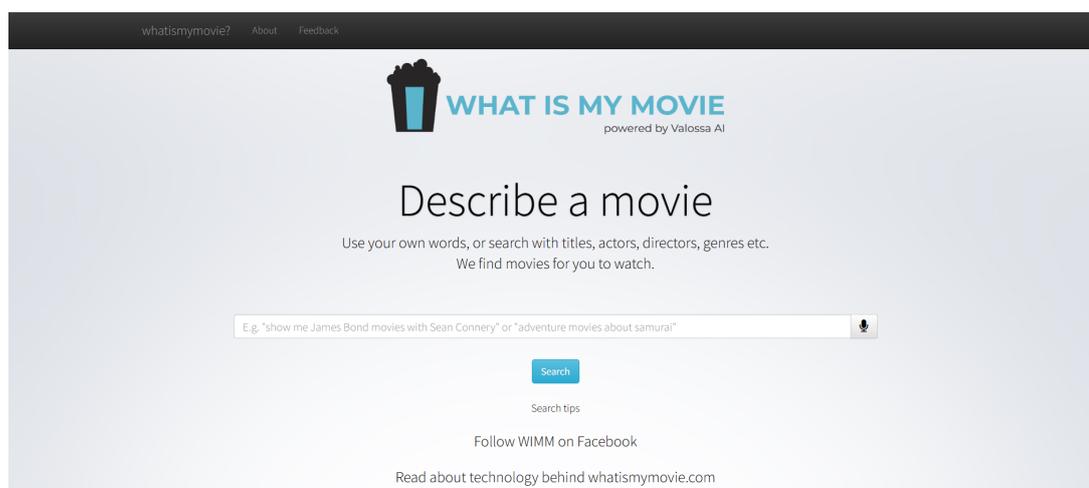
Fonte: Retirado de (IMDB, 2025).

e o campo de busca central para localizar conteúdos específicos. A área principal exibe um trailer em destaque, acompanhado de informações como título, duração e ícones de interação, permitindo que o usuário curta ou reaja ao conteúdo. À direita, a seção “A seguir” lista outros vídeos relacionados, como entrevistas e trailers, com métricas de popularidade, como número de curtidas e reações.

O *What...* (2025) é um mecanismo de busca de filmes que permite aos usuários encontrar filmes descrevendo-os com suas próprias palavras ou usando títulos, atores, diretores, gêneros ou citações. A plataforma se destaca pela aplicação de tecnologias de inteligência artificial e aprendizado de máquina para identificação de conteúdos audiovisuais. Seu diferencial reside no mecanismo de busca descritivo, que possibilita aos usuários encontrar filmes utilizando uma variedade de elementos como enredos, personagens, cenas específicas, gêneros ou até mesmo citações. A tecnologia de *Deep Content* permite uma análise algorítmica profunda que vai além de metadados convencionais, incorporando análises de transcrições, padrões sonoros e visuais. Embora não ofereça sistemas de avaliação ou recursos de comunidade tradicionalmente encontrados em plataformas similares, o *Whatismymovie* se concentra em sua capacidade única de identificação de conteúdo, tornando-se uma ferramenta especializada para descoberta cinematográfica.

A Figura 4 apresenta a interface principal da plataforma *What Is My Movie*, destacando seu design minimalista e o foco na funcionalidade de busca por descrições. No topo, o logotipo da plataforma é exibido ao lado do texto “What Is My Movie”, com a indicação de que a tecnologia é suportada pela Valossa AI. A mensagem central “Describe a movie” orienta o usuário sobre como utilizar a ferramenta, enquanto o campo de busca permite inserir descrições detalhadas ou palavras-chave. Um exemplo de uso é exibido no placeholder, como “show me James Bond movies with Sean Connery”. O botão de microfone ao lado do campo indica suporte para entrada de voz, e o botão “Search” inicia

Figura 4 – Interface da plataforma What is my movie.



Fonte: Retirado de (WHAT . . . , 2025).

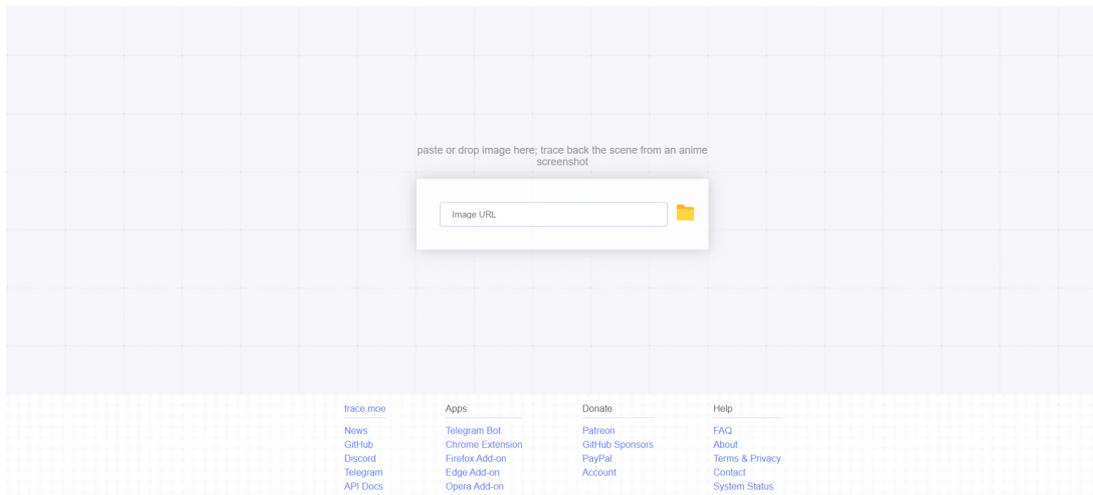
a busca. Abaixo do campo de busca, links adicionais oferecem dicas de uso, informações sobre a tecnologia da plataforma e acesso às redes sociais.

O [trace.moe](#) (2024b) representa uma plataforma tecnológica especializada na identificação de cenas de anime, utilizando tecnologias avançadas de reconhecimento de imagem e análise de conteúdo audiovisual. Sua proposta inovadora consiste em permitir que usuários localizem a origem exata de imagens e trechos de animações japonesas por meio de uploads simples. Com um banco de dados abrangente que abrange mais de 30.000 horas de conteúdo animado, o Trace.moe oferece uma ferramenta precisa para rastreamento de cenas, episódios e momentos específicos em produções anime. A plataforma utiliza algoritmos sofisticados que analisam características visuais para identificar com precisão a origem de screenshots e GIFs.

Diferentemente de plataformas mais generalistas, o Trace.moe se concentra especificamente no universo das animações japonesas, fornecendo uma interface simples que permite aos usuários fazer upload de imagens e receber informações detalhadas sobre sua origem. A ferramenta inclui funcionalidades como pré-visualização da cena identificada, garantindo a confirmação do usuário. Embora não possua sistemas tradicionais de avaliação ou comunidade, o Trace.moe estabelece conexões com comunidades online a partir de links para plataformas como *Discord* e *Telegram*, e oferece integração tecnológica por meio de APIs e extensões de navegador.

A Figura 5 apresenta a interface principal da plataforma *Trace.moe*, destacando seu design minimalista e o foco na funcionalidade de busca por imagens. O elemento central é o campo de upload, onde o usuário pode inserir o URL de uma imagem ou fazer upload diretamente de uma captura de tela. A mensagem “Paste or drop image here; trace back the scene from an anime screenshot” orienta o usuário sobre como utilizar a

Figura 5 – Interface da plataforma Trace moe.



Fonte: Retirado de (TRACE. . . , 2025).

ferramenta para identificar a origem de uma cena de anime. No rodapé, estão disponíveis links organizados em seções, como “Trace.moe”, que inclui acesso à documentação da API e ao *GitHub*, e “Apps”, com extensões para navegadores e bots no *Telegram*. Também há opções para apoiar o projeto por meio de doações e links de ajuda, como FAQ e termos de uso.

A Tabela 2 apresenta uma análise comparativa dos trabalhos relacionados, destacando os pontos positivos, limitações, áreas de atuação, tecnologias utilizadas, arquiteturas adotadas e os principais resultados obtidos. Essa tabela é importante para compreender as contribuições e lacunas de cada estudo, fornecendo um panorama que embasa o desenvolvimento da proposta deste trabalho.

As colunas da tabela possuem os seguintes significados: a coluna *Autor* identifica o autor ou autores do trabalho analisado; *Pontos Positivos* apresenta os principais aspectos positivos e contribuições do estudo; *Pontos Negativos* destaca as limitações ou desafios enfrentados; *Áreas de Atuação* indica o foco principal do trabalho, como análise de imagens, recomendação ou gerenciamento de coleções; *Tecnologias Utilizadas* lista as ferramentas, *frameworks* ou linguagens empregadas no desenvolvimento; *Arquitetura do Sistema* descreve a estrutura arquitetural adotada, como MVC ou *frameworks* específicos; e, por fim, *Resultados* sintetiza os principais encontrados ou contribuições práticas alcançadas em cada trabalho.

Cada linha da tabela representa um trabalho relacionado. O estudo de Johnson et al. (2023) destaca-se pela análise robusta do GPT-4 em imagens, mas apresenta limitações no reconhecimento facial e na implementação prática. Já Eberhard, Ruprechter e Helic (2024) explora o uso de LLMs em sistemas de recomendação baseados em narrativas,

com bons resultados em recomendações contextuais, mas sem suporte multimodal. O trabalho de [Dornelles \(2017\)](#) propõe um aplicativo para gerenciamento de coleções de filmes, com interface intuitiva, embora limitado em funcionalidades e escalabilidade. Em seguida, [Qi \(2024\)](#) apresenta um *framework* multimodal avançado para análise de vídeos, superando modelos unimodais em recall, mas com alta complexidade computacional. Por fim, [Carvalho \(2023\)](#) aborda o desenvolvimento *front-end* de um catálogo de filmes, com design intuitivo e componentização eficiente, mas dependente de APIs externas e com limitações de acessibilidade.

Essas observações reforçam a importância de integrar tecnologias modernas e abordar as limitações identificadas nos trabalhos existentes, de modo a ampliar as funcionalidades de sistemas voltados ao consumo de mídia digital.

Tabela 2 – Comparação de trabalhos relacionados

Autor	Pontos Positivos	Pontos Negativos	Áreas de Atuação	Tecnologias Utilizadas	Arquitetura do Sistema	Resultados
Johnson et al. (2023)	<ul style="list-style-type: none"> <li>Análise robusta do GPT-4</li> <li>Testes com diversos tipos de imagens</li> <li>Análise comparativa com intuição humana</li> <li>Avaliação detalhada de capacidades</li> </ul>	<ul style="list-style-type: none"> <li>Limitações em reconhecimento facial</li> <li>Foco apenas em análise visual</li> <li>Sem implementação prática</li> <li>Dependência da qualidade das imagens</li> </ul>	Análise de Imagens e Visão Computacional	<ul style="list-style-type: none"> <li>ChatGPT-4</li> <li>Técnicas de processamento de imagem</li> </ul>	Não especificada	O GPT-4 demonstrou capacidade significativa na análise de imagens, superando a intuição humana em alguns casos
Eberhard et al. (2024)	<ul style="list-style-type: none"> <li>Avaliação de 38 LLMs</li> <li>Comparação entre modelos open e closed-source</li> <li>Validação robusta</li> <li>Análise de diferentes estratégias</li> </ul>	<ul style="list-style-type: none"> <li>Limitado a recomendação de filmes</li> <li>Foco apenas em entrada textual</li> <li>Ausência de implementação multimodal</li> <li>Dependência de dados de treinamento</li> </ul>	Sistemas de Recomendação	<ul style="list-style-type: none"> <li>ChatGPT</li> <li>Outros LLMs</li> <li>Técnicas de NLP</li> </ul>	Não especificada	LLMs demonstraram eficácia em recomendações narrativas
Domelles (2017)	<ul style="list-style-type: none"> <li>Interface intuitiva</li> <li>Web services eficientes</li> <li>Testes com usuário real</li> <li>Documentação detalhada</li> </ul>	<ul style="list-style-type: none"> <li>População manual de filmes</li> <li>Falta recuperação de conta</li> <li>Sem integração com sites</li> <li>Limitado a um usuário</li> </ul>	Gerenciamento de Coleções	<ul style="list-style-type: none"> <li>Java</li> <li>Android</li> <li>PostgreSQL</li> <li>KSOAP2</li> </ul>	MVC	Aplicativo desenvolvido com sucesso, atendendo requisitos principais
Qi (2024)	<ul style="list-style-type: none"> <li>Integração visual e fala</li> <li>Framework multimodal</li> <li>Amostragem eficiente</li> <li>Arquitetura avançada</li> </ul>	<ul style="list-style-type: none"> <li>Dependência de qualidade A/V</li> <li>Complexidade computacional</li> <li>Limitações em vídeos longos</li> <li>Restrições de hardware</li> </ul>	Análise de Vídeos e Recomendação	<ul style="list-style-type: none"> <li>Visual-Speech LLM</li> <li>Whisper ASR</li> <li>InstructBLIP</li> <li>MGC Q-Former</li> </ul>	VSM-LLM	Alcançou resultados superiores em classificação de gêneros
Carvalho (2023)	<ul style="list-style-type: none"> <li>Design intuitivo</li> <li>Componentização eficiente</li> <li>Documentação abrangente</li> <li>Arquitetura modular</li> </ul>	<ul style="list-style-type: none"> <li>Necessidade de autenticação</li> <li>Dependência de API externa</li> <li>Ausência de criptografia</li> <li>Falta de acessibilidade</li> </ul>	Desenvolvimento Front-end	<ul style="list-style-type: none"> <li>Vue3</li> <li>MySQL</li> <li>Node.js</li> <li>Figma</li> </ul>	MVC com componentização	Sistema implementado com sucesso, interface intuitiva e funcional

## 2.3 Considerações Finais

Neste capítulo foram apresentados os principais fundamentos teóricos que embasam este trabalho, com destaque para a arquitetura e o funcionamento dos LLMs, as técnicas de *prompt engineering* e os diferentes modelos de LLMs atualmente disponíveis.

Foram ainda analisados trabalhos relacionados e aplicações semelhantes, os quais permitiram compreender o estado da arte e identificar limitações presentes em soluções existentes. Essa análise reforçou a relevância da proposta desenvolvida neste TCC, que busca integrar recursos de busca multimodal e gerenciamento de mídia assistidos por inteligência artificial.

A análise comparativa dos trabalhos relacionados, apresentada na Tabela 2, foi importante para identificar as contribuições e lacunas de estudos anteriores. Essa tabela permitiu organizar os trabalhos em termos de suas áreas de atuação, tecnologias utilizadas e arquiteturas adotadas, além de destacar seus pontos positivos e limitações. A partir dessa análise, foi possível embasar o desenvolvimento da proposta deste trabalho, que busca superar as limitações identificadas e propor uma solução inovadora e alinhada às necessidades do cenário atual.

## 3 Modelagem e Desenvolvimento

Este capítulo apresenta uma descrição da concepção, modelagem e implementação do sistema proposto neste projeto, o Media Tracker. O objetivo é documentar as decisões arquiteturais, tecnologias empregadas, padrões de projeto adotados e a estrutura de desenvolvimento de cada componente, justificando as escolhas técnicas em relação aos requisitos funcionais e não funcionais estabelecidos.

A plataforma foi desenvolvida seguindo uma arquitetura modular, na qual cada módulo mantém responsabilidades bem definidas e se comunica por meio de APIs REST. O módulo de *backend* implementa especificamente a arquitetura hexagonal (também conhecida como Portas e Adaptadores), enquanto os demais módulos seguem padrões arquiteturais apropriados às suas responsabilidades. Esta abordagem oferece benefícios de modularidade, testabilidade e separação de responsabilidades, mantendo a simplicidade operacional adequada ao escopo acadêmico do projeto.

Este capítulo está estruturado para apresentar, inicialmente, os requisitos que orientaram o desenvolvimento do sistema, seguidos pela modelagem das funcionalidades e fluxos operacionais. Em seguida, são detalhadas as decisões arquiteturais e as tecnologias utilizadas na implementação dos módulos principais.

### 3.1 Definição dos Requisitos

A definição dos requisitos é uma etapa importante no desenvolvimento de sistemas, pois descreve de forma clara e objetiva as funcionalidades que o sistema deve apresentar, bem como as características de qualidade esperadas da solução. Estes requisitos servem de base para a modelagem, implementação e validação da plataforma proposta.

Os requisitos do sistema Media Tracker foram organizados em duas categorias principais: (1) **funcionais**, que definem os comportamentos e serviços oferecidos ao usuário; e (2) **não funcionais**, que descrevem propriedades relacionadas à qualidade do sistema, como desempenho, usabilidade, segurança e manutenibilidade. Estes requisitos servem como diretrizes fundamentais que orientam todas as decisões arquiteturais e tecnológicas apresentadas nas seções subsequentes deste capítulo. Cada requisito funcional foi mapeado para componentes específicos da arquitetura modular, enquanto os requisitos não funcionais influenciaram diretamente a escolha das tecnologias e padrões implementados.

Na Tabela 3, são apresentados os requisitos funcionais do sistema. Em seguida, a Tabela 4 apresenta os requisitos não funcionais definidos para a plataforma. A implementação de cada requisito será detalhada nas seções de desenvolvimento correspondentes,

demonstrando como a arquitetura proposta atende integralmente às especificações estabelecidas.

Tabela 3 – Requisitos funcionais da plataforma

<b>ID</b>	<b>Descrição</b>
RF01	Permitir que o usuário organize e gerencie um catálogo pessoal de filmes e séries, incluindo adição, remoção e categorização personalizada.
RF02	Permitir ao usuário buscar filmes e séries na biblioteca global, com filtros por título, gênero, ano e número de temporadas (para séries).
RF03	Facilitar a adição de filmes e séries da biblioteca global ao catálogo pessoal do usuário.
RF04	Permitir que o usuário registre o progresso de visualização de filmes e séries (por episódio ou temporada, no caso de séries).
RF05	Permitir busca visual por filmes e séries por meio do upload de imagens, interpretadas por um modelo LLM.
RF06	Permitir busca textual por filmes e séries a partir de descrições ou palavras-chave, interpretadas por um modelo LLM.

Tabela 4 – Requisitos não funcionais da plataforma

ID	Categoria	Descrição
RNF01	Desempenho	O sistema deve responder às solicitações do usuário (como buscas e carregamento de páginas) em até 3 segundos.
RNF02	Desempenho	O sistema deve ser escalável, suportando um grande número de usuários e um extenso catálogo de dados sem degradação perceptível de desempenho.
RNF03	Desempenho	A plataforma deve estar disponível 24 horas por dia, 7 dias por semana, com o mínimo de indisponibilidade.
RNF04	Segurança	O sistema deve exigir autenticação para acesso às funcionalidades personalizadas, como o catálogo pessoal e o progresso de visualização.
RNF05	Segurança	O sistema deve controlar o acesso às funcionalidades com base nas permissões de cada usuário.
RNF06	Usabilidade	A interface deve ser intuitiva, facilitando a navegação e o acesso às funcionalidades.
RNF07	Usabilidade	O sistema deve proporcionar uma experiência agradável e eficiente para o usuário.
RNF08	Manutenibilidade	O código-fonte deve ser limpo, modular e devidamente documentado, facilitando a manutenção e atualizações.
RNF09	Manutenibilidade	O sistema deve ser projetado para permitir fácil adição de novas funcionalidades ou alteração das existentes.
RNF10	Manutenibilidade	O sistema deve permitir a realização de testes unitários e de integração de forma eficaz.
RNF11	Portabilidade	O sistema deve funcionar corretamente nos principais navegadores Web modernos.
RNF12	Portabilidade	A interface deve ser responsiva, adaptando-se a diferentes tamanhos de tela.
RNF13	Confiabilidade	O sistema deve ser capaz de lidar com erros de forma robusta, exibindo mensagens claras e informativas ao usuário.
RNF14	Portabilidade	O sistema deve ser implantável em diferentes ambientes por meio de containerização.

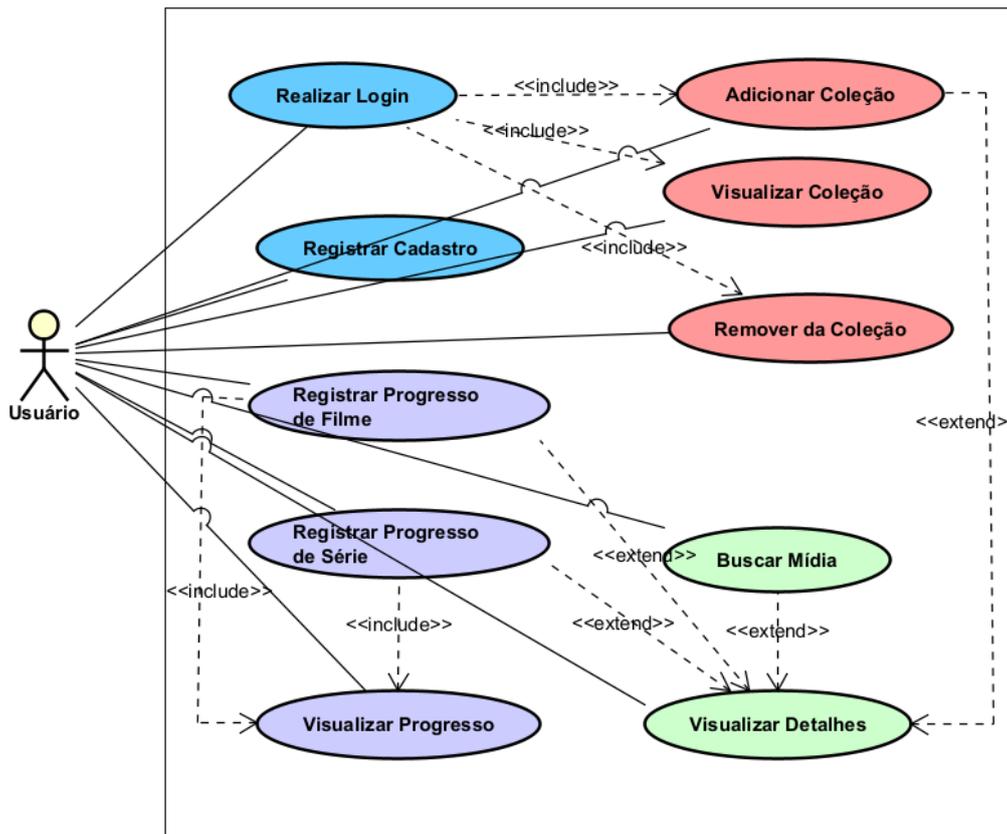
## 3.2 Modelagem dos Casos de Uso

Com o objetivo de representar de forma clara as funcionalidades previstas para o sistema Media Tracker, foi elaborada a modelagem de casos de uso utilizando a linguagem Unified Modeling Language (UML). O diagrama de casos de uso permite visualizar, de maneira concisa, as interações entre o usuário do sistema e os serviços oferecidos pela aplicação.

Na Figura 6, observa-se que o ator principal do sistema é o “Usuário”, que pode realizar diversas ações relacionadas ao gerenciamento de sua coleção de filmes e séries, ao registro de progresso de visualização e à busca por novos conteúdos.

As funcionalidades estão agrupadas por cor, de forma a facilitar a identificação das categorias:

Figura 6 – Diagrama de casos de uso do sistema Media Tracker.



Fonte: Elaborado pela autora.

- **Azul:** Funcionalidades de autenticação (login e cadastro);
- **Rosa:** Gerenciamento da coleção pessoal (adicionar, remover e visualizar);
- **Roxo:** Registro de progresso de visualização;
- **Verde:** Funcionalidades de busca e visualização de detalhes.

Algumas relações de dependência estão representadas por meio dos estereótipos «include» e «extend», que indicam, respectivamente, que um caso de uso é incluído obrigatoriamente em outro ou que pode ser estendido de forma opcional, dependendo do contexto de execução.

### 3.3 Diagrama de Atividades

O diagrama de atividade é uma ferramenta essencial na modelagem de sistemas, pois permite representar o fluxo de controle entre diferentes ações ou estados de um processo. No contexto do sistema Media Tracker, esses diagramas foram utilizados para

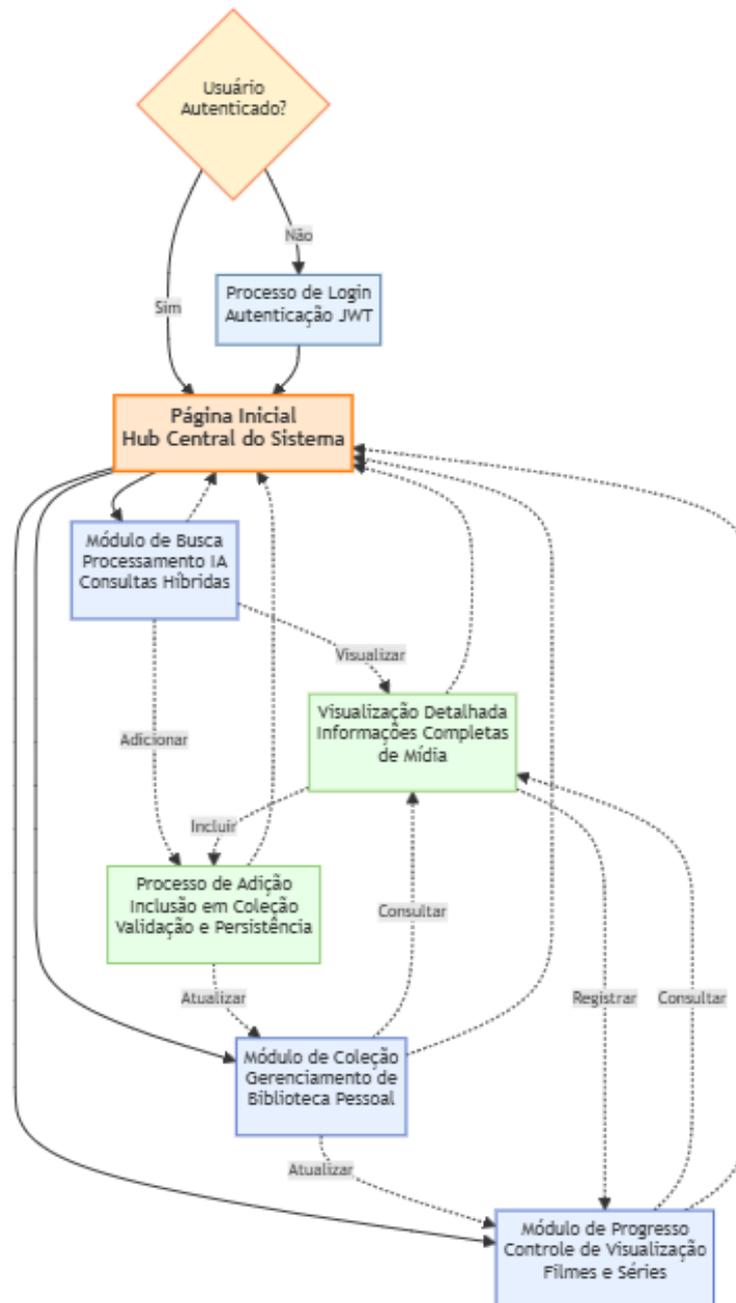
descrever os principais fluxos operacionais e interações dos usuários com as funcionalidades oferecidas pela plataforma.

