UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Faculdade de Filosofia e Ciências
Programa de Pós-Graduação em Ciência da Informação

MARCOS ANTONIO SIQUEIRA

Metadados de *Large Language Models* sob a perspectiva da Ciência da Informação: Proposta de Perfil de Aplicação de Metadados para LLMs Personalizados

Marília
2026

MARCOS ANTONIO SIQUEIRA

Metadados de *Large Language Models* sob a perspectiva da Ciência da Informação: proposta de Perfil de Aplicação de Metadados para LLMs Personalizados

Tese apresentada ao Programa de Pós-Graduação em Ciência da Informação, da Universidade Estadual Paulista (UNESP), como requisito para obtenção do título de Doutor em Ciência da Informação.

Área de Concentração: Informação, Tecnologia e Conhecimento.

Linha de Pesquisa: Informação e Tecnologia

Financiadora: CAPES - PROEX – Proc. 88887.694015/2022-00 (06/2022 a 01/2023)

Orientadora: Profa. Dra. Rachel Cristina Vesu Alves
Coorientador: Prof. Dr. Caio Saraiva Coneglian

Marília
2026

S618

Siqueira, Marcos Antonio
Metadados de Large Language Models sob a perspectiva da Ciência da Informação : proposta de perfil de aplicação de metadados para LLMs personalizados / Marcos Antonio Siqueira. -- Marília, 2026
134 f. : il., tabs.

Tese (doutorado) - Universidade Estadual Paulista (UNESP), Faculdade de Filosofia e Ciências, Marília
Orientadora: Rachel Cristina Vesu Alves

1. Metadados. 2. Perfil de Aplicação de Metadados. 3. Library

Sistema de geração automática de fichas catalográficas da Unesp. Dados fornecidos pelo autor(a).

IMPACTO POTENCIAL DESTA PESQUISA

A integração dos *Large Language Models* (LLMs) personalizados em diversos setores da sociedade contemporânea reconfigura paradigmas de interação humano-computador e produção informacional. Esta tese, ao propor um perfil de aplicação de metadados para LLMs personalizados, doravante denominado MAP-CLLM, estabelece pontos de convergência com os Objetivos de Desenvolvimento Sustentável (ODS) concentrando-se em dimensões onde a estruturação da informação é condição para o desenvolvimento tecnológico responsável. A conexão com o **ODS 4 (Educação de Qualidade)**, manifesta-se na qualificação dos LLMs como recursos educacionais digitais. A ausência de padrões para a representação de agentes inteligentes personalizados dificulta sua integração criteriosa em ambientes de aprendizagem. O MAP-CLLM provê a estrutura necessária para a descoberta, a avaliação e o reuso dessas ferramentas como mediadores pedagógicos, assegurando que o acesso ao conhecimento mediado por IA seja fundamentado em critérios de proveniência e fidedignidade informacional. No âmbito do **ODS 9 (Indústria, Inovação e Infraestrutura)**, a pesquisa contribui para a consolidação de infraestruturas de dados robustas. A aplicação do rigor da Ciência da Informação ao cenário da Inteligência Artificial Generativa fomenta a inovação sustentável, provendo modelos de representação que contribuem para a solidez técnica e a interoperabilidade sistêmica necessária para a economia digital e o avanço científico. Por fim, relativo ao **ODS 16 (Paz, Justiça e Instituições Eficazes)**, o estudo endereça a problemática da opacidade algorítmica. Ao propor elementos de metadados voltados à explicabilidade e à documentação de limitações éticas, a tese oferece subsídios para o fortalecimento de instituições transparentes comprometidas em diminuir riscos associados a vieses informacionais, promovendo a governança ética e confiável da informação.

POTENTIAL IMPACT OF THIS RESEARCH

The integration of customized Large Language Models (LLMs) into various sectors of contemporary society is reshaping paradigms of human-computer interaction and information production. By proposing a metadata application profile for customized LLMs—hereinafter referred to as MAP-CLLM—this thesis establishes points of convergence with the Sustainable Development Goals (SDGs), focusing on dimensions where information structuring is a prerequisite for responsible technological development. The connection to **SDG 4 (Quality Education)** is evident in the characterization of LLMs as digital educational resources. The lack of standards for representing customized intelligent agents hinders their judicious integration into learning environments. MAP-CLLM provides the necessary framework for the discovery, evaluation, and utilization of these tools as pedagogical mediators, ensuring that AI-mediated access to knowledge is grounded in criteria regarding provenance and informational reliability. Within the scope of **SDG 9 (Industry, Innovation, and Infrastructure)**, the research contributes to the development of robust data infrastructures. Applying the rigor of Information Science to the landscape of Generative Artificial Intelligence fosters sustainable innovation by validating representation models that deliver the technical solidity and systemic interoperability essential for the digital economy and scientific advancement. Finally, regarding **SDG 16 (Peace, Justice, and Strong Institutions)**, the study addresses the issue of algorithmic opacity. By proposing metadata elements specific to explainability and the documentation of ethical limitations, the thesis supports the strengthening of transparent institutions committed to mitigating risks associated with informational biases, thereby promoting ethical governance and trust in information.