Nas subseções a seguir são apresentados os diagramas de atividades desenvolvidos para os principais processos do sistema.

### 3.3.1 Visão Integrada dos Fluxos

A Figura 7 apresenta a visão macro do sistema, demonstrando as interconexões entre os seis fluxos operacionais detalhados nas subseções seguintes. O diagrama evidencia como a **Página Inicial** atua como *hub* central do sistema, servindo como ponto de partida para o acesso aos módulos funcionais. A navegação entre estes módulos é coordenada pelo menu lateral persistente (*sidebar*), que permite acesso direto às páginas principais: **Busca de Mídia** (subseção 3.3.4), **Visualizar Coleção** (subseção 3.3.6) e **Registro de Progresso** (subseção 3.3.5). Dentro dessas páginas, o usuário pode realizar ações específicas como **Adicionar Item ao Catálogo Pessoal** (subseção 3.3.3) e **Visualizar Detalhes de Mídia** (subseção 3.3.7). As seções seguintes detalham cada um destes fluxos individuais.

Figura 7 – Diagrama de atividades macro: visão integrada dos fluxos do sistema.

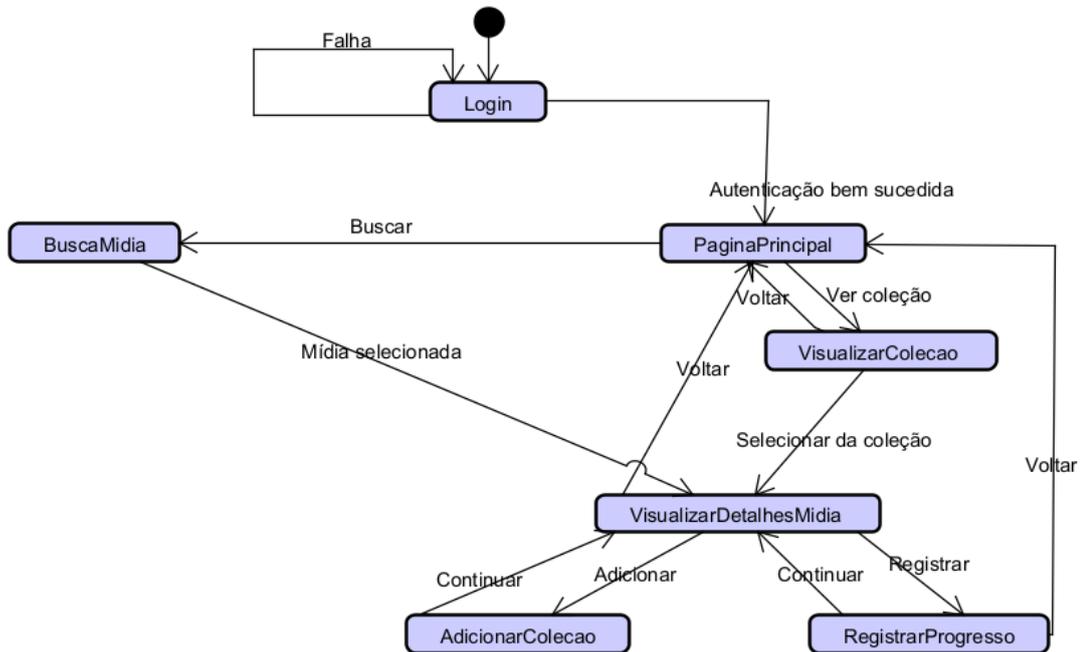


Fonte: Elaborado pela autora.

### 3.3.2 Fluxo de Login

O diagrama apresentado na Figura 8 descreve o fluxo de autenticação do usuário no sistema. Este processo inicia com a tentativa de login, onde o sistema verifica as credenciais fornecidas. Em caso de sucesso, o usuário é redirecionado à página principal, caso contrário, uma mensagem de erro é exibida, permitindo que o usuário tente novamente.

Figura 8 – Diagrama de atividades para o fluxo de login.

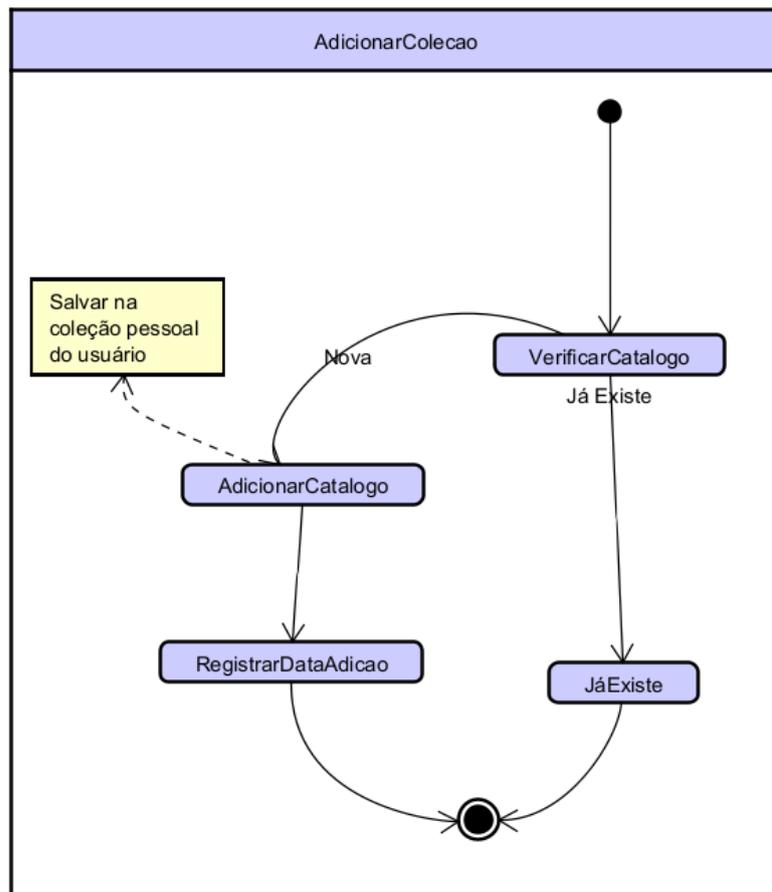


Fonte: Elaborado pela autora.

### 3.3.3 Adicionar Item ao Catálogo Pessoal

A Figura 9 apresenta o fluxo para adicionar um item ao catálogo pessoal do usuário. O processo começa com a verificação se o item já existe no catálogo. Caso seja um novo item, ele é adicionado, e a data de inclusão é registrada. Se o item já estiver presente, nenhuma ação adicional é realizada.

Figura 9 – Diagrama de atividades para adicionar itens ao catálogo pessoal.

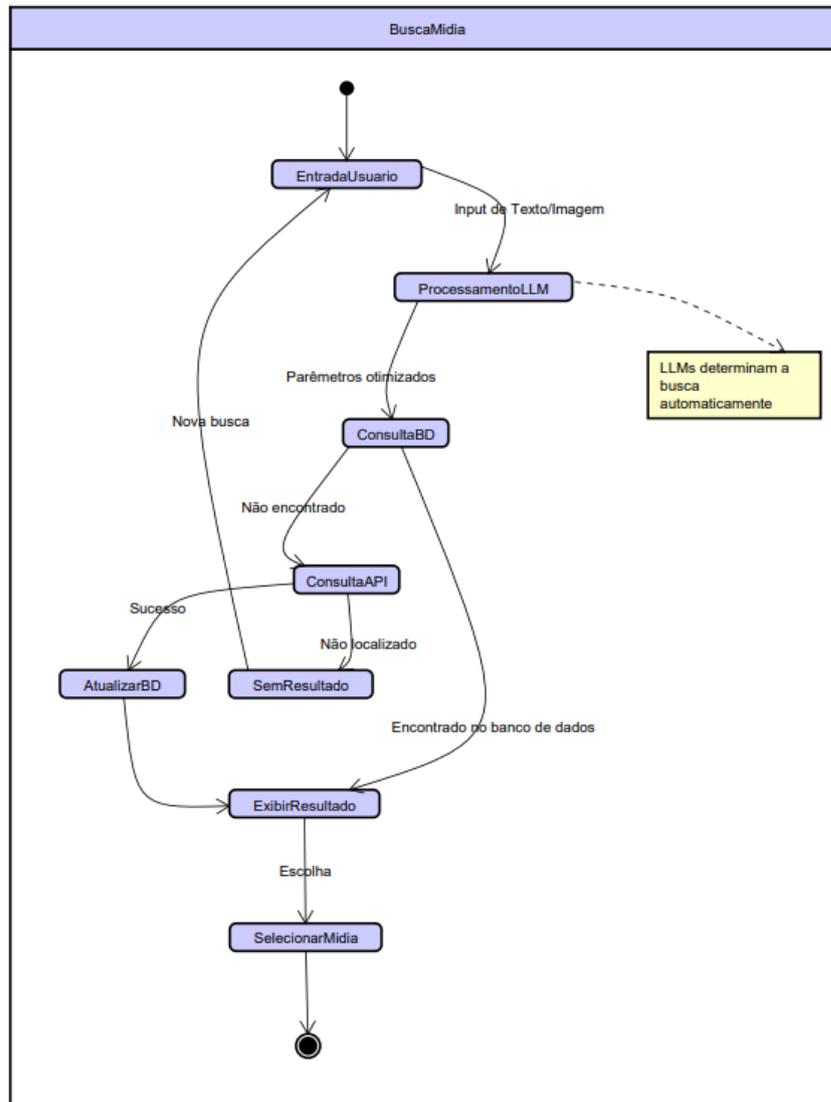


Fonte: Elaborado pela autora.

### 3.3.4 Busca de Mídia

O diagrama da Figura 10 ilustra o fluxo de busca por filmes e séries na biblioteca global. O processo começa com a entrada do usuário, que pode fornecer texto ou imagens como parâmetros de busca. A entrada é processada por um modelo LLM, que otimiza os parâmetros e realiza consultas ao banco de dados e APIs externas. Os resultados encontrados são exibidos ao usuário, que pode selecionar a mídia desejada.

Figura 10 – Diagrama de atividades para busca de mídia.

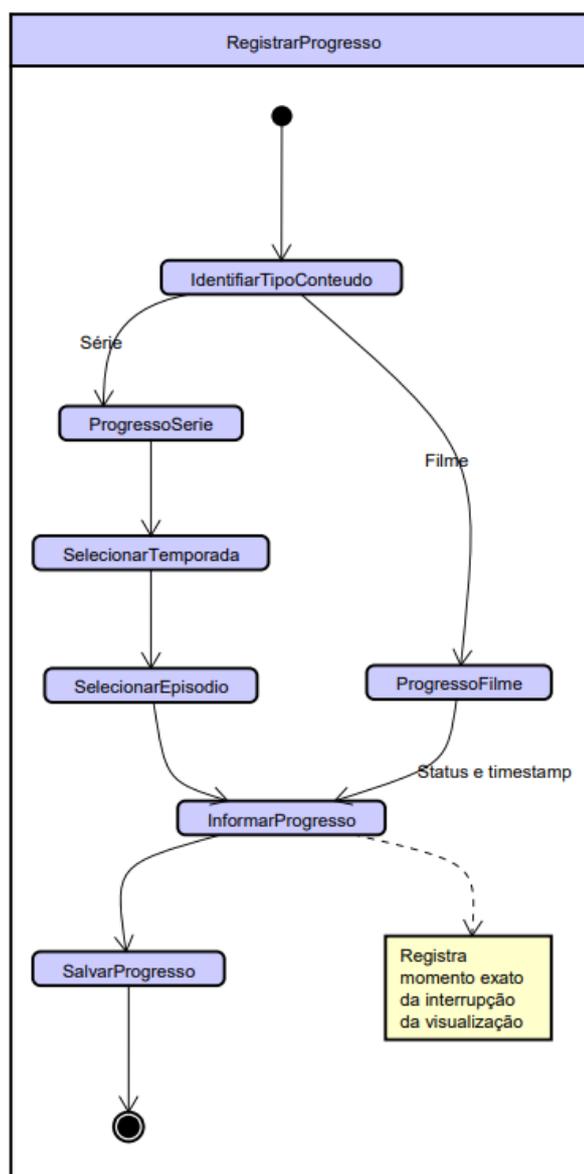


Fonte: Elaborado pela autora.

### 3.3.5 Registro de Progresso

A Figura 11 detalha o fluxo para registrar o progresso de visualização de filmes e séries. O processo identifica o tipo de conteúdo (filme ou série) e permite que o usuário registre o episódio ou temporada assistida, bem como o momento exato de interrupção da visualização.

Figura 11 – Diagrama de atividades para registro de progresso.

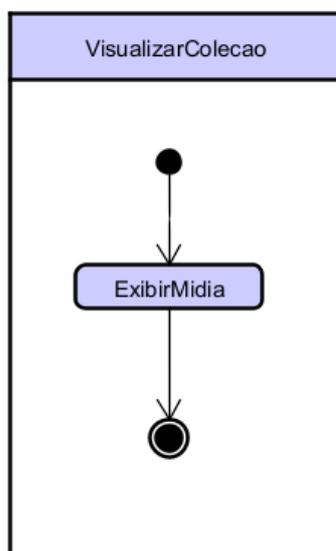


Fonte: Elaborado pela autora.

### 3.3.6 Visualizar Coleção

O diagrama mostrado na Figura 12 descreve o fluxo para visualizar a coleção pessoal do usuário. Ao acessar esta funcionalidade, o sistema exibe todos os itens adicionados pelo usuário, permitindo a navegação e interação com os detalhes de cada item.

Figura 12 – Diagrama de atividades para visualização da coleção.

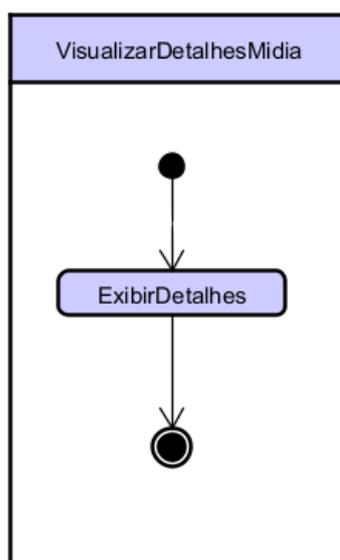


Fonte: Elaborado pela autora.

### 3.3.7 Visualizar Detalhes de Mídia

Por fim, a Figura 13 apresenta o fluxo para visualizar os detalhes de uma mídia específica. O usuário seleciona um item da coleção ou da busca, e o sistema exibe informações detalhadas sobre o título escolhido.

Figura 13 – Diagrama de atividades para visualização de detalhes de mídia.



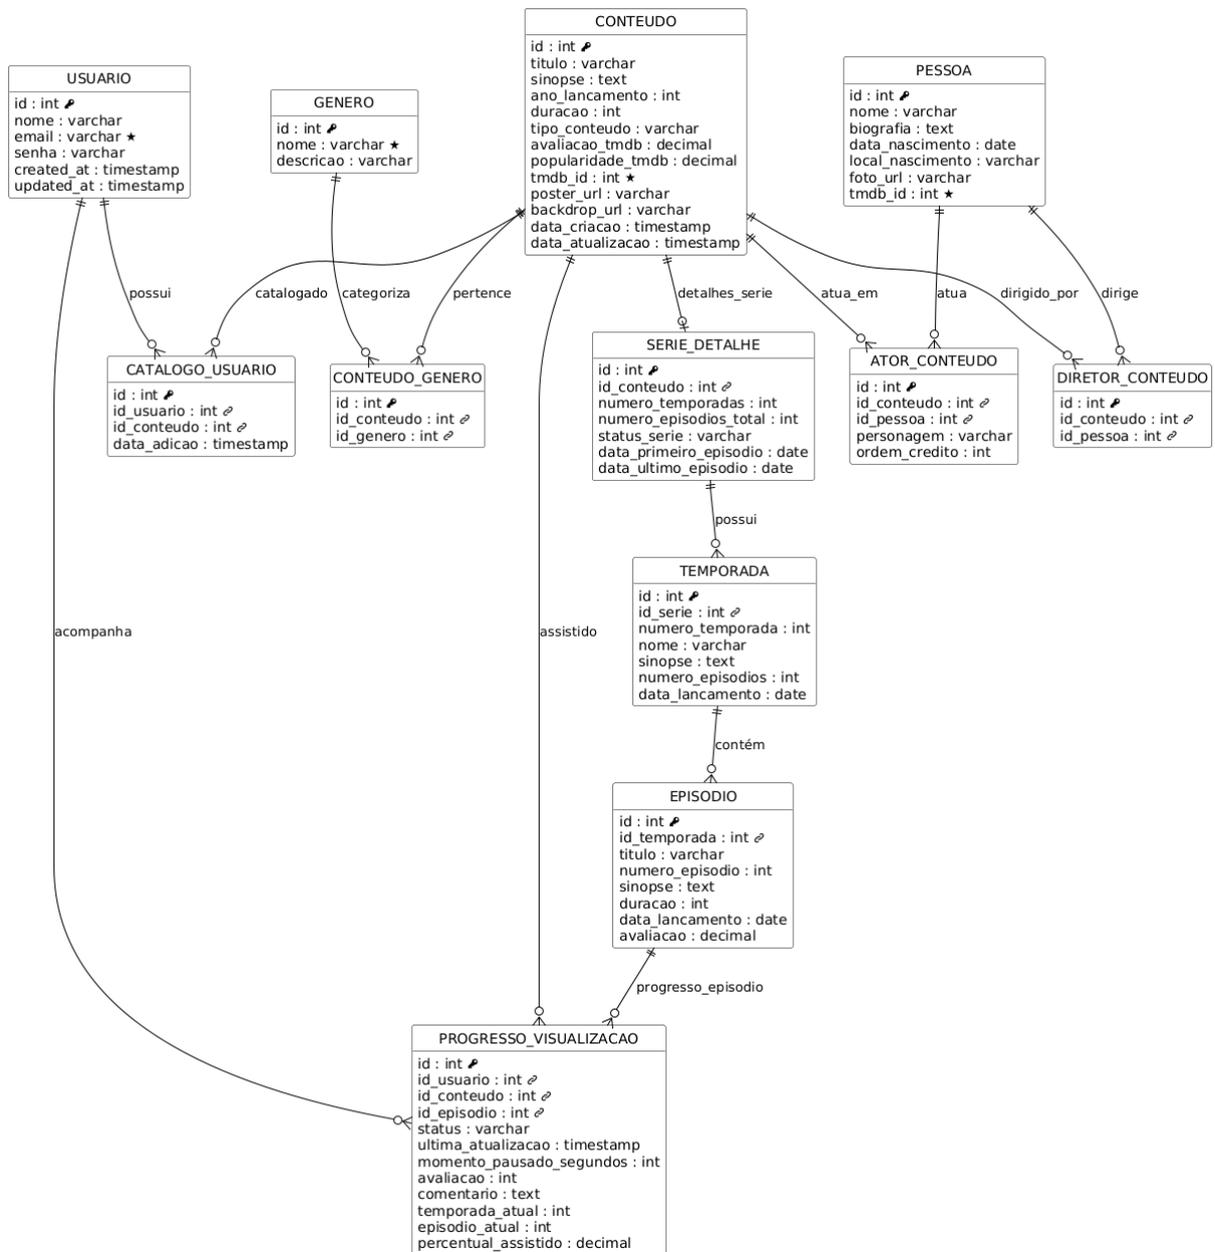
Fonte: Elaborado pela autora.

### 3.4 Modelo Entidade-Relacionamento

O modelo Entidade-Relacionamento (ER) é uma ferramenta essencial na modelagem de bancos de dados, pois permite representar de forma clara e estruturada as entidades do sistema, seus atributos e os relacionamentos entre elas.

A Figura 14 apresenta o diagrama ER do sistema, detalhando as principais entidades e suas interações.

Figura 14 – Diagrama Entidade-Relacionamento do sistema Media Tracker.



Fonte: Elaborado pela autora.

### 3.4.1 Principais Entidades

O diagrama ER do sistema foi projetado para suportar as funcionalidades descritas nos requisitos. A seguir, destacam-se as principais entidades e seus papéis no sistema:

- **USUARIO**: representa os usuários cadastrados no sistema. Contém informações como nome, e-mail, senha criptografada com *bcrypt* e *timestamps* de criação e atualização;
- **CONTEUDO**: centraliza as informações sobre filmes e séries disponíveis no sistema, incluindo título, sinopse, ano de lançamento, duração, tipo de conteúdo (filme ou série usando ENUM nativo do PostgreSQL), avaliação, popularidade e links para imagens e metadados externos (TMDB);
- **GENERO**: armazena os gêneros de filmes e séries, permitindo a categorização dos conteúdos;
- **CATALOGO\_USUARIO**: relaciona os usuários com os conteúdos adicionados ao catálogo pessoal, registrando também a data de adição;
- **PROGRESSO\_VISUALIZACAO**: monitora o progresso de visualização dos usuários, armazenando informações como status (**NAO\_ASSISTIDO**, **EM\_ANDAMENTO**, **FINALIZADO** - usando ENUM), episódio atual, temporada atual, momento pausado e percentual assistido;
- **SERIE\_DETALHE**: contém informações específicas sobre séries, como número total de temporadas e episódios;
- **TEMPORADA**: representa as temporadas de uma série, com informações como número da temporada, nome, sinopse e número de episódios;
- **EPISODIO**: detalha os episódios de uma temporada, incluindo título, número do episódio, sinopse, duração e data de lançamento;
- **PESSOA**: representa atores, diretores e outros profissionais envolvidos nos conteúdos, com informações biográficas e links para metadados externos;
- **ATOR\_CONTEUDO** e **DIRETOR\_CONTEUDO**: relacionam os conteúdos com os atores e diretores, indicando os papéis desempenhados e a ordem de crédito.

## 3.5 Protótipo do Sistema

O desenvolvimento do protótipo do sistema Media Tracker foi realizado utilizando a ferramenta *Figma*, que é amplamente reconhecida por sua capacidade de criar interfaces de usuário interativas e colaborativas. O objetivo principal do protótipo foi validar as

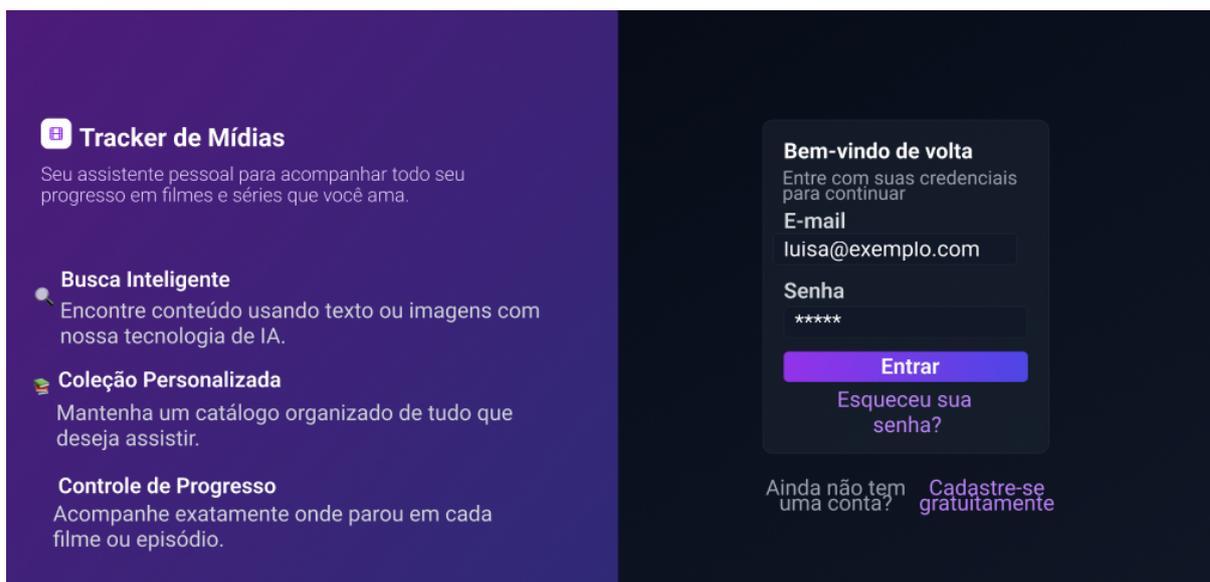
funcionalidades planejadas, bem como garantir uma experiência de usuário intuitiva e eficiente.

A seguir, são apresentadas as principais telas do protótipo, destacando suas funcionalidades e características visuais.

A tela de login, apresentada na Figura 15, é a porta de entrada para o sistema. Ela foi projetada com um design minimalista e moderno, dividido em duas seções principais, cada uma com elementos específicos que facilitam a interação do usuário. A seguir, os elementos da tela são numerados e descritos:

1. **Logotipo e nome da plataforma:** Localizado no canto superior esquerdo da tela, o logotipo da plataforma é acompanhado pelo texto *“Tracker de Mídias”*, reforçando a identidade visual do sistema.
2. **Descrição dos recursos principais:** Abaixo do logotipo, há uma breve descrição da plataforma: *“Seu assistente pessoal para acompanhar todo o seu progresso em filmes e séries que você ama.”* Essa descrição é seguida por uma lista com ícones e textos explicativos que destacam os principais recursos da plataforma:
  - **Busca Inteligente:** Permite encontrar conteúdos usando texto ou imagens com tecnologia de IA;
  - **Coleção Personalizada:** Ajuda a manter um catálogo organizado de filmes e séries;
  - **Controle de Progresso:** Permite acompanhar exatamente onde o usuário parou em cada filme ou episódio.
3. **Formulário de login:** Localizado na seção direita da tela, o formulário de login contém os seguintes elementos:
  - **Título “Bem-vindo de volta”:** Uma saudação que reforça a conexão com o usuário;
  - **Campo de e-mail:** Um campo de entrada para o usuário inserir seu endereço de e-mail;
  - **Campo de senha:** Um campo para o usuário digitar sua senha, com os caracteres ocultados por questões de segurança;
  - **Botão “Entrar”:** Um botão de ação destacado em roxo, que realiza a autenticação do usuário.
4. **Links auxiliares:** Abaixo do botão de login, há dois links para ações auxiliares:
  - **“Esqueceu sua senha?”:** Permite que o usuário recupere sua senha;

Figura 15 – Tela de login do protótipo Media Tracker.



Fonte: Elaborado pela autora.

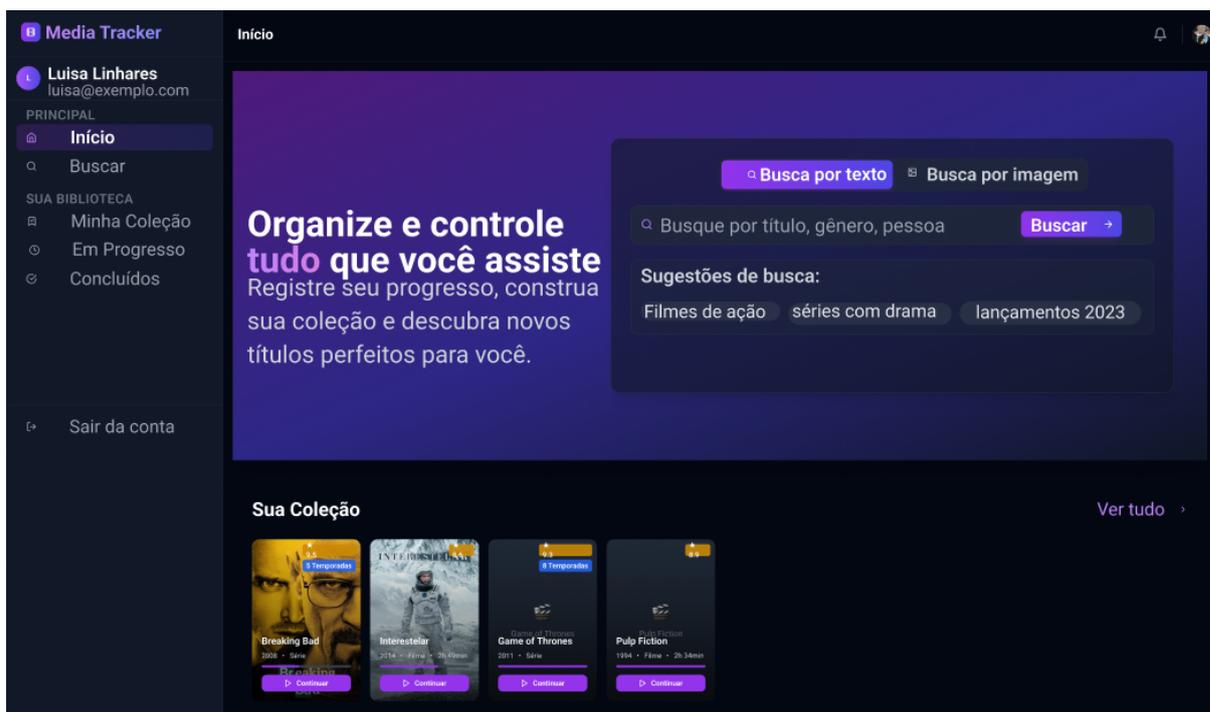
- “**Cadastre-se gratuitamente**”: Um link para criar uma nova conta, posicionado na parte inferior da tela.
5. **Design visual**: A tela utiliza um fundo dividido em duas cores: roxo na seção esquerda, destacando os recursos da plataforma, e preto na seção direita, onde está o formulário de login. O contraste entre as cores facilita a navegação e direciona a atenção do usuário para os elementos principais.

A tela inicial, ilustrada na Figura 16, apresenta ao usuário uma visão geral de sua coleção e oferece acesso rápido à funcionalidade de busca. Ela foi projetada para ser intuitiva e funcional, com elementos organizados em seções distintas. A seguir, os elementos da tela são numerados e descritos:

1. **Menu lateral**: Localizado à esquerda da tela, o menu lateral contém as seguintes opções:
  - **Início**: Redireciona o usuário para a tela inicial;
  - **Buscar**: Permite acessar a funcionalidade de busca avançada;
  - **Minha Coleção**: Exibe os itens adicionados pelo usuário à sua coleção pessoal;
  - **Em Progresso**: Mostra os filmes e séries que o usuário está assistindo no momento;
  - **Concluídos**: Lista os conteúdos que já foram finalizados;
  - **Sair da conta**: Opção para encerrar a sessão do usuário.

2. **Informações do usuário:** No topo do menu lateral, são exibidos o nome e o e-mail do usuário logado, acompanhados de um ícone de perfil.
  3. **Mensagem de boas-vindas e descrição da funcionalidade:** No centro da tela, há uma mensagem de boas-vindas com o texto: *“Organize e controle tudo que você assiste”*. Abaixo, há uma breve descrição que orienta o usuário sobre as funcionalidades da plataforma: *“Registre seu progresso, construa sua coleção e descubra novos títulos perfeitos para você.”*
  4. **Seção de busca:** À direita da mensagem de boas-vindas, encontra-se a funcionalidade de busca, composta pelos seguintes elementos:
    - **Botões de alternância:** Dois botões permitem alternar entre os modos de busca:
      - **Busca por texto:** Permite inserir palavras-chave, como título, gênero ou nome de atores;
      - **Busca por imagem:** Permite fazer upload de uma imagem para identificar conteúdos relacionados.
    - **Campo de busca:** Um campo de entrada onde o usuário pode digitar palavras-chave, acompanhado de um botão "Buscar" para iniciar a pesquisa;
    - **Sugestões de busca:** Abaixo do campo de busca, são exibidas sugestões, como *“filmes de ação”* e *“séries com drama”*, para facilitar a interação.
  5. **Seção “Sua Coleção”:** Na parte inferior da tela, a seção “Sua Coleção” exibe os itens adicionados pelo usuário, organizados em formato de cartões. Cada cartão contém:
    - **Título e tipo de conteúdo:** Exibe o nome do filme ou série e indica se é um filme ou uma série;
    - **Progresso:** Mostra o progresso do usuário, como o número de temporadas assistidas no caso de séries;
    - **Botão “Continuar”:** Permite retomar a visualização do conteúdo a partir do ponto onde foi pausado.
- No canto inferior direito, há um link *“Ver tudo”*, que redireciona o usuário para a visualização completa da coleção.
6. **Design visual:** A tela utiliza um fundo predominantemente escuro, com elementos em roxo e branco para destacar as áreas principais. O contraste entre as cores facilita a navegação e direciona a atenção do usuário para os elementos interativos.

Figura 16 – Tela inicial e funcionalidade de busca.



Fonte: Elaborado pela autora.

A tela de progresso, mostrada na Figura 17, permite que o usuário acompanhe e atualize seu progresso em filmes e séries. Ela foi projetada para ser funcional e intuitiva, com elementos organizados em seções distintas. A seguir, os elementos da tela são numerados e descritos:

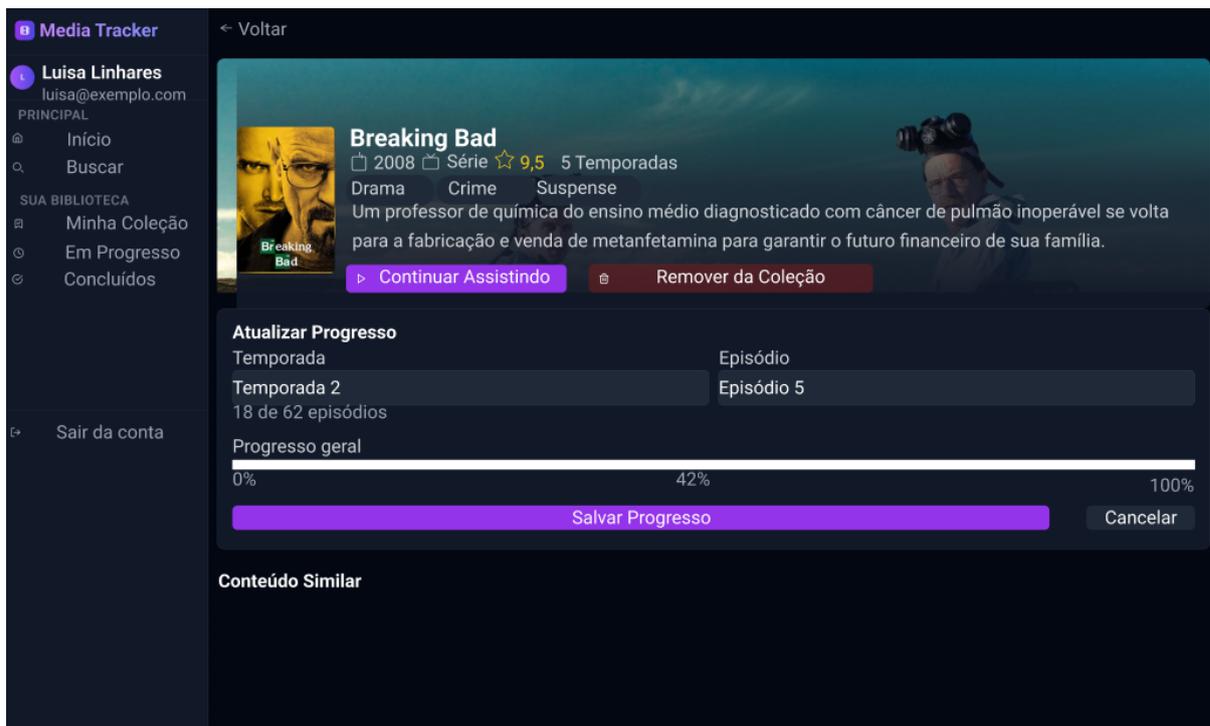
1. **Menu lateral:** Localizado à esquerda da tela, o menu lateral contém as seguintes opções:
  - **Início:** Redireciona o usuário para a tela inicial;
  - **Buscar:** Permite acessar a funcionalidade de busca avançada;
  - **Minha Coleção:** Exibe os itens adicionados pelo usuário à sua coleção pessoal;
  - **Em Progresso:** Mostra os filmes e séries que o usuário está assistindo no momento;
  - **Concluídos:** Lista os conteúdos que já foram finalizados;
  - **Sair da conta:** Opção para encerrar a sessão do usuário.
2. **Informações do conteúdo selecionado:** No topo da tela, são exibidas informações detalhadas sobre o conteúdo selecionado, incluindo:
  - **Título e tipo de conteúdo:** Nome do filme ou série (ex.: *Breaking Bad*) e indicação de que é uma série;

- **Ano de lançamento e classificação:** Ano de lançamento (2008) e classificação (9.5);
  - **Gênero e número de temporadas:** Gêneros (Drama, Suspense) e número total de temporadas (5);
  - **Sinopse:** Uma breve descrição do enredo da série;
  - **Botões de ação:**
    - “**Continuar Assistindo**”: Permite retomar a visualização do conteúdo;
    - “**Remover da Coleção**”: Remove o conteúdo da coleção pessoal do usuário.
3. **Seção “Atualizar Progresso”:** Localizada no centro da tela, essa seção permite que o usuário atualize o progresso de visualização, com os seguintes elementos:
- **Temporada:** Um campo que exibe a temporada atual (ex.: Temporada 2) e o número total de episódios assistidos (18 de 62);
  - **Episódio:** Um campo que exibe o episódio atual (ex.: Episódio 5);
  - **Barra de progresso:** Uma barra visual que indica o percentual concluído (ex.: 42%);
  - **Botões de ação:**
    - “**Salvar Progresso**”: Salva as alterações feitas pelo usuário;
    - “**Cancelar**”: Descarta as alterações realizadas.
4. **Seção “Conteúdo Similar”:** Na parte inferior da tela, são exibidas sugestões de conteúdos similares com base no histórico do usuário. Essa seção ajuda a descobrir novos filmes ou séries que possam ser do interesse do usuário.
5. **Design visual:** A tela utiliza um fundo predominantemente escuro, com elementos em roxo e branco para destacar as áreas principais. O contraste entre as cores facilita a navegação e direciona a atenção do usuário para os elementos interativos.

## 3.6 Arquitetura Geral do Sistema

A arquitetura do sistema foi projetada seguindo princípios de modularidade, separação de responsabilidades e facilidade de manutenção. Utilizando uma abordagem de **arquitetura modular**, o sistema é composto por quatro módulos principais que se comunicam por meio de APIs REST bem definidas, conforme ilustrado na Figura 18. A seguir, cada módulo é descrito e localizado na figura:

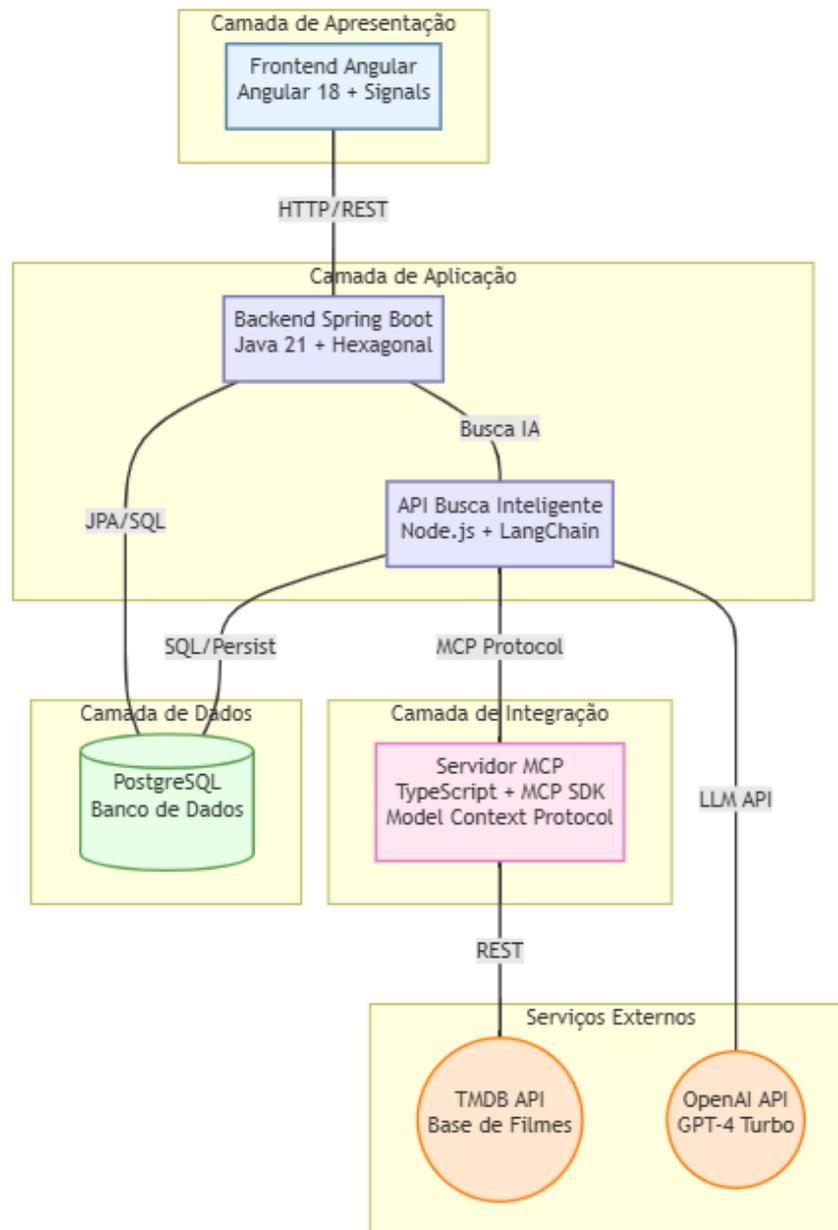
Figura 17 – Tela de progresso de visualização.



Fonte: Elaborado pela autora.

1. **Módulo Frontend Angular:** Representado na parte superior esquerda da Figura 18, este módulo corresponde à interface do usuário, desenvolvida com Angular 18. Ele utiliza componentes *standalone* e gerenciamento de estado reativo com Angular Signals, garantindo uma experiência fluida e responsiva para o usuário;
2. **Módulo Backend Spring Boot:** Localizado no centro da Figura 18, este módulo é o núcleo da aplicação, implementando a arquitetura hexagonal pragmática. Ele é responsável pela lógica de negócio, persistência de dados e segurança da aplicação, atuando como intermediário entre o frontend e os serviços externos;
3. **Módulo API de Busca Inteligente:** Posicionado à direita do *Backend* na Figura 18, este módulo é um serviço especializado em processamento de linguagem natural. Desenvolvido com Node.js e LangChain.js, ele utiliza o padrão *Simple Chains* para análise de intenção e integração com o OpenAI, permitindo buscas avançadas e personalizadas;
4. **Módulo Servidor MCP:** Representado na parte inferior direita da Figura 18, este módulo implementa o *Model Context Protocol* da Anthropic. Ele fornece uma camada de abstração padronizada para integração com a API externa do TMDB, garantindo que os dados sejam acessados e processados de forma eficiente.

Figura 18 – Arquitetura modular do sistema Media Tracker.



Fonte: Elaborado pela autora.

### 3.6.1 Fluxo de Busca Inteligente

O fluxo de uma requisição de busca inteligente demonstra a integração híbrida entre os módulos, seguindo sete etapas principais bem definidas:

1. **Recepção da Requisição:** o módulo *frontend* captura a consulta em linguagem natural do usuário (exemplo: “*filmes de ação com Tom Cruise*”) e envia via `GET /search` para o módulo *backend*;
2. **Delegação para IA:** o módulo *backend* delega a consulta para o módulo API de

Busca Inteligente através do `SearchGatewayAdapter`, utilizando `POST /api/search`;

3. **Análise de Intenção:** o módulo API de Busca Inteligente utiliza o `LLMService` que chama a OpenAI API (GPT-4-mini) para converter a linguagem natural em uma estrutura de dados padronizada (`SearchIntent`);
4. **Busca Local Prioritária:** o `SearchService` executa primeiro uma consulta no banco PostgreSQL local através do `ContentRepository.findByFilters()`, aplicando os filtros estruturados pelo LLM;
5. **Decisão de Busca Externa:** se os resultados locais forem insuficientes (menos de 3 resultados), o sistema aciona automaticamente o módulo MCP Server através da ferramenta `discover_media` para buscar dados adicionais no TMDB;
6. **Deduplicação e Persistência:** o `SearchService` combina os resultados locais e externos, remove duplicatas baseadas no `tmdb_id`, e persiste novos dados através do `ContentRepository.insertWithRelationships()`;
7. **Agregação e Resposta:** o sistema retorna os resultados híbridos (locais + externos) de forma unificada ao módulo *frontend* a partir da cadeia de comunicação inversa.

### 3.6.2 Prompts e Engenharia de Prompt

O módulo API de Busca Inteligente utiliza *prompts* estruturados para orientar o processamento de linguagem natural. O *prompt* principal para análise de intenção de busca é especificamente projetado para interpretar consultas em português é apresentado na Figura 19.

Figura 19 – Prompt de análise de intenção de busca.

```
1 Você é um assistente especializado em análise de consultas de busca
2 de filmes e séries em português.
3
4 Analise a consulta do usuário e extraia a intenção de busca estruturada.
5
6 Regras importantes:
7 1. Para mediaType:
8     - Use 'movie' para filmes
9     - Use 'tv' para séries, seriados, shows de TV
10    - Use 'all' quando não especificado ou ambíguo
11
12 2. Para genres: Use sempre nomes em português (Ação, Comédia, Drama, Terror,
13    ↪ etc.)
14
15 3. Para actors/directors: Mantenha os nomes como mencionados pelo usuário
16
17 4. Para year: Extraia ano específico se mencionado
18
19 5. Para yearRange:
20    - 'anos 90' = {min: 1990, max: 1999}
21    - 'década de 80' = {min: 1980, max: 1989}
22    - 'filmes antigos' = {min: 1900, max: 1980}
23    - 'filmes recentes' = {min: 2020, max: 2024}
24
25 6. Para query: Use apenas quando há um título específico mencionado
26
27 Exemplos:
28 - 'filmes de acao' --> mediaType: 'movie', genres: ['Acao']
29 - 'series de comedia' --> mediaType: 'tv', genres: ['Comedia']
30 - 'Matrix' --> mediaType: 'movie', query: 'Matrix'
31 - 'filmes do tom cruise' --> mediaType: 'movie', actors: ['Tom Cruise']
32 - 'algo bom para assistir' --> mediaType: 'all', query: 'algo bom para
33    ↪ assistir'
```

Fonte: Elaborado pela autora.

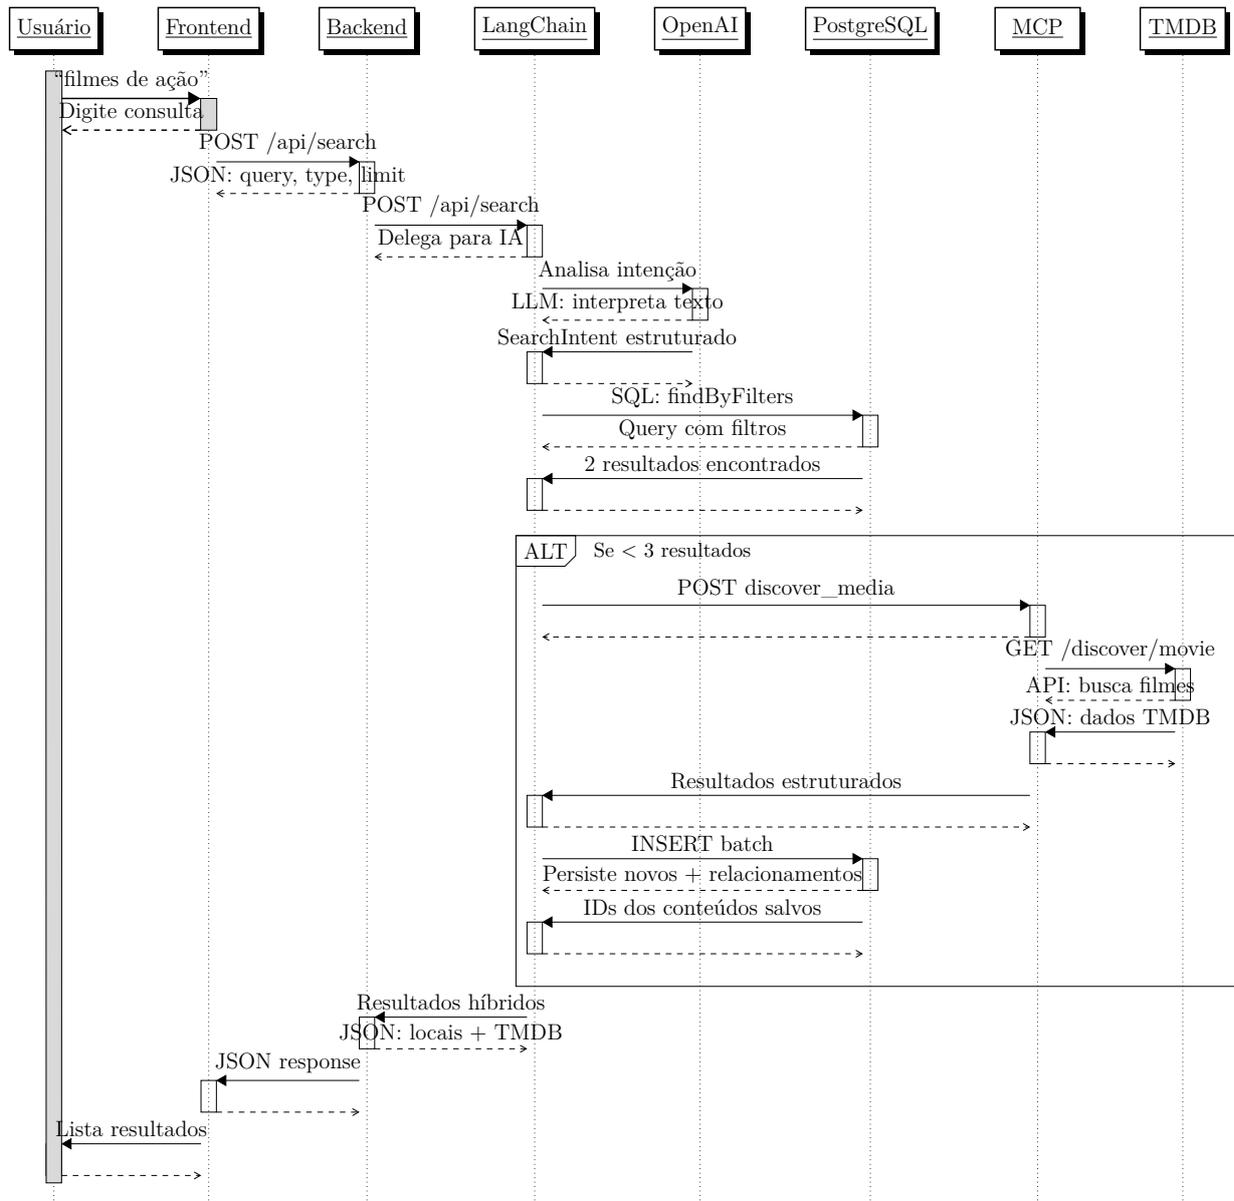
O *prompt* da Figura 19 garante que o sistema interprete corretamente consultas em português e extraia parâmetros estruturados para busca precisa no banco de dados e APIs externas.