MARCOS ANTONIO SIQUEIRA

Metadados de *Large Language Models* sob a perspectiva da Ciência da Informação: Proposta de Perfil de Aplicação de Metadados para LLMs Personalizados

Tese apresentada ao Programa de Pós-Graduação em Ciência da Informação, da Universidade Estadual Paulista (UNESP), como requisito para obtenção do título de Doutor em Ciência da Informação.

Área de Concentração: Informação, Tecnologia e Conhecimento.

Linha de Pesquisa: Informação e Tecnologia

Financiadora: CAPES - PROEX – Proc. 88887.694015/2022-00 (06/2022 a 01/2023)

Orientadora: Profa. Dra. Rachel Cristina Vesu Alves

Coorientador: Prof. Dr. Caio Saraiva Coneglian

BANCA EXAMINADORA

Prof. Dr. Ricardo César Gonçalves Sant'Ana
Programa de Pós-Graduação em Ciência da Informação UNESP

Prof. Dr. Fabiano Ferreira de Castro
Programa de Pós-Graduação em Ciência da Informação UNESP

Prof. Dr. Fernando de Assis Rodrigues
Programa de Pós-Graduação em Ciência da Informação - UFPA

Prof. Dr. Felipe Augusto Arakaki
Programa de Pós-Graduação em Ciência da Informação - UNB

Marília, 30 de junho de 2026.

À minha esposa Karina Siqueira.

AGRADECIMENTOS

À minha esposa, Karina Siqueira, pelo apoio incondicional, pela paciência e pela colaboração profissional nas discussões sobre a aplicação da inteligência artificial no cenário da nutrição, que serviram de inspiração para exemplificar a aplicação do MAP-CLLM em cenário real.

À minha orientadora, Prof.ª Dr.ª Rachel Cristina Vesu Alves, pela orientação, pela confiança depositada desde o início desta pesquisa e pelo compartilhamento generoso de sua experiência. Sua condução foi fundamental para o amadurecimento das reflexões aqui apresentadas e para a consolidação desta proposta de perfil de aplicação de metadados.

Aos membros da banca examinadora, Prof. Dr. Ricardo César Gonçalves Sant'Ana (UNESP), Prof. Dr. Fabiano Ferreira de Castro (UNESP), Prof. Dr. Fernando de Assis Rodrigues (UFPA) e Prof. Dr. Felipe Augusto Arakaki (UNB). As críticas, sugestões e o diálogo acadêmico estabelecido durante as etapas de qualificação e defesa foram indispensáveis para o aprimoramento deste trabalho e para minha formação enquanto pesquisador.

À empresa SysManager (www.sysmanager.com.br), pelo apoio institucional e pelo suporte técnico-científico. O acesso às ferramentas e os treinamentos disponibilizados foram cruciais para a experimentação prática e para a compreensão dos desafios reais que envolvem a personalização de *Large Language Models* (LLMs) em ambientes corporativos.

À Thamiris Silva (thamirisiaras@gmail.com) pela simpatia, dedicação e profissionalismo na revisão deste trabalho, que incluiu o rigoroso cuidado com a normalização e com as referências. Sua competência foi fundamental para a finalização desta tese.