### 3.6.3 Diagrama de Sequência do Sistema

O diagrama de sequência apresenta o fluxo completo de uma requisição de busca inteligente, demonstrando a interação entre todos os módulos do sistema conforme mostra a Figura 20

O diagrama ilustra o fluxo híbrido de busca inteligente, onde o sistema prioriza resultados locais do PostgreSQL e utiliza a API TMDb via MCP apenas quando necessário (menos de 3 resultados locais). A integração com OpenAI GPT-4 permite análise de

Figura 20 – Diagrama de sequência do fluxo de busca inteligente.



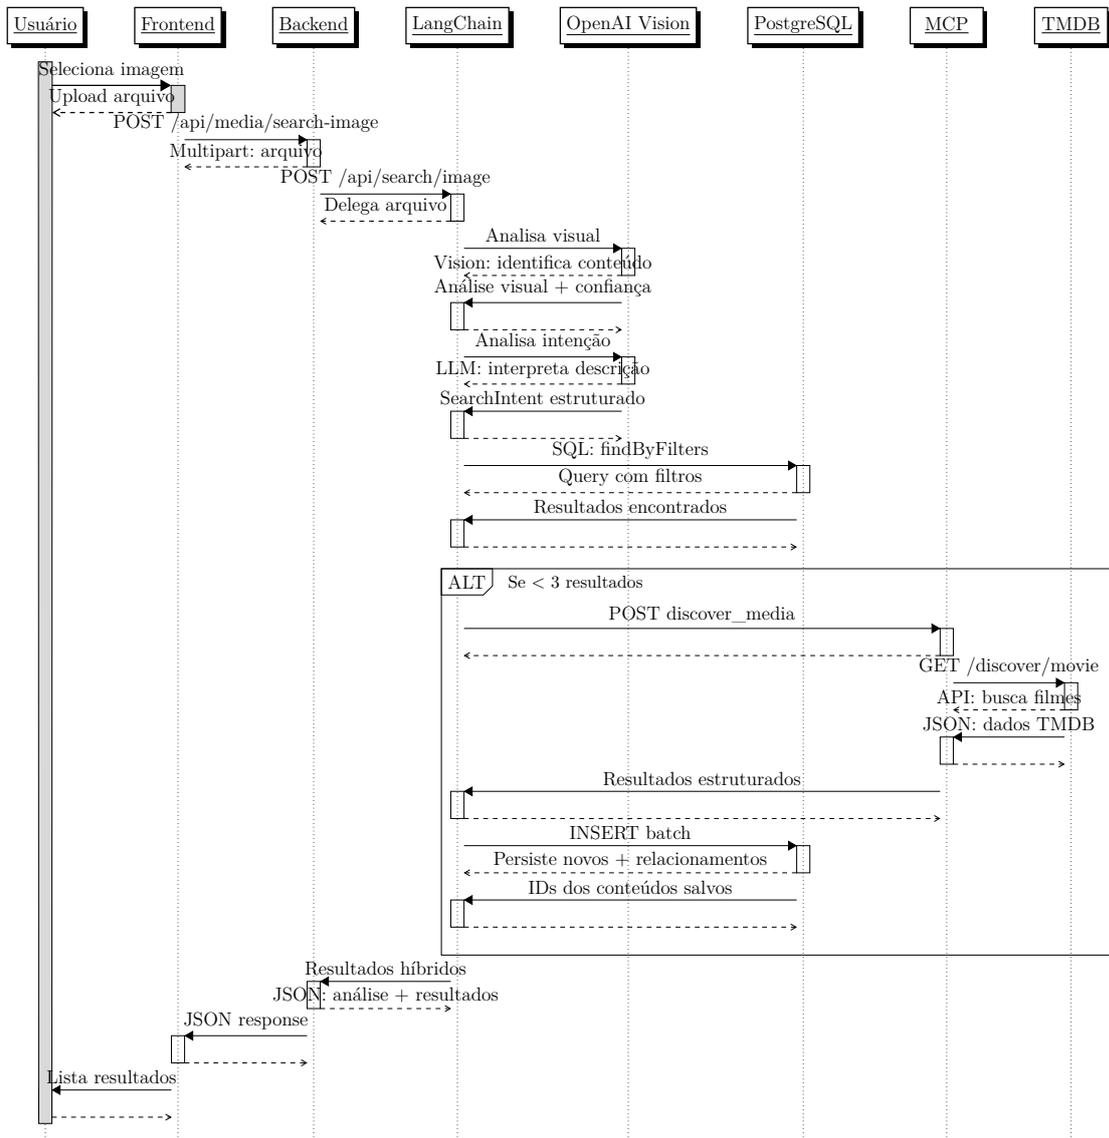
Fonte: Elaborado pela autora.

linguagem natural para estruturar as consultas dos usuários em parâmetros de busca otimizados. Importante destacar que todos os novos conteúdos descobertos via TMDB são imediatamente persistidos no banco local com suas relações completas (gêneros, atores, diretores e dados de séries), enriquecendo continuamente a base de dados local para futuras consultas.

### 3.6.4 Diagrama de Sequência - Busca por Imagem

O sistema também oferece funcionalidade de busca visual a partir do upload de imagens. O diagrama da Figura 21 demonstra o fluxo específico para busca por imagem,

Figura 21 – Diagrama de sequência do fluxo de busca por imagem.



Fonte: Elaborado pela autora.

que utiliza OpenAI Vision para identificação de conteúdo audiovisual.

A busca por imagem utiliza o modelo GPT-4-Vision da OpenAI para identificar filmes e séries a partir de cenas, cartazes ou elementos visuais presentes na imagem. O sistema converte a análise visual em uma consulta textual estruturada, que então segue o fluxo híbrido normal de busca, incluindo as mesmas etapas de deduplicação e persistência transacional de novos conteúdos TMDB no banco PostgreSQL local.

### 3.7 Desenvolvimento do Backend

O *Backend* é o componente central do sistema, implementado com Spring Boot 3.5.3 e Java 21, seguindo os princípios da arquitetura hexagonal (Portas e Adaptadores) de

forma pragmática. Este módulo é responsável por implementar integralmente os requisitos funcionais RF01, RF02, RF03 e RF04, além de atender aos requisitos não funcionais relacionados à segurança (RNF04, RNF05), desempenho (RNF01, RNF02) e manutenibilidade (RNF08, RNF09, RNF10).

A implementação da arquitetura hexagonal no projeto segue uma abordagem pragmática, conciliando os princípios arquiteturais fundamentais com adaptações práticas para atender às demandas de produtividade.

A estrutura de pacotes do *backend* segue rigorosamente os princípios da arquitetura hexagonal, organizando o código em três camadas principais bem definidas. O pacote `core` centraliza a lógica de negócio, dividindo-se em `domain` (entidades, exceções específicas do domínio) e `application` (casos de uso e portas de comunicação). As portas *inbound* definem contratos de entrada (`AuthenticationUseCase`, `CollectionUseCase`), enquanto as portas *outbound* especificam abstrações para dependências externas (`ConteudoRepository`, `SearchGateway`). O pacote `infrastructure` implementa os adaptadores concretos: *controllers* para REST, *repositories* para persistência JPA, *gateways* para integrações externas e *config* para configurações Spring. Esta organização garante que o núcleo da aplicação permaneça independente de tecnologias específicas, facilitando testes unitários e evolução arquitetural.

A seguir, são descritas as decisões arquiteturais pragmáticas:

1. **JPA nas Entidades de Domínio:** optou-se por permitir anotações JPA diretamente nas entidades para reduzir complexidade de mapeamento, mantendo a separação lógica das camadas;
2. **Lombok:** redução de código repetitivo com Lombok 1.18.38 para getters, setters e construtores;
3. **OpenAPI Generator:** utilização do *plugin* Maven OpenAPI Generator 7.13.0 para geração automática de interfaces de *controllers* e DTOs a partir da especificação `swagger.yaml`, garantindo sincronização perfeita entre documentação API e implementação de código.

A implementação de segurança utiliza Spring Security (*framework* de segurança) com tokens JWT (JSON Web Tokens), atendendo diretamente aos requisitos não funcionais RNF04 e RNF05, essa implementação de segurança utiliza filtros personalizados que garantem execução única por requisição. Os filtros interceptam todas as requisições HTTP, extraindo tokens JWT do cabeçalho de autorização e validando sua autenticidade por meio de serviços especializados de JWT. Quando um token válido é identificado, o sistema extrai as credenciais do usuário, carrega os detalhes completos via serviços de usuário e estabelece o contexto de segurança apropriado. Esta abordagem permite autenticação

stateless, onde cada requisição carrega suas próprias credenciais, eliminando a necessidade de sessões servidor e facilitando escalabilidade horizontal do sistema.

O projeto implementa uma abordagem *contract-first* através do OpenAPI Generator (ferramenta Maven para geração automática de código), onde a especificação da API serve como fonte única de verdade para definição de *endpoints*, *request/response* e validações. Esta estratégia contribui diretamente para os requisitos de manutenibilidade (RNF08, RNF09) e confiabilidade (RNF13).

- **Geração de Interfaces:** criação automática de interfaces para *controllers*, eliminando código *boilerplate* e garantindo aderência à especificação;
- **DTOs Tipados:** geração de classes de transferência de dados com validações integradas, baseadas nos esquemas da API;
- **Documentação Sincronizada:** garantia de que implementação e documentação permanecem sempre sincronizadas;
- **Validações em Tempo de Compilação:** falhas de compilação quando implementação diverge da especificação.

Com relação às configurações técnicas do *backend*, têm-se:

- **Processamento em Lote:** configuração JPA para processamento eficiente de múltiplas operações;
- **Lazy Loading com @EntityGraph:** controle de carregamento de entidades relacionadas para evitar consultas excessivas.

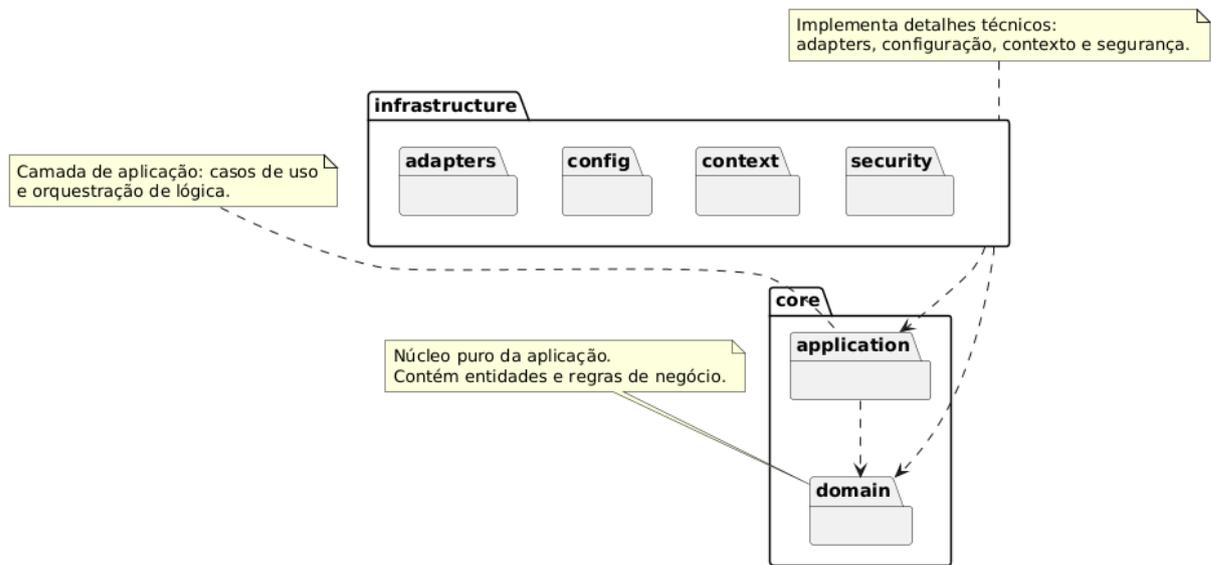
### 3.7.1 Diagrama de Pacotes

O diagrama de pacotes apresentado na Figura 22 evidencia a organização modular do backend, estruturada segundo os princípios da arquitetura hexagonal. No centro encontra-se o *core/domain*, que representa o núcleo puro da aplicação. Nessa camada estão concentradas as entidades e regras de negócio, isoladas de dependências externas, garantindo que a lógica de domínio permaneça independente de tecnologias específicas.

Acima do domínio localiza-se a camada *application*, responsável por orquestrar os casos de uso do sistema. Essa camada atua como ponte entre o domínio e o mundo externo, coordenando as interações e preservando o isolamento da lógica central.

No nível mais externo está o pacote *infrastructure*, que implementa os detalhes técnicos necessários para o funcionamento da aplicação. Essa camada é subdividida em quatro pacotes: *adapters*, que fornecem implementações concretas para comunicação com

Figura 22 – Diagrama de pacotes do backend do sistema Media Tracker



Fonte: Elaborado pela autora.

o ambiente externo; *config*, responsável pelas configurações da aplicação; *context*, que gerencia o contexto de execução; e *security*, dedicado às implementações de segurança.

A principal vantagem dessa estrutura está no isolamento do domínio, que mantém as regras de negócio protegidas contra mudanças tecnológicas. Além disso, a arquitetura favorece a testabilidade, permitindo a criação de testes unitários independentes do restante do sistema. Outro benefício é a flexibilidade, pois torna possível substituir implementações externas sem comprometer o núcleo da aplicação. Por fim, observa-se a aplicação do princípio da inversão de dependência, em que o *core* não conhece os detalhes de infraestrutura, mas pode ser utilizado por ela de maneira controlada.

As linhas tracejadas do diagrama representam as relações de dependência entre as camadas, indicando que a camada de aplicação acessa o domínio e interage com a infraestrutura por meio dos *adapters*, mantendo o devido isolamento e promovendo a separação de responsabilidades.

### 3.8 Desenvolvimento do Frontend

O módulo *frontend* foi desenvolvido com Angular 18, utilizando as funcionalidades mais modernas do *framework* para criar uma interface reativa e responsiva. Este módulo atende integralmente aos requisitos de usabilidade (RNF06, RNF07) e portabilidade (RNF11, RNF12), fornecendo a interface de usuário para todos os requisitos funcionais (RF01 a RF06).

O Angular 18 consolida e aprimora o sistema de Signals introduzido na versão anterior, oferecendo uma primitiva reativa madura e estável para gerenciamento de estado. Os Signals proporcionam reatividade granular e automática, eliminando a necessidade de detectores de mudança manuais e oferecendo performance superior comparado às abordagens tradicionais com RxJS para estados locais.

A aplicação utiliza *Signals* estrategicamente para gerenciar estados reativos, contribuindo para o atendimento dos requisitos de desempenho (RNF01) e usabilidade (RNF07):

- **Estado de autenticação:** `isAuthenticated` e `currentUser` como Signals centrais;
- **Filtros de busca:** estados de filtros que atualizam automaticamente os resultados;
- **Itens de coleção:** lista reativa de filmes e séries do usuário;
- **Preferências de interface:** configurações que persistem entre sessões.

Esta implementação permite atualizações automáticas e eficientes da interface quando os dados são modificados, sem a complexidade de gerenciamento manual de *subscriptions* ou detecção de mudanças.

O projeto utiliza componentes *standalone* do Angular 18, abordagem moderna que elimina a necessidade de `NgModules` tradicionais, simplificando a estrutura e organização do código.

Os principais componentes incluem:

- **SearchComponent:** interface unificada de busca e navegação;
- **MediaCardComponent:** exibição de cartões de mídia;
- **CollectionComponent:** gerenciamento da coleção pessoal;
- **MediaDetailsComponent:** detalhes completos de filmes e séries.

### 3.9 API de Busca Inteligente Assistida por IA

A API de *Busca Inteligente* representa o componente responsável pelo processamento de linguagem natural no sistema, seguindo o princípio de simplicidade com implementação baseada em *Simple Chains* e *Structured Output* do LangChain.js. Este módulo implementa especificamente os requisitos funcionais RF05 e RF06, atendendo também aos requisitos de desempenho (RNF01, RNF02) e confiabilidade (RNF13).

A API de Busca Inteligente foi desenvolvida seguindo o padrão *Simple Chains* do LangChain.js, priorizando simplicidade e previsibilidade sobre complexidade. Esta

abordagem linear contrasta com arquiteturas baseadas em agentes autônomos ou grafos de estado complexos, proporcionando maior confiabilidade e facilidade de manutenção.

O fluxo de processamento da API de Busca Inteligente segue cinco etapas sequenciais bem definidas:

1. **SearchController**: recebe requisições HTTP nos *endpoints* `/api/search` (busca textual) e `/api/search/image` (busca por imagem), extraindo e validando os parâmetros da consulta;
2. **LLMService**: processa a consulta através do método `analyzeIntent()`, utilizando OpenAI GPT-4-turbo para converter linguagem natural em estrutura de dados tipada e validada (`SearchIntent`);
3. **SearchService**: orquestra a busca através do método `search()`, determinando estrategicamente se deve consultar o banco PostgreSQL local, o TMDB via MCP, ou ambos simultaneamente;
4. **Busca Paralela**: executa simultaneamente consultas no PostgreSQL local através de `findByFilters()` e no módulo MCP Server através da ferramenta `discover_media` conectada à API do TMDB;
5. **DatabaseService**: agrega os resultados obtidos, realiza *deduplicação* baseada em `tmdb_id`, e persiste novos dados através do método `insertWithRelationships()`, mantendo o banco local enriquecido e atualizado.

A API utiliza o pacote `@langchain/mcp-adapters` para se comunicar com o MCP Server de forma padronizada:

A integração com o MCP utiliza o pacote `@langchain/mcp-adapters` para estabelecer comunicação padronizada com o servidor MCP. O `MCPService` instancia um cliente MCP configurado com o caminho do servidor TypeScript e variáveis de ambiente necessárias (`TMDB_API_KEY`). Durante a execução, o serviço mapeia parâmetros do `SearchIntent` para a interface esperada pela ferramenta `discover_media`, realizando conversões necessárias como `mediaType` para `media_type` e `actors` para `with_cast`. A comunicação ocorre através de invocação assíncrona da ferramenta remota, que retorna resultados estruturados do TMDB após processamento interno de conversão de gêneros, busca de pessoas e descoberta de mídia, mantendo abstração completa da complexidade da API externa.

Além da busca por texto, o sistema implementa funcionalidade de busca visual a partir do upload de imagens, utilizando o modelo GPT-4-Vision da OpenAI para identificação automática de conteúdo audiovisual. Esta funcionalidade atende ao requisito funcional RF05 e representa uma inovação significativa na interação usuário-sistema.

Conforme demonstrado na Figura 21, o fluxo de busca visual compreende as seguintes etapas principais:

1. **Upload e Validação:** O frontend valida o arquivo (JPEG, PNG, JPG) e tamanho máximo (5MB) antes do envio via FormData para o endpoint `POST /search/image`;
2. **Conversão Base64:** A API de Busca Inteligente converte a imagem recebida para formato base64, criando uma URL de dados compatível com a API OpenAI Vision;
3. **Análise com GPT-4-Vision:** O modelo analisa a imagem utilizando *prompt* especializado em identificação de filmes e séries, retornando descrição textual estruturada;
4. **Conversão para SearchIntent:** A descrição textual é convertida em um objeto SearchIntent estruturado para busca;
5. **Busca Híbrida:** A consulta derivada da imagem segue o fluxo híbrido normal de busca (local + externa se necessário).

A implementação utiliza o schema `ImageAnalysisSchema` para garantir consistência na resposta:

A análise de imagem retorna uma estrutura JSON padronizada contendo três campos principais: `query` (consulta textual gerada automaticamente em português), `confidence` (nível de confiança da análise em escala 0-1) e `details` (descrição detalhada do conteúdo identificado). Esta estrutura é validada pelo `ImageAnalysisSchema` utilizando Zod, garantindo consistência e tipagem rigorosa dos dados retornados pelo modelo GPT-4-Vision.

## 3.10 Módulo Servidor Model Context Protocol

O Módulo Servidor MCP implementa o MCP versão 1.0.5, um padrão *open-source* desenvolvido pela Anthropic para padronizar a integração entre LLMs e fontes de dados externas. Este protocolo define uma interface uniforme para que LLMs possam acessar informações estruturadas de APIs externas de forma controlada, segura e padronizada. O módulo MCP é essencial para o atendimento dos requisitos funcionais RF02, RF05 e RF06, contribuindo para os requisitos de escalabilidade (RNF02) e manutenibilidade (RNF09).

A arquitetura do MCP implementado define três componentes principais que integram de forma orquestrada: (a) **Cliente MCP:** integrado na API de Busca Inteligente através do pacote `<@langchain/mcp-adapters>` versão 0.6.0, responsável por invocar ferramentas remotas de forma transparente; (b) **Servidor MCP:** implementação personalizada em TypeScript que expõe ferramentas especializadas para consulta da API

TMDB, utilizando o `@modelcontextprotocol/sdk` versão 1.0.5; (c) **Transporte**: comunicação assíncrona via `standard input/output (stdio)` entre cliente e servidor, garantindo isolamento de processos e segurança.

A ferramenta `discover_media` representa a interface principal entre o LLM e a API TMDB, implementando lógica inteligente de tradução de parâmetros e otimização de consultas. A implementação considera as particularidades e limitações da API TMDB para fornecer resultados consistentes e relevantes. A ferramenta `discover_media` é implementada através de dois *handlers* principais que gerenciam o ciclo de vida da ferramenta MCP. O primeiro *handler* (`<ListToolsRequestSchema>`) registra a ferramenta no servidor, definindo seu esquema de entrada com validação rigorosa de tipos de mídia (movie/tv/all), arrays de gêneros e atores, e parâmetros temporais. O segundo *handler* (`CallToolRequestSchema`) processa as invocações reais, implementando lógica inteligente de descoberta que inclui: (1) carregamento dinâmico de cache de gêneros da API TMDB, (2) estratégias específicas para busca de séries por ator (utilizando endpoint `/person/{id}/tv_credits`), (3) conversão automática de nomes de gêneros em português para IDs TMDB, e (4) orquestração de chamadas otimizadas à API externa. O processamento inclui validação de parâmetros, deduplicação de resultados e enriquecimento de dados com informações detalhadas de elenco, temporadas e episódios, retornando estruturas JSON padronizadas para consumo pelo cliente LangChain.

O MCP Server atua como uma camada de abstração inteligente:

- **Simplificação**: cliente usa parâmetros simples (nomes) ao invés de IDs complexos;
- **Validação**: verifica compatibilidade de parâmetros antes de chamar TMDB;
- **Estratégias**: escolhe o endpoint TMDB mais adequado para cada consulta;
- **Portabilidade**: pode trocar TMDB por outra API sem afetar clientes.

## 3.11 Banco de Dados e Migrações

O sistema utiliza PostgreSQL 15 (sistema de gerenciamento de banco de dados relacional) com tipos ENUM nativos integrados com enumerações Java correspondentes, garantindo validação tanto no banco de dados quanto na camada de aplicação. Esta implementação atende aos requisitos de confiabilidade (RNF13) e manutenibilidade (RNF08). Os principais tipos incluem classificação de conteúdo (filmes e séries) para RF02 e status de visualização (não assistido, em andamento, finalizado) para RF04.

O controle de versão do *schema* é gerenciado pelo Flyway (ferramenta de migração de banco de dados), garantindo evolução controlada e rastreável da estrutura do banco de dados:

- `V1__Initial_schema.sql`: schema inicial completo com todas as entidades principais, tipos ENUM e relacionamentos básicos;
- `V2__Add_percentual_column.sql`: adição da coluna `percentual_assistido` na tabela `progresso_visualizacao`;
- `V3__Add_tmdb_integration.sql`: integração com TMDB através das colunas `tmdb_id` e `popularidade_tmdb`;
- `V4__Fix_status_enum.sql`: correção e padronização do tipo ENUM `<status_visualizacao>`;
- `V5__Add_unique_constraints.sql`: implementação de *constraints* únicos para integridade referencial;
- `V6__Add_performance_indexes.sql`: criação de índices otimizados para consultas de performance;
- `V7__Add_search_function.sql`: Implementação da função `f_unaccent` para busca textual sem acentos.