À Seção Técnica de Pós-Graduação da Faculdade de Filosofia e Ciências (FFC/UNESP) - Campus de Marília, SP, pelo atendimento sempre solícito e pelo auxílio nos trâmites administrativos necessários ao longo deste doutorado.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

RESUMO

Esta tese analisa a estrutura de metadados para *Large Language Models* (LLMs) sob a perspectiva da Ciência da Informação (CI), propondo um Perfil de Aplicação de Metadados (MAP) para LLMs personalizados, denominado MAP-CLLM. Reconhecendo a crescente relevância dos LLMs e a necessidade de controle e representação informacional, o estudo justifica-se pela lacuna na literatura sobre diretrizes formais para a organização e representação de metadados de modelos de Inteligência Artificial Generativa (IAG). O objetivo principal reside em desenvolver e apresentar o MAP-CLLM, visando padronizar a representação de LLMs personalizados e viabilizar a interoperabilidade, a recuperação e o reuso informacional. A metodologia de natureza aplicada, com abordagem qualitativa e objetivo exploratório-descritivo, operacionaliza uma revisão de literatura e análise documental, servindo-se do modelo conceitual LRM para a desconstrução do objeto de estudo, um LLM personalizado, fundamentada na literatura da CI focada na determinação de metadados e, na literatura da Ciência da Computação (CC) para especificações de metadados presentes em ferramentas de personalização de LLMs. A pesquisa realiza a análise e integração do padrão Dublin Core, do vocabulário Schema.org e do *framework Model Cards*, adaptando-os ao contexto da IAG. Os resultados culminam no MAP-CLLM, um conjunto de elementos que incorpora requisitos funcionais e estruturais específicos para contribuir para uma explicabilidade contextual de LLMs personalizados. O perfil é detalhado por meio de um *Description Set Profile* (DSP). Conclui-se que o MAP-CLLM constitui-se como uma estrutura fundamentada pela CI para a gestão de metadados de LLMs personalizados, contribuindo para a governança, transparência e confiabilidade desses objetos informacionais.

Palavras-chave: metadados; perfil de aplicação de metadados; library reference model; dublin core; schema.org; *model cards*; modelo de linguagem de grande escala; inteligência artificial.

ABSTRACT

This thesis analyzes the metadata structure for Large Language Models (LLMs) from the perspective of Information Science (IS), proposing a Metadata Application Profile (MAP) for customized LLMs, designated as MAP-CLLM. Acknowledging the growing relevance of LLMs and the need for informational control and representation, the study is justified by a gap in the literature regarding formal guidelines for the organization and representation of metadata for Generative Artificial Intelligence (GAI) models. The primary objective is to develop and present MAP-CLLM, aiming to standardize the representation of customized LLMs and enable interoperability, retrieval, and information reuse. The methodology—applied in nature, qualitative in approach, and exploratory-descriptive in objective—operationalizes a literature review and document analysis. It employs the LRM conceptual model to deconstruct the object of study (a customized LLM), grounded in IS literature focused on metadata determination and in Computer Science (CS) literature regarding metadata specifications found in LLM customization tools. The research analyzes and integrates the Dublin Core standard, the Schema.org vocabulary, and the Model Cards framework, adapting them to the GAI context. The results culminate in MAP-CLLM, a set of elements incorporating specific functional and structural requirements to contribute to the contextual explainability of customized LLMs. The profile is detailed through a Description Set Profile (DSP). The study concludes that MAP-CLLM constitutes an IS-grounded framework for managing metadata for customized LLMs, contributing to the governance, transparency, and trustworthiness of these information objects.

Keywords: metadata; metadata application profile; library reference model; dublin core; schema.org; model cards; large language model; artificial intelligence.

LISTA DE ILUSTRAÇÕES

Figura 1 – Diagrama proposto por Sant'Ana (2022) desta pesquisa 27
Figura 2 – Um panorama referente aos termos relacionados a IA 29
Figura 3 – Cenários relacionados a personalização de um LLM 36
Figura 4 – Interface do Google AI Studio 39
Figura 5 – Interface do Gemini Gem 42

LISTA DE QUADROS

Quadro 1 –	Cenários relacionados a personalização de um LLM	36
Quadro 2 –	Principais parâmetros de configuração no Google AI Studio	40
Quadro 3 –	Componentes Instrucionais para a Criação de um Gemini Gem	43
Quadro 4 –	Os 15 Elementos do Dublin Core Metadata Element Set (DCMES)	65
Quadro 5 –	Processo de Desenvolvimento de um Perfil de Aplicação	73
Quadro 6 –	Dublin Core aplicado a um LLM personalizado	86
Quadro 7 –	Metadados determinados a partir dos Model Cards e ferramentas Google	89
Quadro 8 –	Mapeamento (De/Para) entre Model Cards e Dublin Core	96
Quadro 9 –	Description Set Profile (DSP) para LLMs personalizados	97
Quadro 10 –	Mapeamento (De/Para) entre MAP e Schema.org	105
Quadro 11 –	DSP de um LLM personalizado para a área de Nutrição (TiaNutri)	125