Essa abordagem incremental permite que atualizações de schema sejam aplicadas automaticamente em diferentes ambientes (desenvolvimento, teste, produção) de forma consistente e auditável, mantendo histórico completo das mudanças estruturais do banco de dados.

## 3.12 DevOps e Infraestrutura

Todos os serviços são containerizados usando Docker (plataforma de containerização), atendendo diretamente aos requisitos de portabilidade (RNF14), escalabilidade (RNF02) e disponibilidade (RNF03):

A containerização do *backend* utiliza estratégia de *build* em estágios. O primeiro estágio utiliza imagem Maven (ferramenta de gerenciamento de projetos Java) com OpenJDK (implementação *open-source* do Java) para compilação, executando cache de dependências antes da cópia do código fonte, maximizando reutilização de camadas Docker. O segundo estágio utiliza imagem runtime JRE Alpine (Java Runtime Environment em distribuição Linux minimalista), significativamente menor, copiando apenas o JAR (Java Archive) compilado do estágio anterior. A configuração inclui otimizações JVM (Java Virtual Machine), usuário não-root para segurança, health checks automáticos via endpoints de saúde, e variáveis de ambiente para configurações específicas de produção.

O sistema é executado em ambiente containerizado, facilitando o deploy em diferentes plataformas. Para demonstração e testes acadêmicos, utiliza-se Azure Container

Apps (plataforma de containers gerenciada) com configuração simplificada de recursos limitados, adequados ao escopo educacional do projeto.

O projeto utiliza *GitHub Actions* (plataforma de CI/CD integrada ao *GitHub*) para automação básica de testes e build, executando validações automatizadas dos componentes Java e Node.js (runtime JavaScript) a cada commit na branch principal. Esta integração garante a qualidade do código ao longo do desenvolvimento.

### 3.13 Tecnologias Utilizadas

A Tabela 5 apresenta todas as tecnologias utilizadas no projeto com suas versões específicas.

O desenvolvimento do sistema *Media Tracker* foi realizado utilizando uma estação de trabalho com as seguintes especificações: processador AMD Ryzen 7 3700X (8 núcleos, 16 threads), 32GB de memória RAM DDR4, armazenamento SSD NVMe de 1TB, e placa gráfica NVIDIA GeForce RTX 2070 Super. Essa configuração proporcionou desempenho adequado para o desenvolvimento simultâneo de múltiplos módulos do sistema, compilação eficiente dos projetos Java e Node.js, execução de containers Docker, e testes de integração entre os serviços.

Tabela 5 – Tecnologias utilizadas no projeto - Versões implementadas.

Tecnologia	Versão	Descrição
Angular	18.2.0	<i>Framework frontend</i> com <i>Signals</i> e componentes <i>standalone</i>
TypeScript	5.2+	Linguagem tipada para <i>frontend</i> e servidor MCP
TailwindCSS	3.4.17	<i>Framework CSS utility-first</i>
Lucide Angular	0.525.0	Biblioteca de ícones otimizada
Java	21	Linguagem para <i>backend</i> com <i>virtual threads</i>
Spring Boot	3.5.3	<i>Framework</i> Java empresarial
Spring Security	6.3+	Segurança e autenticação
JWT (jjwt)	0.12.3	<i>Tokens</i> de autenticação
PostgreSQL	15	Banco de dados relacional
Node.js	20 LTS	<i>Runtime</i> para serviço de IA
LangChain.js	0.3.29	<i>Framework</i> para LLM
OpenAI GPT	4-turbo	Modelo de linguagem
MCP SDK	1.0.5	<i>Model Context Protocol</i>
Express.js	4.21.1	<i>Framework web</i> Node.js
Express Rate Limit	7.4.1	Limitação de taxa de requisições
Docker	24+	Containerização
Docker Compose	2.20+	Orquestração local
Azure Container Apps	-	Plataforma de hospedagem
GitHub Actions	-	CI/CD automatizado
Maven	3.9+	<i>Build</i> Java
NPM	10+	Gerenciador de pacotes JS
OpenAPI Generator	7.13.0	Geração automática de código a partir de especificação <i>swagger</i>
Playwright	1.54.1	Testes <i>end-to-end</i>
JUnit	5	Testes unitários Java
Jest	29.7	Testes unitários JavaScript

### 3.14 Considerações finais

O desenvolvimento do sistema *Media Tracker* demonstrou a aplicação bem-sucedida de tecnologias modernas e padrões arquiteturais consolidados no contexto acadêmico, atendendo integralmente aos requisitos funcionais e não funcionais estabelecidos. A implementação dos seis requisitos funcionais foi garantida por meio da arquitetura modular proposta. O requisito RF01, referente ao catálogo pessoal, foi concretizado por meio de serviços especializados de coleção no *backend*, que se conectam a entidades de domínio para catálogo de usuário e à interface de coleção no *frontend*, oferecendo operações completas de inclusão, edição e exclusão, além de categorização personalizada. Já o RF02, ligado à busca com filtros, foi viabilizado pela integração entre controladores de mídia no *backend*, base de dados externa via servidor MCP e um componente unificado de busca no *frontend*, permitindo consultas por título, gênero, ano e número de temporadas, devidamente documentadas em API.

O requisito RF03, relacionado à adição de mídia, foi realizado por meio de endpoints RESTful com validação de duplicatas, integrando *backend* e frontend de modo a facilitar a inclusão de itens do catálogo global à coleção pessoal. O registro de progresso, descrito no RF04, contou com a definição de entidades de domínio específicas que utilizam tipos ENUM híbridos para controlar o status detalhado por episódio ou temporada, além de percentuais de visualização, tudo centralizado em serviços de progresso. No caso do RF05, que trata da busca visual, a solução foi a criação de um módulo de busca inteligente integrado a modelos de visão computacional, permitindo o envio de imagens por meio de endpoints especializados e a conversão da análise visual em consultas estruturadas. Finalmente, o RF06, que aborda a busca textual com inteligência artificial, foi alcançado por meio de serviços de processamento de linguagem natural em português, utilizando *frameworks* modernos de IA capazes de transformar descrições em buscas híbridas (locais e externas), com persistência automática dos resultados.

Em relação aos quatorze requisitos não funcionais, estes orientaram diretamente as principais escolhas arquiteturais e tecnológicas do projeto. O desempenho, contemplado em RNF01, RNF02 e RNF03, foi assegurado com uso de containerização para escalabilidade, consultas otimizadas no banco com índices, cache para resultados externos e monitoramento automatizado da saúde dos serviços, garantindo disponibilidade contínua. No aspecto de segurança, abordado por RNF04 e RNF05, foram aplicados mecanismos de autenticação com JWT, criptografia de senhas utilizando bcrypt, controle de acesso via Spring Security e middleware de limitação de requisições, assegurando proteção e restrição adequada às funcionalidades personalizadas.

A usabilidade, destacada em RNF06 e RNF07, foi atendida com design responsivo em TailwindCSS, componentes modulares no Angular, sistema de notificações reativas com Angular Signals e interface intuitiva em português, proporcionando experiência de navegação eficiente. Já a manutenibilidade, associada a RNF08, RNF09 e RNF10, foi alcançada por meio de arquitetura hexagonal pragmática, modularidade clara, geração de código automática via OpenAPI Generator e ampla cobertura de testes com JUnit 5 e Jest. Quanto à portabilidade, descrita em RNF11, RNF12 e RNF14, a solução foi garantida pela compatibilidade cross-browser, design totalmente responsivo e containerização Docker, permitindo implantação em diferentes ambientes. Por fim, a confiabilidade, relacionada ao RNF13, foi assegurada com tratamento centralizado de exceções, logs estruturados em todos os módulos, aplicação de padrões de resiliência em integrações externas e feedback claro ao usuário.

Complementarmente, o controle evolutivo do banco de dados foi estabelecido por meio do Flyway, a validação foi reforçada pela utilização de tipos ENUM híbridos entre PostgreSQL e Java, e a implementação da API de Busca Inteligente ocorreu através do LangChain.js, com padrões *Simple Chains*. A incorporação do Model Context Protocol por

meio do módulo MCP Server evidencia, ainda, a capacidade da solução em integrar padrões emergentes da indústria de IA. A documentação técnica detalhada, aliada ao atendimento integral de todos os requisitos funcionais e não funcionais, garante que o sistema se configure como uma referência válida para trabalhos futuros, mantendo qualidade e rigor científico esperados em um Trabalho de Conclusão de Curso em Engenharia de Computação.

## 4 Resultados

Neste capítulo são apresentados os resultados obtidos com o desenvolvimento da plataforma Media Tracker. Este capítulo tem como objetivo detalhar as funcionalidades implementadas, os recursos disponibilizados e a experiência proporcionada aos usuários com base nos requisitos previamente definidos e nas tecnologias empregadas.

A partir de uma abordagem centrada no usuário, o sistema foi projetado para oferecer uma interface intuitiva e responsiva, integrando funcionalidades avançadas como busca visual e textual por meio de inteligência artificial. Os resultados aqui descritos incluem a análise das principais telas do protótipo, os fluxos de interação entre os usuários e o sistema. Por fim, são apresentados os testes realizados para garantir a usabilidade, desempenho e confiabilidade da plataforma, demonstrando como o Media Tracker atende às necessidades identificadas no cenário atual de consumo de mídia digital.

Este capítulo está estruturado da seguinte maneira: na Seção 4.1 apresenta-se a tela de login do sistema, descrevendo seus elementos constituintes e funcionalidades. A Seção 4.2 expõe a tela inicial e as sessões de destaque, contemplando indicadores estatísticos e conteúdos recomendados ao usuário. Na Seção 4.3 descreve-se a tela de busca, abordando os filtros disponíveis, os modos de exibição e as formas de interação com as obras. A Seção 4.4 trata da tela de coleção, destinada ao gerenciamento dos itens salvos pelo usuário. A Seção 4.5 aborda a tela de progresso, que possibilita o acompanhamento e a atualização do status de visualização de filmes e séries. Em seguida, a Seção 4.6 apresenta a análise da pesquisa realizada com usuários de teste, contemplando o perfil dos participantes, a avaliação das funcionalidades e a experiência geral de uso. Por fim, a Seção 4.7 reúne as considerações finais do capítulo, sintetizando os principais resultados obtidos.

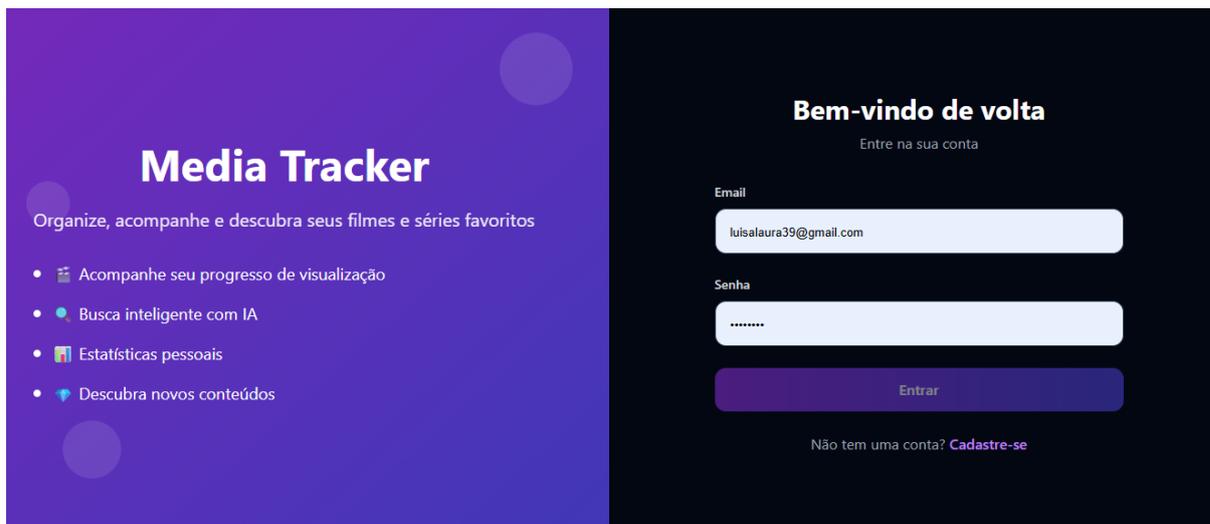
### 4.1 Tela de Login

A Figura 23 apresenta a tela de login do sistema Media Tracker, que é a interface inicial para acesso à plataforma. O design foi elaborado com foco na simplicidade e na usabilidade, seguindo boas práticas de interface para sistemas Web.

No lado esquerdo da tela, encontram-se informações sobre os principais recursos oferecidos pela plataforma, como:

- acompanhamento do progresso de visualização de filmes e séries;
- busca inteligente utilizando inteligência artificial;
- exibição de estatísticas personalizadas;

Figura 23 – Tela de Login do sistema Media Tracker.



Fonte: Elaborado pela autora.

- descoberta de novos conteúdos relevantes.

No lado direito, está localizado o formulário de autenticação, composto pelos seguintes elementos:

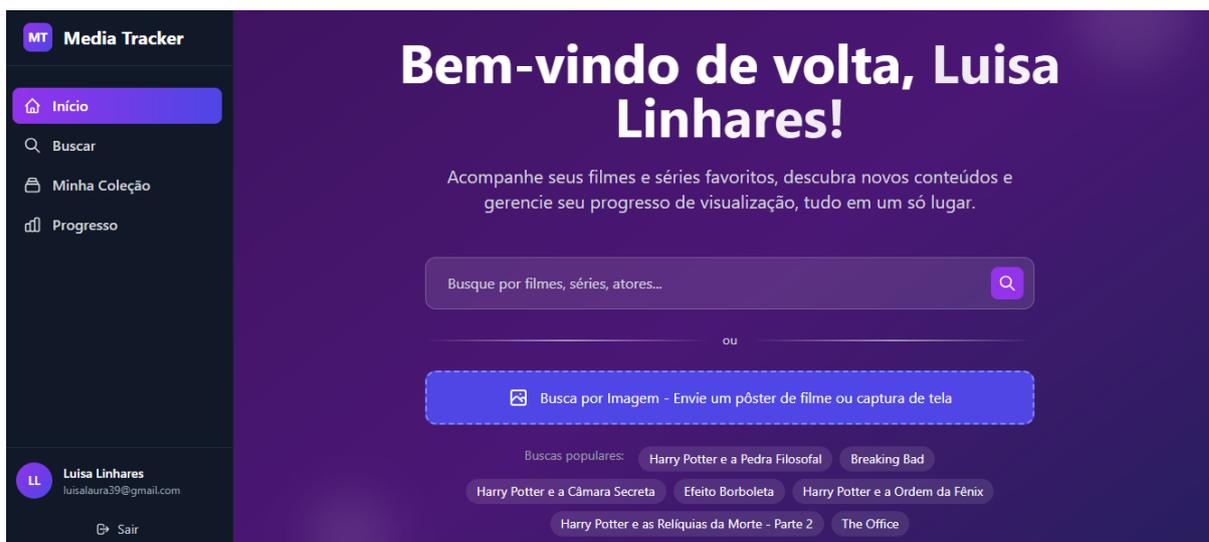
- campo para inserção do e-mail do usuário;
- campo para inserção da senha;
- botão de ação **Entrar**, que realiza a autenticação do usuário;
- link de redirecionamento para o cadastro de novos usuários, que está posicionado abaixo do botão de login.

A paleta de cores foi escolhida para garantir contraste adequado e facilitar a leitura, enquanto o layout responsivo assegura que a interface seja acessível em diferentes dispositivos. A organização dos elementos na tela visa oferecer uma experiência intuitiva e eficiente para o usuário.

## 4.2 Tela de Início e Sessões de Destaque

A Figura 24 apresenta a tela de busca da aplicação *Media Tracker*, interface responsável por centralizar os mecanismos de pesquisa de conteúdo. Nessa tela, o usuário é recepcionado com uma mensagem personalizada de boas-vindas, seguida de uma breve descrição sobre as principais funcionalidades da plataforma, que incluem: o acompanhamento de filmes e séries, a descoberta de novos títulos e o gerenciamento do progresso

Figura 24 – Tela de início do sistema Media Tracker.



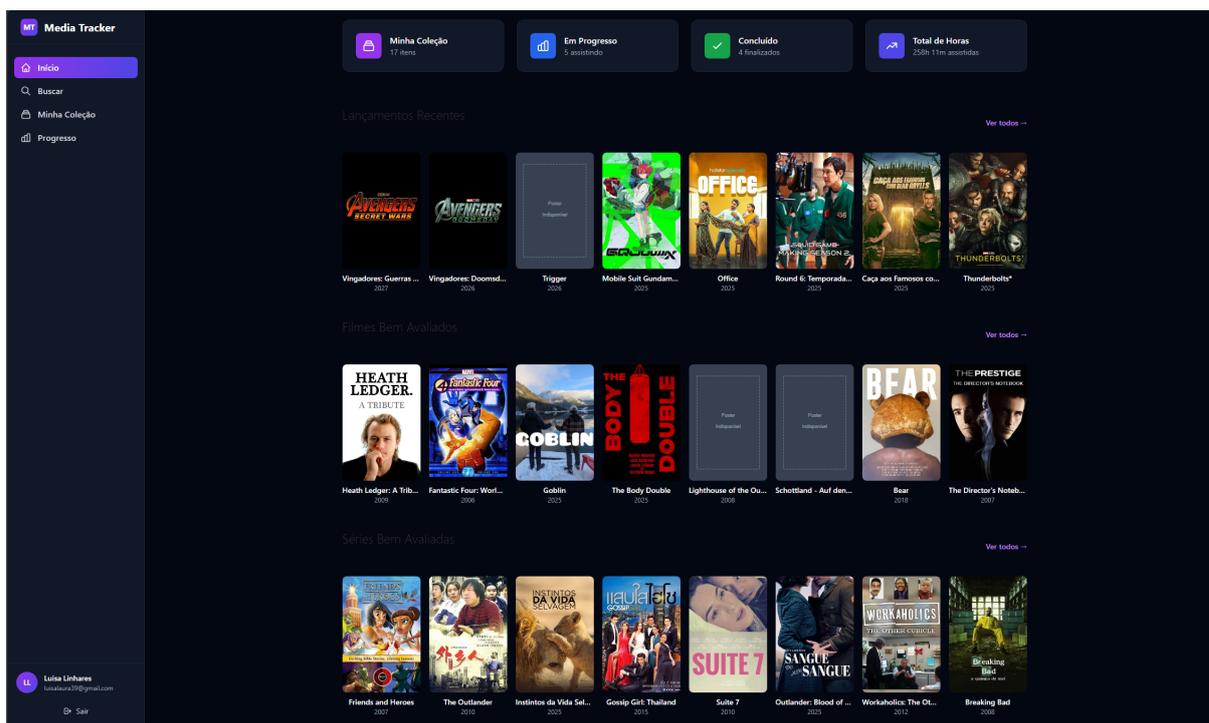
Fonte: Elaborado pela autora.

de visualização. A área central da interface oferece dois modos de busca. O primeiro é a **Busca Textual**, que é realizada por meio de um campo de entrada em que o usuário pode digitar palavras-chave como títulos de filmes, séries, nomes de atores ou outros termos relevantes, acionando a pesquisa por meio do ícone de lupa localizado à direita do campo.

O segundo modo é a **Busca por Imagem**, que permite ao usuário enviar arquivos contendo pôsteres, capturas de tela ou imagens relacionadas ao conteúdo desejado, que também se encontra na área central da Figura 24 logo abaixo da **Busca Textual**. Essa funcionalidade utiliza recursos de reconhecimento visual para identificar o título correspondente, oferecendo uma alternativa prática para situações em que o usuário não se recorda do nome exato da obra. Abaixo dos campos de busca, a interface apresenta a seção de **Buscas Populares**, que exibe uma lista dinâmica dos títulos mais frequentemente salvos nas coleções dos usuários do aplicativo Media Tracker. Essa funcionalidade serve como uma recomendação baseada em tendências da comunidade, permitindo que o usuário descubra conteúdos amplamente apreciados. Os títulos são apresentados em forma de botões clicáveis, facilitando o acesso rápido às informações detalhadas de cada obra.

Do lado esquerdo da Figura 24, a interface apresenta um menu lateral fixo, que fornece acesso rápido às principais funcionalidades da aplicação. Esse menu contém as opções **Início**, **Buscar**, **Minha Coleção** e **Progresso**, cada uma representada por ícones intuitivos e texto descritivo. Na parte inferior, estão as informações do perfil do usuário, incluindo nome, endereço de e-mail e a opção de encerrar a sessão. A presença desse menu garante uma navegação consistente e ágil por todas as seções do sistema, mantendo o acesso às funcionalidades essenciais independentemente da tela em exibição.

Figura 25 – Tela de início do sistema Media Tracker.



Fonte: Elaborado pela autora.

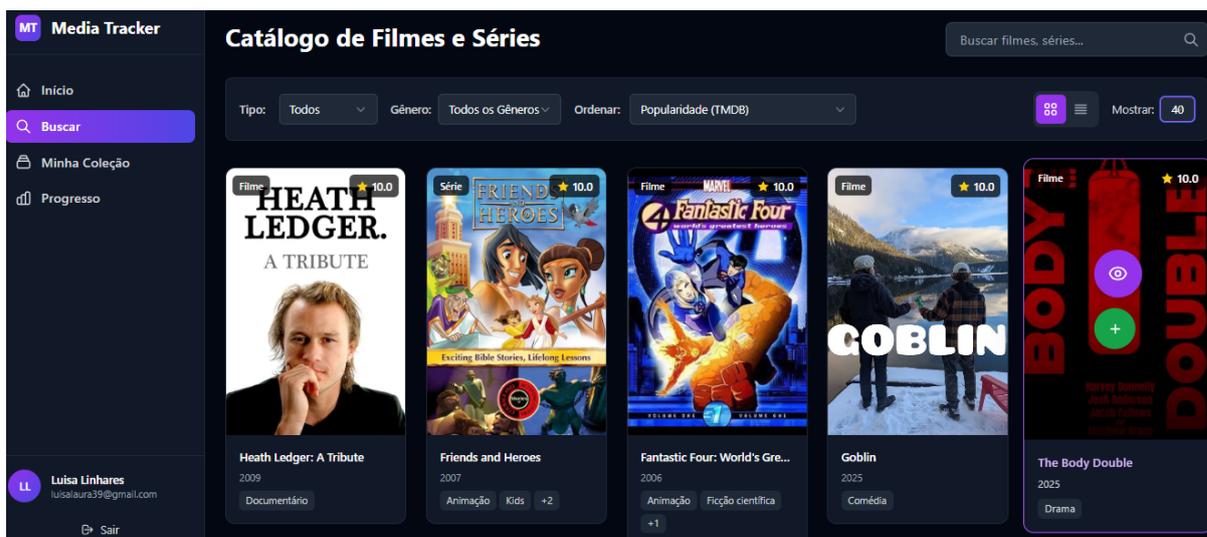
A Figura 25 apresenta a tela inicial do sistema Media Tracker, que reúne diversas seções destinadas a facilitar a navegação e a descoberta de novos conteúdos, além de fornecer um panorama geral do perfil do usuário. Na parte superior da tela, são exibidos indicadores estatísticos que resumem o histórico de consumo do usuário, incluindo:

- Minha Coleção:** total de itens salvos pelo usuário;
- Em Progresso:** quantidade de obras que o usuário está assistindo no momento;
- Concluído:** número de filmes e séries finalizados;
- Total de Horas:** tempo total de visualização acumulado.

Na parte inferior da Figura 25, a interface apresenta três seções principais organizadas em formato de galerias horizontais:

- Lançamentos Recentes:** exibe os títulos mais recentemente adicionados ao banco de dados do TMDb, independente de sua data de lançamento original. Essa seção é composta por filmes e séries, apresentados com seus respectivos cartazes, títulos e anos de lançamento;
- Filmes Bem Avaliados:** apresenta uma seleção de filmes com as maiores avaliações médias atribuídas por usuários do TMDb. Essa seção prioriza a qualidade percebida pelo público, exibindo os títulos mais bem avaliados acompanhados de seus cartazes, títulos e anos de lançamento;

Figura 26 – Tela de Busca com filtros avançados no sistema Media Tracker.



Fonte: Elaborado pela autora.

- c) **Séries Bem Avaliadas:** similar à seção de filmes, essa galeria exibe as séries com as maiores notas médias no TMDb. Os títulos são apresentados com seus cartazes, títulos e anos de lançamento, permitindo ao usuário identificar rapidamente as produções mais bem avaliadas. O botão **Ver todos** redireciona para a **Tela de Busca**, onde é possível explorar o catálogo completo de filmes e séries.

Essa tela foi projetada para oferecer uma experiência intuitiva e centralizada, combinando estatísticas do perfil do usuário com ferramentas de descoberta de novos conteúdos.

## 4.3 Tela de Busca

A Figura 26 apresenta a tela de busca do sistema Media Tracker, projetada para oferecer uma experiência de pesquisa completa e personalizada. Essa interface permite ao usuário explorar o catálogo de filmes e séries utilizando filtros avançados e opções de ordenação, garantindo uma navegação eficiente e prática.

### 4.3.1 Filtros de Pesquisa

Na parte superior da tela da Figura 26, encontram-se os filtros que permitem refinar os resultados da busca:

- a) **Filtro de Tipo:** oferece as opções **Todos**, **Filmes** e **Séries**, permitindo que o usuário selecione o tipo de conteúdo que deseja visualizar;

- b) **Filtro de Gênero:** apresenta uma lista de gêneros, como **Ação**, **Comédia**, **Drama**, *Ficção Científica*, entre outros. Essa funcionalidade possibilita a filtragem de conteúdos com base em preferências específicas do usuário;
- c) **Filtro de Ordenação:** permite organizar os resultados de acordo com critérios como **Popularidade (TMDb)**, **Mais Recentes (Ano de Lançamento)**, **Adicionados Recentemente (ao Sistema)**, **Título A-Z** e **Avaliação**. Esse recurso facilita a descoberta de conteúdos relevantes com base em diferentes prioridades.

Ainda, na parte superior direita da tela na Figura 26, encontra-se o campo de **Busca Textual**, onde o usuário pode inserir palavras-chave relacionadas a filmes, séries ou atores.

### 4.3.2 Exibição dos Resultados

Os resultados da busca são exibidos em formato de galeria, com cartazes, títulos, anos de lançamento e informações adicionais como gêneros logo abaixo da área do **Filtro de Pesquisa** na Figura 26. A interface também oferece duas opções de visualização:

- a) **Modo de Grade:** exibe os resultados em uma grade compacta, ideal para visualizar vários itens simultaneamente;
- b) **Modo de Lista:** apresenta os resultados em uma lista detalhada, com informações adicionais sobre cada item.

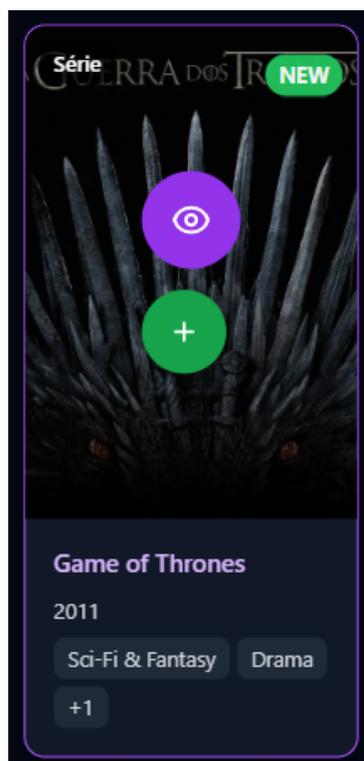
O botão **Mostrar** permite ajustar a quantidade de itens exibidos por página, com opções como 20, 40 ou 50 itens, proporcionando maior controle sobre a navegação.

### 4.3.3 Interação com Obras

Na Figura 26, onde está a **Região dos Resultados** de busca em que se encontra a **galeria de resultados**, ao passar o cursor sobre uma obra nessa galeria, são exibidos dois ícones interativos que permitem ao usuário realizar ações rápidas diretamente na tela de busca. A Figura 27 ilustra essa funcionalidade:

- a) **Ícone de Visualização:** representado por um símbolo de olho (ícone roxo), este botão permite que o usuário acesse uma página detalhada da obra selecionada (Figura 28). Nessa página, são exibidas informações completas, como sinopse, elenco, duração, gênero e outras características relevantes;
- b) **Ícone de Adicionar à Coleção:** representado por um símbolo de “+” (ícone verde), este botão possibilita que o usuário adicione a obra diretamente à sua coleção pessoal. Essa funcionalidade facilita o gerenciamento de conteúdos que o usuário deseja acompanhar ou visitar no futuro.

Figura 27 – Interação com obras na tela de busca.



Fonte: Elaborado pela autora.

Esses recursos tornam a navegação mais dinâmica e intuitiva, permitindo que o usuário interaja rapidamente com as obras de interesse.

Figura 28 – Página de detalhes da obra selecionada.

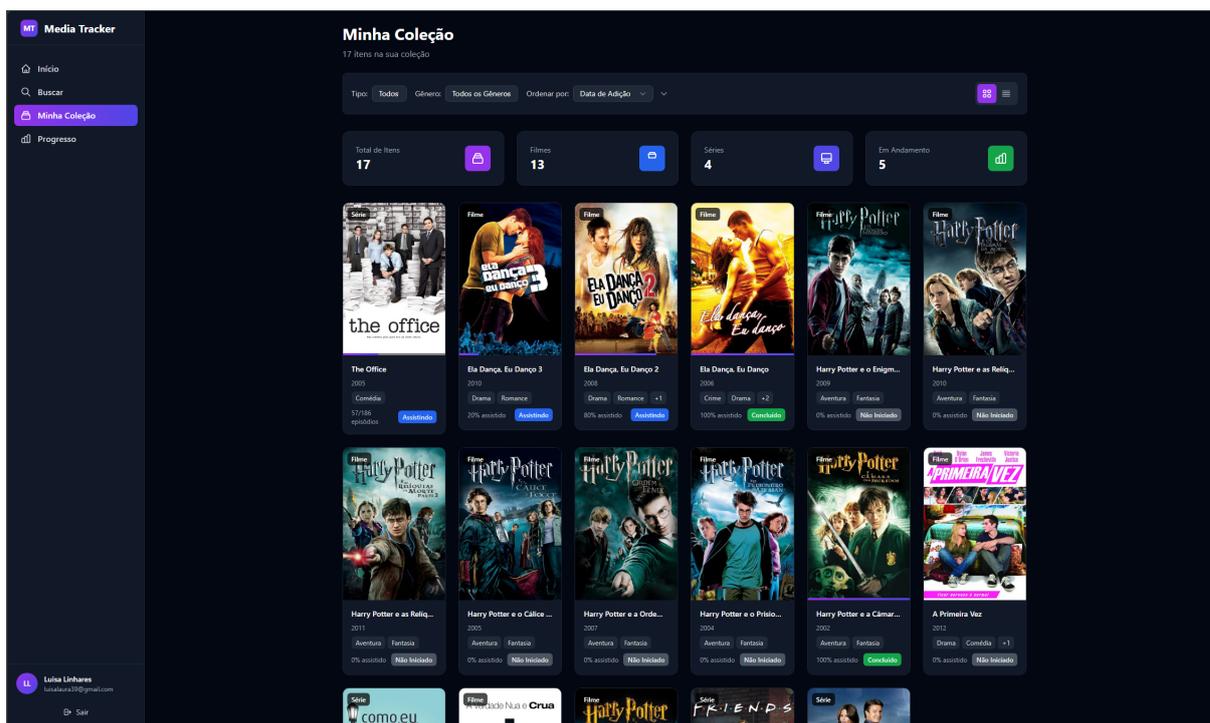


Fonte: Elaborado pela autora.

## 4.4 Tela de Coleção

A Figura 29 apresenta a tela **Minha Coleção** do sistema Media Tracker, que foi projetada para que o usuário gerencie os filmes e séries adicionados à sua coleção

Figura 29 – Tela de coleção do sistema Media Tracker.



Fonte: Elaborado pela autora.

peçoal. Essa interface oferece uma visão consolidada dos itens salvos, o que permite uma navegação eficiente e personalizada. Essa tela foi projetada para oferecer uma experiência organizada e prática, isso permite que o usuário gerencie sua coleção de forma eficiente e personalizada.

Na parte superior da tela da Figura 29, encontram-se filtros e opções de ordenação que auxiliam na organização e na busca por itens específicos na coleção:

- Filtro de Tipo:** permite ao usuário selecionar entre **Todos**, **Filmes** ou **Séries**, facilitando a visualização de conteúdos de acordo com a preferência;
- Filtro de Gênero:** apresenta uma lista de gêneros, como **Aventura**, **Comédia**, **Crime**, **Drama**, **Fantasia** e **Romance**, possibilitando que o usuário refine os resultados com base em categorias específicas;
- Filtro de Ordenação:** permite organizar os itens da coleção com base em critérios como **Data de Adição**, **Título**, **Progresso**, **Ano de Lançamento** e **Avaliação**, ajudando o usuário a encontrar rapidamente os itens desejados.

Abaixo dos filtros, são exibidos indicadores estatísticos que resumem o estado atual da coleção do usuário:

- Total de Itens:** número total de filmes e séries na coleção;
- Filmes e Séries:** quantidade de cada tipo de conteúdo;

c) **Em Andamento**: número de obras que o usuário está assistindo atualmente.

Na seção principal da tela na Figura 29, os itens da coleção são exibidos em formato de galeria, com cartazes, títulos e informações adicionais. Cada item apresenta os seguintes detalhes:

- **Tags de Status**: cada item possui uma tag que indica o status atual do conteúdo na coleção do usuário. As opções incluem:
  - **Não Iniciado**: o conteúdo foi adicionado à coleção, mas ainda não foi iniciado;
  - **Assistindo**: o usuário está atualmente assistindo ao conteúdo;
  - **Concluído**: o conteúdo foi completamente assistido;
  - **Abandonado**: o usuário optou por não continuar assistindo ao conteúdo;
- **Porcentagem Assistida**: indica o progresso do usuário em relação ao conteúdo. Para filmes, é exibido o percentual do total assistido. Para séries, é exibida a quantidade de episódios assistidos em relação ao total disponível;
- **Gêneros**: os gêneros associados ao conteúdo são apresentados para facilitar a identificação e organização.

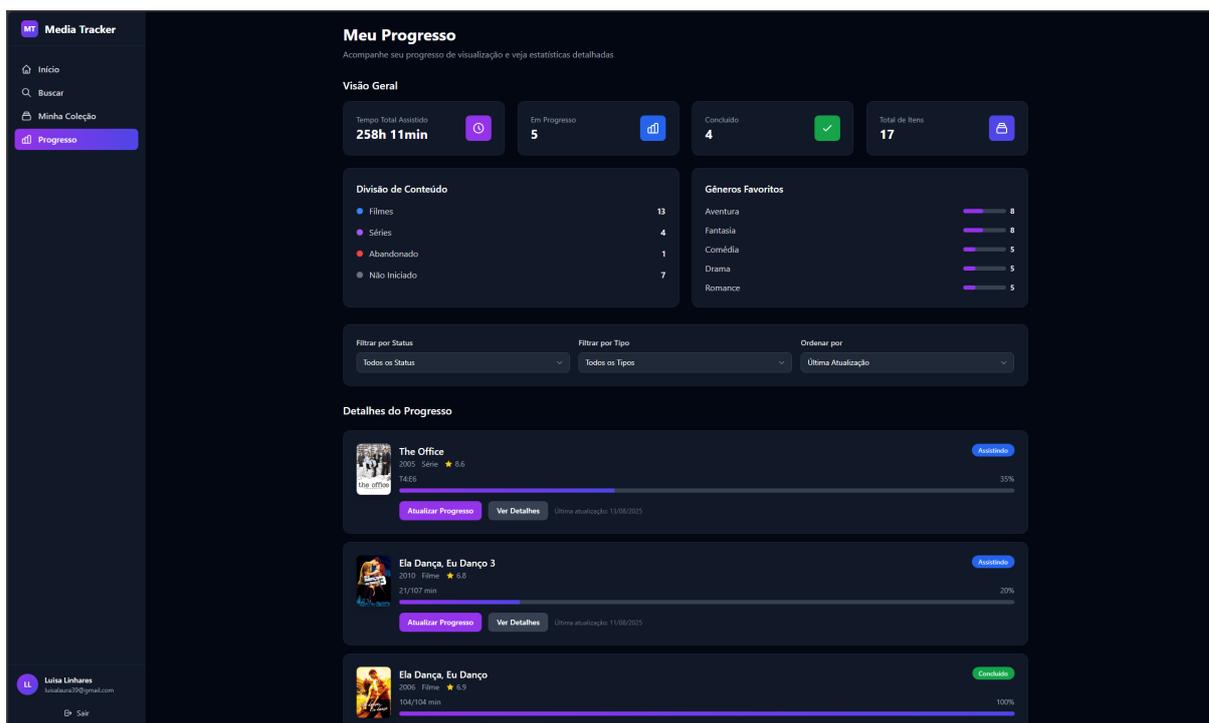
Além disso, o usuário pode alternar entre os modos de exibição **Grade** e **Lista**, garantindo flexibilidade na visualização. O modo **Grade** exibe os itens com cartazes maiores e informações resumidas, enquanto o modo **Lista** apresenta uma visão mais detalhada.

## 4.5 Tela de Progresso

A Figura 30 apresenta a tela **Meu Progresso** do sistema Media Tracker, projetada para que o usuário acompanhe e gerencie o progresso de visualização de filmes e séries, além de acessar estatísticas detalhadas sobre o conteúdo consumido. Na parte superior da tela, é apresentada uma **Visão Geral** com indicadores que resumem o progresso do usuário:

- a) **Tempo Total Assistido**: exibe o tempo acumulado de visualização em horas e minutos;
- b) **Em Progresso**: indica a quantidade de itens que o usuário está assistindo no momento;
- c) **Concluído**: mostra o número de filmes e séries finalizados;
- d) **Total de Itens**: apresenta o número total de conteúdos adicionados à coleção.

Figura 30 – Tela de progresso do sistema Media Tracker.



Fonte: Elaborado pela autora.

Abaixo dos indicadores, a tela apresenta dois gráficos detalhados:

- Divisão de Conteúdo:** quantidade de filmes e séries que existem na coleção do usuário e a quantidade de obras com status (*Não Iniciado* e *Abandonado*);
- Gêneros Favoritos:** exhibe os gêneros mais assistidos pelo usuário com a quantidade de itens consumidos em cada categoria.

Na seção inferior da Figura 30, intitulada **Detalhes do Progresso**, os itens em progresso são exibidos com informações detalhadas, organizados em formato de lista. Cada item apresenta:

- **Cartaz e Informações Básicas:** inclui o cartaz, título, ano de lançamento, nota média e duração total para filmes ou número temporadas com seus respectivos episódios para séries;
- **Barra de Progresso:** indica visualmente o percentual já assistido do conteúdo;
- **Botões de Ação:**
  - **Atualizar Progresso:** permite que o usuário registre o progresso de visualização;
  - **Ver Detalhes:** exhibe informações adicionais sobre o conteúdo.

Figura 31 – Modal de atualização de progresso para filmes no sistema Media Tracker.



Fonte: Elaborado pela autora.

Filtros adicionais estão disponíveis acima da lista de **Detalhes de Progresso** na Figura 30, a qual permite que o usuário refine os resultados por **Status**, **Tipo** e **Ordenação** que visa uma navegação que seja eficiente e personalizada. Essa tela foi projetada para oferecer uma experiência prática e intuitiva, combinando uma visão geral do progresso com ferramentas detalhadas de gerenciamento de filmes e séries.

Ainda, ao clicar no botão **Atualizar Progresso** de uma obra na lista de **Detalhes de Progresso** na Figura 30, o sistema exibe um modal específico para filmes ou séries, conforme ilustrado nas Figuras 31 e 32.

Na Figura 31 é apresentado o **Modal de Atualização de Progresso** para filmes no sistema Media Tracker. Este modal permite ao usuário gerenciar e registrar o progresso de visualização de um filme de forma detalhada. As principais funcionalidades incluem:

- a) **Progresso Atual**: exibe o tempo assistido em relação à duração total do filme, acompanhado de uma barra de progresso visual e a porcentagem correspondente. Por exemplo, no caso da figura, o progresso está em 20% (21 minutos de 1h47min);

- b) **Tempo Assistido:** permite ajustar manualmente o tempo assistido por meio de um controle deslizante, que atualiza automaticamente a barra de progresso e a porcentagem. Além disso, há botões de atalho para definir rapidamente o progresso em 25%, 50%, 75% ou **Completo**;
- c) **Status de Visualização:** o usuário pode alterar o status do filme, escolhendo entre as opções: **Não Iniciado**, **Em Andamento**, **Concluído** ou **Abandonado**;
- d) **Avaliação:** o sistema permite que o usuário atribua uma nota ao filme, selecionando uma opção no campo **Sua Avaliação**. Caso nenhuma nota tenha sido atribuída, o campo exibe **Sem Avaliação**;
- e) **Comentários:** há um campo opcional para que o usuário adicione observações ou notas pessoais sobre o filme. O texto inserido não é obrigatório e pode ser utilizado para registrar impressões ou detalhes relevantes;
- f) **Botões de Ação:** na parte inferior do modal, estão disponíveis os botões **Cancelar** e **Atualizar**. O botão **Cancelar** descarta as alterações feitas, enquanto o botão **Atualizar** salva as informações editadas no sistema.

Por sua vez, a Figura 32 apresenta o **Modal de Atualização para Séries** para séries no sistema Media Tracker. Este modal permite ao usuário gerenciar e registrar o progresso de visualização de uma série de forma detalhada. As principais funcionalidades incluem:

- a) **Progresso Atual:** indica o número de episódios assistidos em relação ao total da série, acompanhado de uma barra de progresso visual e a porcentagem correspondente;
- b) **Controle de Temporadas e Episódios:** o usuário pode selecionar a temporada e o episódio atual por meio de controles incrementais (“+” e “-”). Além disso, há atalhos para marcar rapidamente um episódio como assistido (**+1 Episódio**) ou concluir uma temporada inteira (**Temporada Completa**);
- c) **Status de Visualização:** permite alterar o status da série, com as opções **Não Iniciado**, **Em Andamento**, **Concluído** ou **Abandonado**;
- d) **Avaliação:** o sistema permite que o usuário atribua uma nota à série, selecionando uma opção no campo **Sua Avaliação**. Caso nenhuma nota tenha sido atribuída, o campo exibe **Sem Avaliação**;
- e) **Comentários:** há um campo opcional para que o usuário adicione observações ou notas pessoais sobre a série. O texto inserido não é obrigatório e pode ser utilizado para registrar impressões ou detalhes relevantes;

Figura 32 – Modal de Atualização de Progresso para séries no sistema Media Tracker.

The image shows a dark-themed modal window titled "Atualizar Progresso - The Office". At the top right is a close button (X). The main content area is divided into several sections:

- Progresso Atual:** Shows "Episódio 6 de 186" and "31% completo" with a progress bar.
- Progresso da Série (T4:E6):** Includes a "Temporada" section with a minus button, a text input containing "4", and a plus button, followed by "/ 9". Below it is an "Episódio" section with a minus button, a text input containing "6", and a plus button, followed by "/ 14".
- Buttons:** Two buttons are present: "+ 1 Episódio" (purple) and "Temporada Completa" (green).
- Status de Visualização:** A dropdown menu currently set to "Em Andamento".
- Sua Avaliação:** A dropdown menu currently set to "Sem avaliação".
- Comentário (opcional):** A text input field with the placeholder "Adicione uma nota sobre este conteúdo...".
- Bottom Buttons:** "Cancelar" (grey) and "Atualizar" (purple).

Fonte: Elaborado pela autora.

- f) **Botões de Ação:** na parte inferior do modal, estão disponíveis os botões **Cancelar** e **Atualizar**. O botão **Cancelar** descarta as alterações feitas, enquanto o botão **Atualizar** salva as informações editadas no sistema.

## 4.6 Análise da Pesquisa com Usuários de Teste

Esta seção apresenta uma análise dos resultados obtidos por meio da pesquisa realizada com 16 usuários de teste da plataforma Media Tracker. O objetivo foi avaliar a experiência do usuário, funcionalidades implementadas e identificar pontos de melhoria para o desenvolvimento da plataforma Web destinada ao gerenciamento e descoberta de novos títulos a partir de busca por imagem e texto.

A coleta de dados foi realizada utilizando um formulário estruturado desenvolvido no Google Forms, o qual foi especialmente elaborado para esta pesquisa. O instrumento de

coleta, apresentado integralmente no Apêndice B, foi organizado em seis seções distintas: (1) **Perfil do Usuário**; (2) **Primeira Impressão**; (3) **Funcionalidades Específicas**; (4) **Usabilidade**; (5) **Experiência Geral**; e, finalmente, (6) **Feedback Aberto**. Esta estruturação permitiu uma avaliação sistemática e abrangente da plataforma, cobrindo tanto aspectos quantitativos quanto qualitativos da experiência dos participantes.

Para o formulário, foi adotada uma metodologia que exigia dos participantes o teste prático das funcionalidades antes da avaliação, garantindo que todas as respostas fossem baseadas na experiência real de uso da plataforma. As instruções detalhadas, conforme apresentado na Figura 36 do Apêndice B, orientavam os usuários sobre como acessar a plataforma, criar uma conta e explorar as principais funcionalidades, incluindo busca por texto e imagem, gerenciamento de coleção e controle de progresso de visualização.

#### 4.6.1 Perfil dos Usuários Participantes

A caracterização do perfil dos participantes, coletada através das questões iniciais do formulário (Figura 37 do Apêndice B), revelou um perfil predominantemente jovem dos usuários, com 56,3% dos participantes na faixa etária entre 26 e 35 anos, seguidos por 25% na faixa entre 18 e 25 anos e 18,8% entre 36 e 45 anos.

Os dados mostram um equilíbrio entre os diferentes padrões de consumo de filmes e séries, com 25% dos usuários assistindo diariamente, semanalmente, algumas vezes por semana e algumas vezes por mês. Nenhum usuário relatou assistir raramente, o que demonstra um engajamento consistente com conteúdo audiovisual.

O perfil tecnológico dos usuários é favorável, com 56,3% classificando-se com nível “*muito alto*” de familiaridade com tecnologias avançadas. Adicionalmente, 18,8% se consideram com nível “*alto*” e outros 18,8% com nível “*médio*”. Apenas 6,3% relataram ter dificuldades ocasionais, indicando que a plataforma está sendo testada por um público que tem habilidades com o uso de tecnologias da Web.

#### 4.6.2 Avaliação da Interface e Usabilidade

As questões relacionadas à primeira impressão da plataforma (Figura 38 do Apêndice B) revelaram resultados positivos. A plataforma causou uma boa primeira impressão, com 62,5% dos usuários avaliando o design como “*excelente - moderno e muito atrativo*”, e 31,3% como “*bom - design agradável*”. Nenhum usuário classificou o design de forma negativa, o que reflete uma boa aceitação da criação visual da interface.

A navegação inicial foi avaliada de forma muito positiva, com 62,5% dos usuários considerando-a “*muito intuitiva*” e conseguindo encontrar tudo facilmente. Outros 31,3% a classificaram como “*intuitiva*”, resultando em 93,8% de avaliações positivas. Apenas 6,3% relataram alguma dificuldade inicial.

Os aspectos técnicos de usabilidade, avaliados por meio das questões apresentadas na Figura 40 do Apêndice B, demonstram um desempenho razoável. A velocidade de carregamento das páginas atendeu às expectativas dos usuários, com 50% classificando-a como “*muito rápida*” (menos de 1 segundo) e 37,5% como “*rápida*” (entre 1 e 2 segundos). Apenas 12,5% consideraram “*aceitável*”, sem nenhuma avaliação negativa.

A estrutura informacional da plataforma foi bem recebida, com 62,5% dos usuários considerando as informações “*muito claras e bem posicionadas*” e 31,3% avaliando como “*claras e bem organizadas*”. Somente 6,3% relataram alguma dificuldade na organização do layout.

### 4.6.3 Análise das Funcionalidades Específicas

A avaliação das funcionalidades principais da plataforma, estruturada nas questões apresentadas nas Figuras 38 e 39 do Apêndice B, fornece *insights* importantes sobre o desempenho de cada componente da aplicação.

A funcionalidade de busca textual demonstrou excelente performance, com 81,3% dos usuários encontrando exatamente o que procuravam. Outros 12,5% obtiveram resultados relevantes, totalizando 93,8% de taxa de sucesso. Apenas 6,3% tiveram resultados parcialmente relevantes.

A inovadora funcionalidade de busca por imagem, implementada com inteligência artificial, foi o destaque da plataforma. Com a maioria de 62,5% dos usuários conseguindo identificar corretamente o conteúdo desejado, enquanto 25% obtiveram identificação precisa na maioria dos casos. A taxa de sucesso combinada de 87,5% demonstra a eficácia da implementação dessa tecnologia.

O sistema de gerenciamento de coleção pessoal recebeu avaliação excepcional, com 75% dos usuários considerando-o “*excelente e muito fácil de adicionar/remover itens*”. Outros 18,8% avaliaram como “*bom, com processo simples e claro*”. Apenas 6,3% tiveram alguma dificuldade inicial.

A funcionalidade de acompanhamento de progresso foi bem avaliada, com 50% considerando-a “*boa, útil e clara*” e 37,5% como “*excelente, muito prática e completa*”. A combinação resulta em 87,5% de satisfação com essa funcionalidade.

Os filtros implementados na plataforma receberam aprovação significativa, com 75% dos usuários considerando-os “*muito úteis*” e facilitadores da busca. Outros 18,8% os classificaram como “*úteis*”. Apenas 6,3% reportaram funcionalidade duplicada nos filtros.

#### 4.6.4 Experiência Geral e Impacto

A análise da experiência geral dos usuários, baseada nas questões apresentadas nas Figuras 41 e 42 do Apêndice B, revelou-se de forma positiva sobre a percepção da plataforma.

A análise das funcionalidades consideradas mais úteis/inovadoras revelou:

1. **Busca por imagem com IA:** 75% confirmaram o diferencial competitivo da plataforma;
2. **Controle detalhado de progresso:** 43,8% demonstraram a importância do acompanhamento;
3. **Organização da coleção pessoal:** 37,5% validam a necessidade de gerenciamento;
4. **Estatísticas de visualização:** 37,5% mostraram interesse em *analytics* pessoais.

Quando questionados sobre funcionalidades que precisam de melhorias em cada uma das funcionalidades a seguir:

1. **Controle de progresso:** apesar da boa avaliação, 37,5% afirmam que existe possibilidade para refinamentos;
2. **Busca por imagem:** 31,3% afirmam que há oportunidade para aprimorar ainda mais a precisão da ferramenta;
3. **Interface/Design e Busca por texto:** 18,8% apontaram melhorias pontuais necessárias para cada um destes.

A plataforma demonstrou alto nível de satisfação conforme descrito a seguir:

- **Avaliação geral:** 56,3% consideraram nota 10 (excelente) e 31,3% nota 9 (muito bom);
- **Taxa de recomendação:** 68,8% “*definitivamente sim*” e 31,3% “*provavelmente sim*”;
- **Nenhuma avaliação negativa** em ambos os quesitos.

O *feedback* qualitativo coletado por meio das questões abertas, apresentadas nas Figuras 42 e 43 no Apêndice B, complementou a análise quantitativa com *insights* específicos sobre dificuldades encontradas, sugestões de melhorias e comentários gerais sobre a experiência de uso.

## 4.7 Considerações Finais

A análise realizada neste capítulo permitiu avaliar, de forma integrada, as funcionalidades implementadas na plataforma *Media Tracker* e a percepção dos usuários de teste quanto à sua usabilidade, desempenho e relevância.

A **Tela de Login** apresentou-se clara e objetiva, cumprindo adequadamente sua função de autenticação, com campos bem definidos e acesso direto ao cadastro de novos usuários. A **Tela de Início e Sessões de Destaque** demonstrou eficiência ao reunir, em um único espaço, indicadores estatísticos do perfil do usuário, galerias horizontais com lançamentos recentes, filmes e séries bem avaliados, além de concentrar os mecanismos de busca textual e por imagem, permitindo uma interação inicial abrangente e facilitando a descoberta de novos conteúdos. A **Tela de Busca** mostrou-se adequada para pesquisas textuais detalhadas, oferecendo filtros avançados por tipo, gênero e ordenação, modos de exibição em grade ou lista e interação direta com as obras para visualização de detalhes ou adição à coleção. A **Tela de Coleção** revelou-se eficaz no gerenciamento dos itens salvos, possibilitando organização por tipo, gênero e status de visualização. A **Tela de Progresso** permitiu o acompanhamento detalhado do consumo de mídia, com recursos para atualização manual do status e visualização de estatísticas de progresso.

Os resultados da pesquisa validaram o conceito da plataforma, evidenciando que a combinação de funcionalidades tradicionais de gerenciamento com tecnologias inovadoras, como a busca por imagem com inteligência artificial, atendeu às expectativas e necessidades dos usuários. A busca por imagem configurou-se como o principal diferencial, sendo reiteradamente destacada como a funcionalidade mais útil e inovadora. A satisfação dos usuários com o design, a navegação e o desempenho indica que as decisões de UX/UI foram adequadas, equilibrando funcionalidades avançadas com simplicidade de uso.

Apesar dos resultados positivos, foram identificadas áreas específicas para aprimoramento contínuo, especialmente no refinamento de funcionalidades já bem avaliadas, como o controle de progresso e a precisão da busca por imagem. A elevada taxa de recomendação (100% entre “*definitivamente*” e “*provavelmente sim*”) demonstra o potencial de crescimento orgânico da base de usuários, aspecto essencial para o êxito de plataformas digitais. Assim, este capítulo apresenta subsídios consistentes para a validação do projeto e para o direcionamento de melhorias futuras, confirmando que a plataforma *Media Tracker* atende a uma demanda real do mercado, configurando-se como uma solução tecnicamente robusta e bem aceita pelos usuários.

## 5 Conclusão e Trabalhos Futuros

O presente trabalho teve como objetivo o desenvolvimento de uma plataforma Web para gerenciamento de filmes e séries, integrando recursos de Inteligência Artificial para busca textual e visual, a fim de oferecer aos usuários uma solução unificada para organização, descoberta e acompanhamento de conteúdo audiovisual. A proposta buscou suprir lacunas identificadas nas soluções existentes, que, em sua maioria, carecem de integração entre gerenciamento de coleção, reconhecimento visual e enriquecimento de dados por meio de APIs especializadas.

Durante o desenvolvimento, foram aplicadas tecnologias modernas como *Spring Boot* no *backend* e *Angular* no *frontend*, com integração à API TMDb para obtenção de informações detalhadas sobre obras, e recursos de IA baseados em LLMs para interpretação de descrições e reconhecimento de imagens. A arquitetura contemplou práticas de modularidade, segurança com JWT, containerização via *Docker* e integração contínua, garantindo escalabilidade e facilidade de manutenção.

A metodologia adotada permitiu alcançar, de forma estruturada, cada um dos objetivos específicos definidos no Capítulo 1, contribuindo diretamente para o alcance do objetivo geral.

O desenvolvimento do módulo de gerenciamento de coleção pessoal resultou na implementação da *Tela de Coleção*, que permite ao usuário adicionar, remover e organizar filmes e séries, com filtros por tipo, gênero e status de visualização. Essa funcionalidade atende ao requisito de centralizar e organizar o acervo pessoal, elemento essencial para o objetivo geral de gerenciamento de mídia.

Em relação ao sistema de busca multimodal, a *Tela de Início* incorporou a busca textual e a busca por imagem com inteligência artificial, utilizando LLMs e reconhecimento visual para identificar obras a partir de descrições ou imagens. Essa inovação amplia as possibilidades de descoberta de conteúdo, alinhando-se diretamente à proposta de oferecer recursos avançados de pesquisa.

No que se refere ao acompanhamento de progresso, a *Tela de Progresso* foi desenvolvida para registrar e atualizar o status de visualização de filmes e séries, permitindo ao usuário retomar conteúdos de forma prática e acompanhar estatísticas de consumo. Esse recurso fortalece o controle sobre o histórico de visualização, contribuindo para a organização e continuidade do consumo.

A disponibilização da plataforma em ambiente público possibilitou sua avaliação em testes com usuários, permitindo a coleta de dados reais de uso e a validação das

funcionalidades implementadas. Por fim, a análise da experiência dos participantes da pesquisa forneceu dados quantitativos e qualitativos sobre usabilidade, desempenho e relevância das funcionalidades. Os resultados confirmaram a boa aceitação da plataforma e indicaram pontos de melhoria, especialmente no refinamento da busca por imagem e no controle de progresso.

A relação entre esses objetivos específicos e o objetivo geral é direta: ao integrar gerenciamento de coleção, busca multimodal e acompanhamento de progresso em uma única plataforma, a solução proposta atendeu à necessidade de unificar, em um ambiente centralizado, a organização e a descoberta de conteúdo audiovisual, com suporte de tecnologias modernas e inteligência artificial.

Os resultados obtidos indicaram que a plataforma atendeu aos objetivos estabelecidos. Os testes com usuários demonstraram boa aceitação das funcionalidades, com destaque para a busca por imagem assistida por IA, que permitiu a identificação de obras a partir de capturas de tela ou pôsteres, e para o controle de progresso de visualização, que possibilitou maior organização e praticidade. As avaliações apontaram que a solução proporcionou agilidade na localização de títulos e maior controle sobre o histórico pessoal de consumo de mídia.

## 5.1 Resultados e Contribuições

O desenvolvimento da plataforma *Media Tracker* resultou em um sistema funcional, responsivo e integrado, capaz de unificar em um único ambiente o gerenciamento de coleção pessoal, a busca multimodal e o acompanhamento de progresso de filmes e séries. A implementação atendeu aos requisitos funcionais e não funcionais definidos no Capítulo 3, empregando tecnologias modernas e arquitetura modular para garantir escalabilidade, segurança e facilidade de manutenção.

Entre os principais resultados alcançados, destacam-se:

- Implementação de um módulo de gerenciamento de coleção pessoal, com filtros avançados e organização por tipo, gênero e status de visualização;
- Desenvolvimento de mecanismos de busca textual e por imagem com suporte de inteligência artificial, permitindo a identificação de obras a partir de descrições ou elementos visuais;
- Criação de um módulo de acompanhamento de progresso, com registro detalhado de status e estatísticas de consumo;
- Integração com a API TMDb para enriquecimento de dados, ampliando a qualidade e a quantidade de informações disponíveis ao usuário;

- Disponibilização da plataforma em ambiente de testes e realização de avaliação com usuários, obtendo índices elevados de satisfação e recomendação.

A pesquisa com usuários demonstrou que a busca por imagem foi percebida como o principal diferencial da plataforma, sendo apontada como a funcionalidade mais inovadora e útil. O controle de progresso e a organização da coleção também receberam avaliações positivas, confirmando a relevância dessas funcionalidades para a experiência de uso. A taxa de recomendação de 100% (entre “*definitivamente*” e “*provavelmente sim*”) evidencia o potencial de adoção da solução.

As contribuições deste trabalho podem ser agrupadas em três dimensões principais:

1. **Contribuições técnicas:** integração de tecnologias como LLMs e reconhecimento visual, em um sistema web modular; uso de arquitetura hexagonal no *backend* e *frontend* reativo com *Angular Signals*; aplicação de boas práticas de segurança, escalabilidade e manutenção;
2. **Contribuições para a área de consumo de mídia digital:** oferta de uma solução unificada que supera limitações de ferramentas existentes, combinando gerenciamento de coleção, descoberta de conteúdo e acompanhamento de progresso em um único ambiente, com suporte a busca multimodal;
3. **Contribuições acadêmicas e científicas:** demonstração prática da viabilidade de integrar inteligência artificial multimodal a sistemas de gerenciamento de mídia; fornecimento de um protótipo funcional e documentado que pode servir como base para pesquisas futuras, especialmente em sistemas de recomendação e interação humano-computador.

Dessa forma, o *Media Tracker* não apenas cumpre os objetivos propostos, mas também estabelece um modelo de referência para o desenvolvimento de plataformas similares, contribuindo para a evolução de soluções inteligentes voltadas ao consumo e à organização de conteúdo audiovisual.

Apesar desses resultados e contribuições, algumas limitações foram identificadas ao longo do desenvolvimento e da avaliação da plataforma, as quais são apresentadas a seguir.

## 5.2 Limitações do Trabalho

Apesar dos resultados positivos e da boa aceitação por parte dos usuários, o desenvolvimento e a avaliação da plataforma *Media Tracker* evidenciaram algumas limitações que precisam ser consideradas para interpretações adequadas dos resultados e para orientar trabalhos futuros.

Uma das principais limitações está na dependência de APIs externas, em especial da API do TMDb, utilizada para obtenção e atualização de metadados sobre filmes e séries. Essa dependência implica que eventuais mudanças na política de uso, na estrutura de dados ou na disponibilidade do serviço podem impactar diretamente o funcionamento do sistema. Além disso, restrições como limites de requisições (*rate limits*) podem afetar o desempenho em cenários de alta demanda.

Também foi observado que consultas mais complexas — especialmente aquelas que combinam múltiplos filtros ou que dependem de análise multimodal — apresentaram tempos de resposta superiores ao desejado. Esse comportamento está relacionado tanto ao volume de dados processados quanto à necessidade de integração entre diferentes módulos (banco de dados local, API externa e processamento por LLMs). Embora o desempenho geral tenha sido satisfatório, há espaço para otimizações, como uso de índices adicionais, cache de resultados e estratégias de pré-processamento.

Outro ponto a considerar é que os recursos de personalização ainda são limitados. Embora a plataforma permita o gerenciamento de coleção pessoal e o acompanhamento de progresso, não há um sistema de recomendações proativas totalmente integrado que utilize o histórico de consumo e preferências do usuário para sugerir novos conteúdos de forma personalizada. Essa limitação reduz o potencial de engajamento contínuo e de descoberta automatizada de títulos relevantes.

A funcionalidade de busca por imagem, apesar de inovadora e bem avaliada, apresentou variações de precisão dependendo da qualidade, do enquadramento e do contexto da imagem fornecida. Imagens com baixa resolução ou ausência de características marcantes do conteúdo dificultaram a identificação correta. Além disso, a cobertura do reconhecimento visual está limitada ao escopo dos dados disponíveis na API TMDb e ao desempenho do modelo de IA utilizado.

A avaliação com usuários também apresentou restrições, uma vez que foi conduzida com um grupo reduzido de participantes (16 usuários), com perfil predominantemente jovem e alto nível de familiaridade tecnológica. Embora os resultados tenham sido positivos, esse recorte limita a generalização das conclusões para públicos mais amplos e heterogêneos. Uma avaliação com amostras maiores e mais diversificadas poderia fornecer insights adicionais sobre acessibilidade, curva de aprendizado e adequação da interface a diferentes perfis de uso.

Por fim, a implantação foi realizada em ambiente de testes acadêmicos, com recursos computacionais limitados, o que pode não refletir integralmente o desempenho e a escalabilidade esperados em um cenário de produção. O consumo de recursos por modelos de IA, especialmente na busca multimodal, pode se tornar um gargalo em ambientes com alta concorrência de usuários.

Em síntese, tais limitações não comprometem a comprovação da viabilidade técnica da solução, mas indicam pontos claros de atenção e oportunidades de evolução. Trabalhos futuros podem explorar estratégias para mitigar essas restrições, como diversificação de fontes de dados, otimização de consultas, ampliação de recursos de personalização e realização de testes em larga escala.

### 5.3 Trabalhos Futuros

Como continuidade do trabalho, levando em consideração o *feedback* dos usuários, direções concretas, baseadas nas propostas apresentadas, foram elencados os seguintes trabalhos futuros:

- Otimização da busca por imagem, reduzindo o tempo de resposta e aprimorando a ordenação para que os resultados mais relevantes apareçam primeiro;
- Implementação de busca global sem caracteres obrigatórios, possibilitando a listagem completa do catálogo quando o campo de busca estiver vazio;
- Integração com serviços de streaming (e.g. Netflix, Disney+, Prime Video) para sincronizar automaticamente o status de visualização e indicar onde assistir cada título;
- Restrições no *upload* de arquivos para evitar formatos incompatíveis (como *.webp*) na busca por imagem;
- Implementar um sistema de recomendação híbrido, combinando dados de histórico pessoal, preferências explícitas e análise multimodal.
- Realização de testes de estresse em consultas de imagens mais genéricas utilizando LLMs, com o objetivo de avaliar a robustez do sistema em cenários de maior ambiguidade visual, medindo impacto em tempo de resposta, precisão e consumo de recursos.

Essas melhorias, associadas às evoluções já previstas, têm potencial para elevar a qualidade, a precisão e a usabilidade da plataforma, ampliando seu impacto e potencial de adoção. Em síntese, a plataforma desenvolvida cumpre seu papel como solução inovadora para gerenciamento e descoberta de filmes e séries, unindo tecnologias de ponta em um ambiente funcional e intuitivo. Espera-se que este trabalho sirva de base para evoluções futuras e inspire novas aplicações de Inteligência Artificial no contexto do consumo de mídia digital.

## Referências

- ACHIAM, J. et al. Gpt-4 technical report. *arXiv preprint*, arXiv, p. arXiv:2303.08774, 2023. Acesso em: 20 ago. 2025. Disponível em: <<https://arxiv.org/abs/2303.08774>>. Citado na página 24.
- ALAYRAC, J.-B. et al. Flamingo: a visual language model for few-shot learning. In: *Advances in Neural Information Processing Systems*. [S.l.]: Curran Associates, Inc., 2022. v. 35, p. 23716–23736. Citado na página 22.
- Anthropic. *Introducing Claude 4*. 2024. Website. Acesso em: 20 ago. 2025. Disponível em: <<https://www.anthropic.com/news/claude-4>>. Citado na página 23.
- Anthropic. *Introducing the Claude 3 Model Family*. 2024. Website. Acesso em: 20 ago. 2025. Disponível em: <<https://www.anthropic.com/news/claude-3-family>>. Citado na página 25.
- ANTHROPIC. *Introducing the Model Context Protocol*. 2024. Acesso em: 27 ago. 2025. Disponível em: <<https://www.anthropic.com/news/model-context-protocol>>. Citado na página 29.
- Anthropic. *Models Overview*. 2024. Documentação oficial. Acesso em: 20 ago. 2025. Disponível em: <<https://docs.anthropic.com/en/docs/about-claude/models/overview>>. Citado na página 26.
- Artificial Analysis. *AI Model Comparison*. 2024. Website. Acesso em: 20 ago. 2025. Disponível em: <<https://artificialanalysis.ai/models>>. Citado na página 26.
- BROWN, T. et al. Language models are few-shot learners. *Advances in Neural Information Processing Systems*, Curran Associates, Inc., v. 33, p. 1877–1901, 2020. Acesso em: 20 ago. 2025. Disponível em: <<https://proceedings.neurips.cc/paper/2020/hash/1457c0d6bfcb4967418bfb8ac142f64a-Abstract.html>>. Citado na página 22.
- BUCIONI, A. et al. A functional software reference architecture for llm-integrated systems. In: *2025 IEEE 22nd International Conference on Software Architecture Companion (ICSA-C)*. [S.l.]: IEEE, 2025. p. 1–5. Acesso em: 27 ago. 2025. Citado na página 28.
- CAROLAN, K.; FENNELLY, L.; SMEATON, A. F. A review of multi-modal large language and vision models. *arXiv preprint*, arXiv, p. arXiv:2404.01322, 2024. Acesso em: 20 ago. 2025. Disponível em: <<https://arxiv.org/abs/2404.01322>>. Citado na página 25.
- CARVALHO, T. R. d. S. *Explorando o desenvolvimento front-end: um estudo de caso em catálogo de filmes*. Tese (Doutorado) — Pontifícia Universidade Católica de Goiás, 2023. Acesso em: 27 ago. 2025. Citado 2 vezes nas páginas 32 e 39.
- CHADHA, A. *GPT-5 in 2025: Leader of the New LLM Era? Benchmarks and Rival Comparison*. 2025. Medium. Acesso em: 20 ago. 2025. Disponível em: <<https://ashishchadha11944.medium.com/gpt-5-in-2025-leader-of-the-new-llm-era-benchmarks-and-rival-comparison-5786e25b5ae4>>. Citado na página 24.

- CHAUHAN, S. et al. Llm-generated microservice implementations from restful api definitions. *arXiv preprint*, arXiv, p. arXiv:2502.09766, 2025. Acesso em: 20 ago. 2025. Disponível em: <<https://arxiv.org/abs/2502.09766>>. Citado na página 29.
- COHERE. *Command: Enterprise-grade LLM for business*. 2024. Acesso em: 22 maio 2025. Disponível em: <<https://cohere.com/command>>. Citado na página 23.
- Cursor IDE. *GPT-4.1 vs Gemini 2.5 Pro Comparison 2025*. 2025. Blog post. Acesso em: 20 ago. 2025. Disponível em: <<https://www.cursor-ide.com/blog/gpt41-vs-gemini25-pro-comparison-2025>>. Citado na página 25.
- DEEPMIND, G. *Gemini*. 2024. Acesso em: 22 maio 2025. Disponível em: <<https://deepmind.google/models/gemini/>>. Citado na página 23.
- DING, P.; STEVENS, R. Unified tool integration for llms: A protocol-agnostic approach to function calling. *arXiv preprint*, arXiv, p. arXiv:2508.02979, 2025. Acesso em: 20 ago. 2025. Disponível em: <<https://arxiv.org/abs/2508.02979>>. Citado na página 28.
- DORNELLES, D. L. T. *Aplicativo para gerenciamento de coleção de filmes*. Tese (Doutorado) — Universidade Tecnológica Federal do Paraná, 2017. Acesso em: 27 ago. 2025. Citado 2 vezes nas páginas 31 e 39.
- DRIESS, D. et al. *PaLM-E: An Embodied Multimodal Language Model*. 2023. Citado na página 22.
- EBERHARD, L.; RUPRECHTER, T.; HELIC, D. *Large Language Models as Narrative-Driven Recommenders*. 2024. Citado 2 vezes nas páginas 30 e 38.
- EVENS, T.; HENDERICKX, A.; CONRADIE, P. Technological affordances of video streaming platforms: Why people prefer video streaming platforms over television. *European Journal of Communication*, v. 39, n. 1, p. 3–21, 2024. Acesso em: 27 ago. 2025. Citado na página 18.
- Fireworks AI. *DeepSeek R1 Deep Dive*. 2024. Blog post. Acesso em: 20 ago. 2025. Disponível em: <<https://fireworks.ai/blog/deepseek-r1-deepdive>>. Citado na página 23.
- Google DeepMind. *Gemini*. 2024. Website. Acesso em: 20 ago. 2025. Disponível em: <<https://deepmind.google/models/gemini/>>. Citado 2 vezes nas páginas 25 e 26.
- HAU, K.; HASSAN, S.; ZHOU, S. Llms in mobile apps: Practices, challenges, and opportunities. In: *2025 IEEE/ACM 12th International Conference on Mobile Software Engineering and Systems (MOBILESoft)*. [S.l.]: IEEE, 2025. p. 3–14. Acesso em: 20 ago. 2025. Citado na página 29.
- Helicone. *The Complete LLM Model Comparison Guide*. 2024. Blog post. Acesso em: 20 ago. 2025. Disponível em: <<https://www.helicone.ai/blog/the-complete-llm-model-comparison-guide>>. Citado na página 26.
- IBM. *Context Window*. 2024. Website. Acesso em: 20 ago. 2025. Disponível em: <<https://www.ibm.com/br-pt/think/topics/context-window>>. Citado na página 25.
- IMDB. 2025. Disponível em: <<https://www.imdb.com/pt/>>. Citado 2 vezes nas páginas 35 e 36.

- INSIGHTS, F. B. *Video Streaming Market Size, Share & Growth [2024-2030]*. 2024. Disponível em: <<https://www.fortunebusinessinsights.com/video-streaming-market-103057>>. Citado na página 16.
- JOHNSON, O. V. et al. Image analysis through the lens of chatgpt-4. *Journal of Applied Artificial Intelligence*, v. 4, n. 2, p. 31–46, 2023. Citado 2 vezes nas páginas 30 e 38.
- KIM, J.; YANG, N.; JUNG, K. Persona is a double-edged sword: Enhancing the zero-shot reasoning by ensembling the role-playing and neutral prompts. *arXiv e-prints*, arXiv, p. arXiv:2408.08631, 2024. Acesso em: 20 ago. 2025. Disponível em: <<https://arxiv.org/abs/2408.08631>>. Citado na página 23.
- KOJIMA, T. et al. Large language models are zero-shot reasoners. *Advances in Neural Information Processing Systems*, Curran Associates, Inc., v. 35, p. 22199–22213, 2022. Acesso em: 20 ago. 2025. Disponível em: <<https://proceedings.neurips.cc/paper/2022/hash/8bb0d291acd4acf06ef112099c16f326-Abstract-Conference.html>>. Citado na página 23.
- LE, Q.; MIKOLOV, T. Distributed representations of sentences and documents. In: *International Conference on Machine Learning*. [S.l.]: PMLR, 2014. p. 1188–1196. Acesso em: 28 ago. 2025. Citado na página 30.
- LESTER, B.; AL-RFOU, R.; CONSTANT, N. The power of scale for parameter-efficient prompt tuning. *arXiv preprint arXiv:2104.08691*, 2021. Acesso em: 20 ago. 2025. Disponível em: <<https://arxiv.org/abs/2104.08691>>. Citado na página 23.
- LETTERBOXD. *About Letterboxd*. 2023. Disponível em: <<https://letterboxd.com/about/>>. Citado 3 vezes nas páginas 17, 33 e 35.
- LIU, P. et al. Pre-train, prompt, and predict: A systematic survey of prompting methods in natural language processing. *ACM Computing Surveys*, Association for Computing Machinery, v. 55, n. 9, p. 1–35, 2023. Acesso em: 20 ago. 2025. Disponível em: <<https://doi.org/10.1145/3560815>>. Citado na página 22.
- META. *Meta AI*. 2024. Acesso em: 22 maio 2025. Disponível em: <<https://ai.meta.com/>>. Citado na página 23.
- MEZA, L. R.; D'URSO, G. User's dilemma: A qualitative study on the influence of netflix recommender systems on choice overload. *Psychological Studies*, v. 69, n. 3, p. 349–367, 2024. Acesso em: 27 ago. 2025. Citado na página 18.
- Mistral AI. *Mistral Small 3*. 2024. Website. Acesso em: 20 ago. 2025. Disponível em: <<https://mistral.ai/news/mistral-small-3>>. Citado na página 23.
- NETFLIX. *Netflix Technology Blog: System Architectures for Personalization and Recommendation*. 2023. Disponível em: <<https://netflixtechblog.com/>>. Citado na página 16.
- NIELSEN. *Nielsen's State of Play Report: Streaming is the Future, but Consumers are Currently Overwhelmed by Choice*. [S.l.], 2022. Acesso em: 19 mar. 2024. Disponível em: <<https://www.nielsen.com/pt/news-center/2022/niensens-state-of-play-report-reveals-that-streaming-is-the-future-but-consumers-are-currently-overwhelmed-by-choice/>>. Citado na página 16.

- NIELSEN. *Nielsen's state of play report: Streaming is the future, but consumers are currently overwhelmed by choice*. [S.l.], 2022. Acesso em: 19 mar. 2025. Disponível em: <<https://www.nielsen.com>>. Citado na página 18.
- OpenAI. *GPT-V System Card*. 2023. Relatório técnico. Acesso em: 20 ago. 2025. Disponível em: <[https://cdn.openai.com/papers/GPTV\\_System\\_Card.pdf](https://cdn.openai.com/papers/GPTV_System_Card.pdf)>. Citado na página 24.
- OpenAI. *Hello GPT-4o*. 2024. Website. Acesso em: 20 ago. 2025. Disponível em: <<https://openai.com/index/hello-gpt-4o/>>. Citado 2 vezes nas páginas 24 e 26.
- OPENAI. *Model release notes*. 2024. Acesso em: 22 maio 2025. Disponível em: <<https://help.openai.com/en/articles/9624314-model-release-notes>>. Citado na página 23.
- OUYANG, L. et al. Training language models to follow instructions with human feedback. In: *Advances in Neural Information Processing Systems*. [S.l.]: Curran Associates, Inc., 2022. v. 35, p. 27730–27744. Citado na página 22.
- QI, P. Movie visual and speech analysis through multi-modal llm for recommendation systems. *IEEE Access*, 2024. Citado 2 vezes nas páginas 31 e 39.
- RADFORD, A. et al. Language models are unsupervised multitask learners. *OpenAI Blog*, OpenAI, v. 1, n. 8, p. 9, 2019. Acesso em: 20 ago. 2025. Disponível em: <[https://cdn.openai.com/better-language-models/language\\_models\\_are\\_unsupervised\\_multitask\\_learners.pdf](https://cdn.openai.com/better-language-models/language_models_are_unsupervised_multitask_learners.pdf)>. Citado na página 22.
- RESEARCH, G. V. *Video Streaming Market Size Report, 2022-2029*. 2022. Acesso em: 19 mar. 2024. Disponível em: <<https://www.grandviewresearch.com/industry-analysis/video-streaming-market>>. Citado na página 16.
- REYNOLDS, L.; MCDONELL, K. Prompt programming for large language models: Beyond the few-shot paradigm. In: *Extended Abstracts of the 2021 CHI Conference on Human Factors in Computing Systems*. Association for Computing Machinery, 2021. p. 1–7. Acesso em: 20 ago. 2025. Disponível em: <<https://doi.org/10.1145/3411763.3451760>>. Citado na página 23.
- SENNRICH, R.; HADDOW, B.; BIRCH, A. Neural machine translation of rare words with subword units. *arXiv preprint arXiv:1508.07909*, 2015. Acesso em: 20 ago. 2025. Disponível em: <<https://arxiv.org/abs/1508.07909>>. Citado na página 21.
- STATISTA. *Number of SVOD subscribers worldwide from 2020 to 2028*. 2024. Acesso em: 19 mar. 2024. Disponível em: <<https://www.statista.com/statistics/949391/svod-subscribers-global/>>. Citado na página 16.
- TAN, F. A. et al. Phantom: Persona-based prompting has an effect on theory-of-mind reasoning in large language models. *arXiv preprint*, arXiv, p. arXiv:2403.02246, 2024. Acesso em: 20 ago. 2025. Disponível em: <<https://arxiv.org/abs/2403.02246>>. Citado na página 23.
- TAO, C.; FAN, X.; YANG, Y. Harnessing llms for api interactions: A framework for classification and synthetic data generation. In: *2024 5th International Conference on Computers and Artificial Intelligence Technology (CAIT)*. [S.l.]: IEEE, 2024. p. 628–634. Acesso em: 20 ago. 2025. Citado na página 28.

TEAM, G. et al. Gemini 1.5: Unlocking multimodal understanding across millions of tokens of context. *arXiv preprint*, arXiv, p. arXiv:2403.05530, 2024. Acesso em: 20 ago. 2025. Disponível em: <<https://arxiv.org/abs/2403.05530>>. Citado 2 vezes nas páginas 24 e 25.

TEAM, Q. *Qwen Language Model*. 2024. Acesso em: 22 maio 2025. Disponível em: <<https://qwenlm.github.io/>>. Citado na página 23.

The Walt Disney Company. *Fiscal Year 2023 Annual Financial Report and Shareholder Letter*. 2023. <<https://thewaltdisneycompany.com/investor-relations/financial-information/>>. Acesso em: 19 mar. 2024. Citado na página 16.

TRACE.MOE. *Anime scene search engine*. 2024. Acesso em: 15 mar. 2025. Disponível em: <<https://trace.moe/>>. Citado na página 16.

TRACE.MOE. *Anime Scene Search Engine*. 2024. Disponível em: <<https://trace.moe/>>. Citado na página 37.

TRACE.MOE: Anime Scene Search Engine. 2025. Disponível em: <<https://trace.moe/>>. Citado na página 38.

TRAKT: Discover. Track. Share. 2025. Disponível em: <<https://trakt.tv/>>. Citado 2 vezes nas páginas 33 e 34.

VASWANI, A. et al. Attention is all you need. In: *Advances in Neural Information Processing Systems*. [S.l.]: Curran Associates, Inc., 2017. v. 30, p. 5998–6008. Citado na página 21.

Vellum AI. *LLM Leaderboard*. 2024. Website. Acesso em: 20 ago. 2025. Disponível em: <<https://www.vellum.ai/llm-leaderboard>>. Citado na página 24.

WAYNE, M. L. Global streaming platforms and national production cultures: Netflix, disney+ and local content. *Television & New Media*, SAGE Publications, v. 24, n. 3, p. 271–288, 2023. Citado na página 16.

WEI, J. et al. Chain-of-thought prompting elicits reasoning in large language models. *Advances in neural information processing systems*, Curran Associates, Inc., v. 35, p. 24824–24837, 2022. Acesso em: 20 ago. 2025. Disponível em: <<https://proceedings.neurips.cc/paper/2022/hash/9d5609613524ecf4f15af0f7b31abca4-Abstract-Conference.html>>. Citado na página 22.

WHAT is my movie? Describe and find movies. 2025. Disponível em: <<https://www.whatismymovie.com/>>. Citado 2 vezes nas páginas 36 e 37.

WHATISMYMOVIE. *Find movies by entering any word, phrase or sentence*. 2024. Acesso em: 15 mar. 2025. Disponível em: <<https://www.whatismymovie.com/>>. Citado na página 16.

YANG, W. et al. A comprehensive survey on integrating large language models with knowledge-based methods. *Knowledge-Based Systems*, Elsevier, p. 113503, 2025. Acesso em: 20 ago. 2025. Citado na página 28.

---

YIN, S. et al. A survey on multimodal large language models. *National Science Review*, Oxford University Press, v. 11, n. 12, p. nwae403, 2024. Acesso em: 20 ago. 2025. Citado 2 vezes nas páginas [17](#) e [29](#).

ZHAO, W. X. et al. *A survey of large language models*. 2023. ArXiv preprint arXiv:2303.18223. Acesso em: 27 ago. 2025. Citado na página [23](#).

# Apêndices

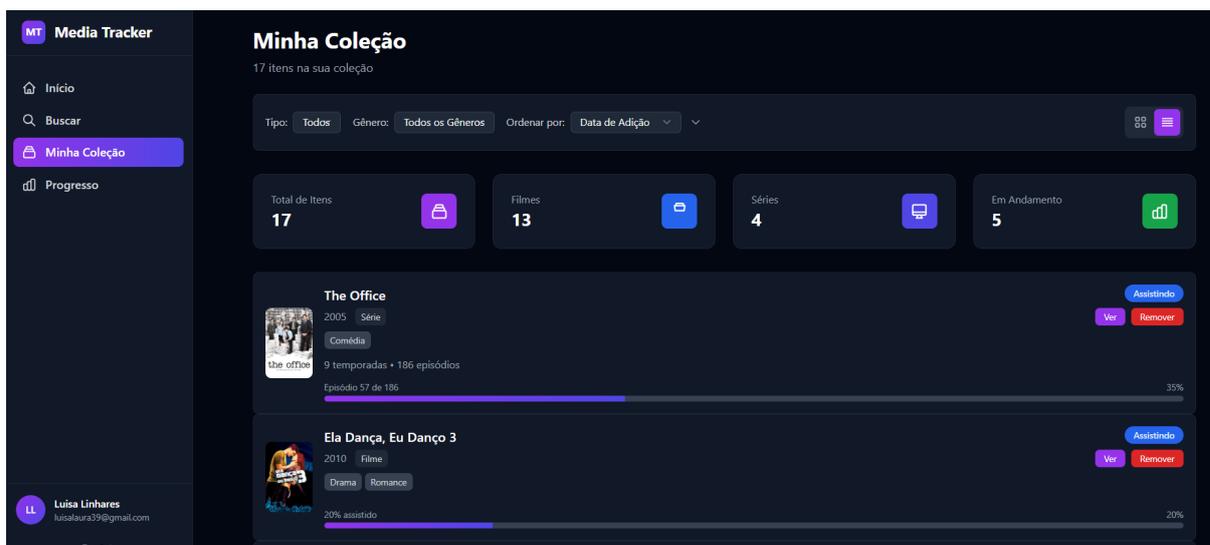
# APÊNDICE A – Materiais elaborados pelo autor

Este apêndice apresenta as visões alternativas do sistema que não foram abordadas no texto principal. Enquanto o texto principal foca na visão em grade, aqui são mostradas as visões em linha e uma tela de progresso que exhibe o conteúdo em andamento.

## A.1 Visão em Linha

A visão em linha foi projetada como uma alternativa à visão em grade, oferecendo uma organização vertical dos itens. Abaixo estão exemplos de como a visão em linha é exibida nas telas de busca e coleção.

Figura 34 – Tela de coleção com visão em linha do sistema Media Tracker.

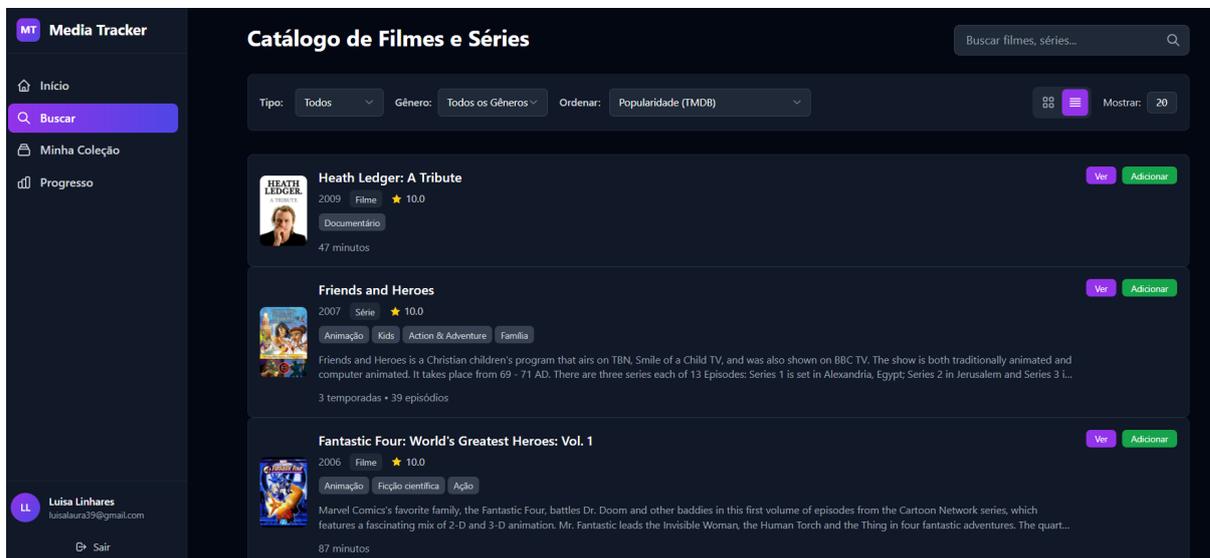


Fonte: Elaborado pela autora.

## A.2 Tela de Progresso

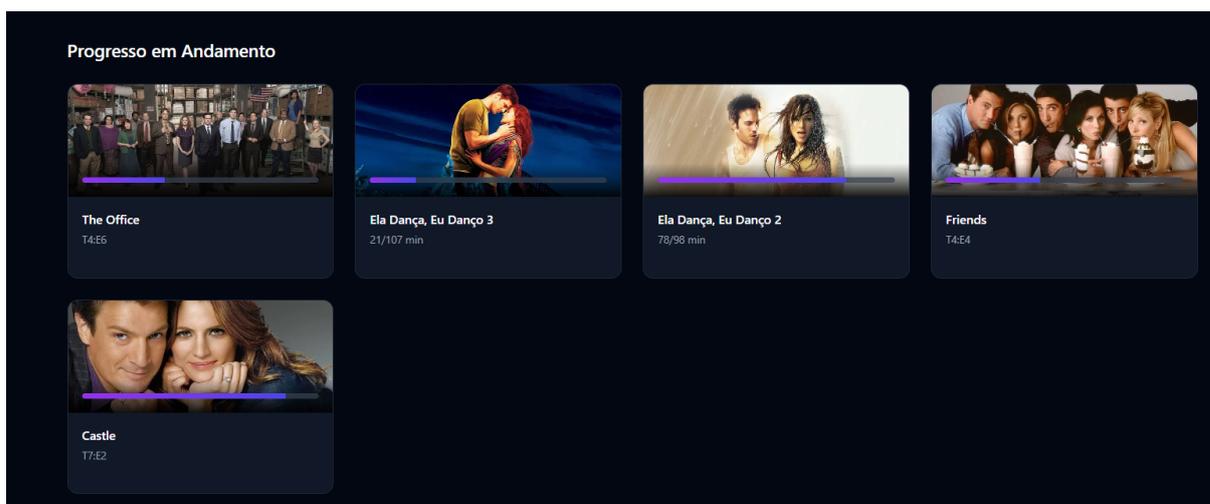
A tela de progresso exhibe os itens que estão em andamento, permitindo ao usuário acompanhar o status de séries e filmes. Abaixo está a visão correspondente.

Figura 33 – Tela de busca com visão em linha do sistema Media Tracker.



Fonte: Elaborado pela autora.

Figura 35 – Tela de progresso com itens em andamento do sistema Media Tracker.



Fonte: Elaborado pela autora.

# APÊNDICE B – Avaliação da Plataforma Media Tracker – Formulário Google

Este apêndice apresenta o formulário de avaliação desenvolvido no Google Forms para coleta de feedback dos usuários sobre a plataforma Media Tracker. O questionário foi elaborado como instrumento de pesquisa visando avaliar a usabilidade, funcionalidades e experiência do usuário com a aplicação web desenvolvida.

O formulário foi estruturado de forma a permitir que os participantes testem as principais funcionalidades da plataforma antes de responder às questões, garantindo assim uma avaliação baseada na experiência prática de uso. As funcionalidades avaliadas incluem busca por texto e imagem utilizando inteligência artificial, gerenciamento de coleções pessoais de filmes e séries, acompanhamento de progresso de visualização e uso de filtros e estatísticas.

A metodologia adotada solicita que os usuários primeiro acessem a plataforma através do link fornecido (<<https://mango-wave-03b0faa0f.2.azurestaticapps.net>>), criem uma conta, testem as funcionalidades principais e, posteriormente, respondam às questões de avaliação. Esta abordagem permite obter feedback qualificado sobre a experiência real de uso da aplicação.

## B.1 Estrutura do Questionário

O formulário está dividido em seções distintas para melhor organização da coleta de dados:

1. **Perfil do Usuário (Questões 1–4):** coleta informações demográficas e de perfil tecnológico dos participantes, incluindo faixa etária, frequência de consumo de mídia, experiência prévia com plataformas similares e nível de familiaridade com tecnologia;
2. **Primeira Impressão (Questões 5–6):** avalia a percepção inicial dos usuários sobre o design da interface e facilidade de navegação na plataforma;
3. **Funcionalidades Específicas (Questões 7–10):** examina detalhadamente o desempenho das principais funcionalidades: busca por texto, busca por imagem com IA, gerenciamento de coleção pessoal e controle de progresso de visualização;
4. **Usabilidade (Questões 11–13):** analisa aspectos técnicos como velocidade de carregamento, organização visual das informações e utilidade dos filtros de busca;

5. **Experiência Geral (Questões 14–17):** identifica as funcionalidades mais valorizadas pelos usuários, pontos que necessitam melhorias, intenção de recomendação e avaliação geral numa escala de 0–10;
6. **Feedback Aberto (Questões 18–20):** permite aos participantes expressar livremente dificuldades encontradas, sugestões de novas funcionalidades e comentários adicionais.

## B.2 Apresentação do Formulário

A seguir são apresentadas todas as páginas do formulário de avaliação, organizadas sequencialmente conforme a experiência do usuário participante da pesquisa.

Figura 36 – Página inicial do formulário com instruções de teste e apresentação da pesquisa.

## Avaliação da Plataforma Media Tracker

Prezado(a), muito obrigado pela sua colaboração! Esta pesquisa faz parte de um Trabalho de Conclusão de Curso (TCC) sobre o desenvolvimento da plataforma **Media Tracker** - uma aplicação Web para gerenciamento de filmes e séries personalizada com funcionalidades de inteligência artificial.

A plataforma permite organizar sua coleção pessoal de mídia, acompanhar progresso de visualização e realizar buscas inteligentes por texto e imagem utilizando tecnologias de IA.

### INSTRUÇÕES PARA TESTE

Antes de responder, por favor:

1. **Acesse a plataforma:** <https://mango-wave-03b0faa0f.2.azurestaticapps.net>
2. **Crie uma conta** ou faça login.
3. **Teste as funcionalidades principais:**
  - Faça uma busca por texto (ex: "Friends", "Harry Potter").
  - Experimente a busca por imagem por meio do upload de um pôster ou screenshot.
  - Adicione alguns filmes/séries à sua coleção.
  - Atualize o progresso de visualização de algum item.
  - Explore os filtros e estatísticas.

### PERFIL DO USUÁRIO

1/9

Fonte: Elaborado pela autora.

A Figura 36 apresenta a página inicial do formulário, contendo as instruções detalhadas para os participantes da pesquisa. Esta seção orienta os usuários sobre como acessar a plataforma, criar uma conta e testar as funcionalidades principais antes de responder ao questionário, garantindo que a avaliação seja baseada na experiência prática de uso.

Figura 37 – Seção “Perfil do Usuário” – questões sobre idade, frequência de uso, experiência prévia e familiaridade tecnológica.

1. **Qual sua idade? \***
  - 18-25 anos
  - 26-35 anos
  - 36-45 anos
  - 46-55 anos
  - Mais de 55 anos
  
2. **Com que frequência você assiste filmes e/ou séries? \***
  - Diariamente
  - Algumas vezes por semana
  - Semanalmente
  - Algumas vezes por mês
  - Raramente
  
3. **Você já utilizou alguma plataforma para gerenciar filmes/séries que assistiu? \***
  - Sim (IMDb, Letterboxd, Trakt, etc.)
  - Não, mas gostaria de usar
  - Não e não tenho interesse
  
4. **Qual seu nível de familiaridade com tecnologia? \***
  - Muito alto - uso tecnologias avançadas regularmente
  - Alto - me adapto facilmente a novas plataformas
  - Médio - uso o básico sem dificuldades
  - Baixo - preciso de ajuda ocasionalmente
  - Muito baixo - tenho muitas dificuldades

Fonte: Elaborado pela autora.

Na Figura 37 são apresentadas as questões iniciais do formulário, destinadas à caracterização do perfil dos participantes. Esta seção coleta informações sobre faixa etária, frequência de consumo de filmes e séries, experiência prévia com plataformas similares de gerenciamento de mídia e nível de familiaridade com tecnologia, permitindo uma análise

segmentada dos resultados.

Figura 38 – Seções “Primeira Impressão” e início de “Funcionalidades Específicas” – avaliação de design, navegação e busca por texto.

### PRIMEIRA IMPRESSÃO

5. **Primeira impressão sobre o design da plataforma:** \*

- Excelente - design moderno e muito atrativo
- Bom - design agradável
- Regular - design comum
- Ruim - precisa melhorar
- Muito ruim - design desagradável

6. **A navegação inicial foi:** \*

- Muito intuitiva, encontrei tudo facilmente
- Intuitiva, consegui navegar sem dificuldades
- Razoável, tive algumas dúvidas
- Confusa, precisei de tempo para entender
- Muito confusa, não consegui navegar adequadamente

### FUNCIONALIDADES ESPECÍFICAS

7. **Como avalia a funcionalidade de BUSCA por texto?** \*

- Excelente, encontrou exatamente o que procurava
- Boa, resultados relevantes na maioria das vezes
- Regular, alguns resultados úteis
- Ruim, poucos resultados relevantes
- Muito ruim, não encontrou resultados úteis
- Não testei esta funcionalidade

A Figura 38 apresenta as questões relacionadas à primeira impressão dos usuários sobre a plataforma, incluindo avaliação do design visual e facilidade de navegação. Adicio-

nalmente, inicia-se a seção de funcionalidades específicas com a avaliação da busca por texto, funcionalidade fundamental da aplicação.

Figura 39 – Continuação da seção “Funcionalidades Específicas” – avaliação de busca por imagem, coleção pessoal e controle de progresso.

8. **Como avalia a funcionalidade de BUSCA por imagem realizada por IA?** \*

- Excelente, identificou corretamente as imagens
- Boa, identificação precisa na maioria dos casos
- Regular, identificação parcialmente correta
- Ruim, identificação incorreta frequentemente
- Muito ruim, não funcionou adequadamente
- Não testei esta funcionalidade

9. **Como avalia o gerenciamento da COLEÇÃO PESSOAL?** \*

- Excelente, muito fácil adicionar/remover itens
- Bom, processo simples e claro
- Regular, funciona mas poderia ser melhor
- Ruim, processo complicado
- Muito ruim, muito difícil de usar
- Não testei esta funcionalidade

10. **Como avalia o controle de PROGRESSO de visualização?** \*

- Excelente, muito prático e completo
- Bom, funcionalidade útil e clara
- Regular, funciona mas falta algo
- Ruim, difícil de usar
- Muito ruim, não atende às necessidades
- Não testei esta funcionalidade

**USABILIDADE**

Na Figura 39 são apresentadas as questões específicas sobre as funcionalidades mais inovadoras da plataforma: a busca por imagem utilizando inteligência artificial, o

gerenciamento da coleção pessoal de filmes e séries, e o controle de progresso de visualização. Estas funcionalidades representam os principais diferenciais da aplicação desenvolvida.

Figura 40 – Seção “Usabilidade” – avaliação de velocidade, organização visual e utilidade dos filtros.

11. **A velocidade de carregamento das páginas foi:** \*

- Muito rápida (menos de 1 segundo)
- Rápida (entre 1 e 2 segundos)
- Aceitável (entre 3 e 4 segundos)
- Lenta (entre 5 e 7 segundos)
- Muito lenta (mais de 7 segundos)

12. **A organização das informações na tela é:** \*

- Muito clara, todas as informações bem posicionadas
- Clara, informações bem organizadas
- Razoável, organização aceitável
- Confusa, informações mal posicionadas
- Muito confusa, layout desorganizado

13. **Os filtros e opções de busca são:** \*

*Marque todas que se aplicam.*

- Muito úteis, facilitam muito a busca
- Úteis, ajudam a encontrar conteúdo
- Razoáveis, funcionam adequadamente
- Pouco úteis, não ajudam muito
- Inúteis, não funcionam bem

**EXPERIÊNCIA GERAL**

A Figura 40 apresenta a seção dedicada à avaliação da usabilidade da plataforma, abordando aspectos técnicos e de experiência do usuário como velocidade de carregamento

das páginas, organização das informações na interface e utilidade dos filtros e opções de busca disponíveis.

Figura 41 – Seção “Experiência Geral” – funcionalidades mais úteis, pontos de melhoria e intenção de recomendação.

14. **Qual funcionalidade considerou mais útil/inovadora? \***

- Busca por imagem com IA
- Controle detalhado de progresso
- Organização da coleção pessoal
- Interface intuitiva
- Filtros de busca
- Estatísticas de visualização

15. **Qual funcionalidade precisa de mais melhorias? \***

- Busca por imagem
- Busca por texto
- Gerenciamento da coleção
- Controle de progresso
- Interface/Design
- Velocidade do sistema

16. **Você recomendaria esta plataforma para outros usuários? \***

- Definitivamente sim
- Provavelmente sim
- Talvez
- Provavelmente não
- Definitivamente não

Na Figura 41 são apresentadas questões sobre a experiência geral do usuário com a plataforma, incluindo a identificação das funcionalidades consideradas mais úteis ou

inovadoras, aspectos que necessitam melhorias e a intenção de recomendação da plataforma para outros usuários.

Figura 42 – Avaliação geral em escala numérica e início da seção “Feedback Aberto” com questões dissertativas.

17. **Avaliação geral da plataforma (0-10): \***

- 10 - Excelente
- 9 - Muito bom
- 8 - Bom
- 7 - Satisfatório
- 6 - Regular
- 5 - Mediano
- 4 - Abaixo da média
- 3 - Ruim
- 2 - Muito ruim
- 1 - Péssimo
- 0 - Não funcionou

**FEEDBACK ABERTO**

18. **Descreva a maior dificuldade que enfrentou ao usar a plataforma:**

---

---

---

---

---

19. **Que funcionalidade você gostaria que fosse adicionada?**

---

---

---

---

---

A Figura 42 apresenta a avaliação geral da plataforma em escala numérica de 0 a 10, permitindo uma quantificação da satisfação dos usuários. Adicionalmente, inicia-se

a seção de feedback aberto com questões dissertativas sobre dificuldades enfrentadas e funcionalidades desejadas.

Figura 43 – Finalização do formulário com campo para comentários adicionais e agradecimento aos participantes.

20. **Comentários adicionais, sugestões ou bugs encontrados:** \*

---

---

---

---

---

**Muito obrigada pela sua participação! Seu feedback é fundamental para o aprimoramento da plataforma Media Tracker.**

---

Por fim, a Figura 43 apresenta a conclusão do formulário com um campo aberto para comentários adicionais, sugestões ou relatos de bugs encontrados, seguido do agradecimento

aos participantes da pesquisa. Esta seção permite a coleta de feedback qualitativo adicional que pode não ter sido contemplado nas questões estruturadas anteriores.

### **B.3 Considerações sobre o Questionário**

O formulário desenvolvido contempla uma avaliação abrangente da plataforma Media Tracker, cobrindo aspectos técnicos, funcionais e de experiência do usuário. A estrutura sequencial das questões, partindo do perfil do participante até a avaliação detalhada das funcionalidades, permite uma análise sistemática dos dados coletados.

A inclusão de questões tanto objetivas quanto dissertativas proporciona uma visão quantitativa e qualitativa da percepção dos usuários sobre a aplicação, fornecendo dados essenciais para a validação da proposta desenvolvida e identificação de oportunidades de melhoria.