LISTA DE ABREVIATURAS E SIGLAS

CC	Ciência da Computação
CI	Ciência da Informação
CNN	Convolutional Neural Network
DC	Dublin Core
DCMES	Dublin Core Metadata Element Set
DCMI	Dublin Core Metadata Initiative
DL	Deep Learning
DSP	Description Set Profile
GPT	Generative Pre-trained Transformer
IA	Inteligência Artificial
IAG	Inteligência Artificial Generativa
IFLA	International Federation of Library Associations and Institutions
LLM	Large Language Model
LRM	Library Reference Model
MAP	Metadata Application Profile
MAP-CLLM	Metadata Application Profile for Custom Large Language Models
ML	Machine Learning
NISO	National Information Standards Organization
PLN	Processamento de Linguagem Natural
RAG	Retrieval Augmented Generation
RNA	Rede Neural Artificial
RNN	Recurrent Neural Network
URI	Uniform Resource Identifiers

SUMÁRIO

1 INTRODUÇÃO.....14
1.1 Problema de pesquisa, tese e hipótese.....15
1.2 Objetivos: geral e específicos.....17
1.3 Justificativa, relevância e motivação da pesquisa.....18
2 METODOLOGIA.....20
3 ESTRUTURA DA PESQUISA.....28
4 LARGE LANGUAGE MODEL - LLM.....29
4.1 Fundamentos da tecnologia Large Language Model - LLM.....31
4.2 Processo de personalização de um Large Language Model.....37
4.3 Inteligência Artificial Confiável fundamentada em Metadados.....44
4.4 Model Cards: representação da informação para LLMs personalizados.....48
5 METADADOS NO CONTEXTO DA CIÊNCIA DA INFORMAÇÃO.....55
5.1 Determinação de Metadados.....56
5.2 Library Reference Model – LRM.....59
5.3 O padrão Dublin Core.....63
5.4 O vocabulário Schema.org.....69
5.5 Perfil de Aplicação de Metadados.....72
6 PROPOSTA DE PERFIL DE APLICAÇÃO DE METADADOS PARA LLMS PERSONALIZADOS.....79
6.1 Requisitos Funcionais.....81
6.2 Modelo Relacional.....84
6.3 Description Set Profile - DSP.....85
6.4 Diretrizes de Uso.....104
6.5 Definição da Sintaxe e Esquema de Codificação.....105
7 CONSIDERAÇÕES FINAIS.....112
REFERÊNCIAS.....117
APÊNDICE A – APLICAÇÃO PRÁTICA E EXEMPLIFICAÇÃO DO MAP-CLLM EM UM CENÁRIO HIPOTÉTICO DA ÁREA DA NUTRIÇÃO.....125

1 INTRODUÇÃO

A sociedade contemporânea observa a ascensão e a integração dos *Large Language Models* (LLMs) em múltiplos setores, provocando transformações estruturais na produção da informação, no desenvolvimento de software e na interação humano-computador (Pinheiro, 2024). Tais modelos de Inteligência Artificial (IA), oriundos de avanços significativos na área da Ciência da Computação (CC), são projetados para processar e gerar linguagem humana com fluidez e coerência fazendo emergir a chamada Inteligência Artificial Generativa (IAG) (Silva; Cazella, 2024). Não obstante, o potencial impacto nos processos informacionais dos LLMs é acompanhado por desafios vinculados à sua complexidade. Frequentemente caracterizados como caixas-pretas, seus processos internos de tomada de decisão são obscuros, suscitando preocupações legítimas acerca de confiança, transparência, vieses e responsabilidades (Mitchell e*t al.*, 2019).

Os LLMs, como a família de modelos Gemini desenvolvida pela empresa Google, neste contexto denominado como modelos de base, estabeleceram novas formas de produção e interação com a informação (Google, 2025a). No cerne dessa transformação emerge uma nova categoria de objeto informacional denominado LLM personalizado. Ferramentas como o Google AI Studio e os Gemini Gems permitem que diferentes classes de usuários adaptem e configurem esses LLMs, os modelos de base, para casos de uso específicos, gerando instâncias de conversação especializadas, caracterizando um LLM personalizado, dentro do contexto desta pesquisa, como um objeto informacional complexo (Gilliland, 2016; Haynes, 2018; Google, 2025b; Google, 2025c).

O desafio é acentuado pela ampliação do acesso a essas ferramentas de personalização, por exemplo, Google AI Studio e Gemini Gems, que possibilitam a usuários, com ou sem aprofundado conhecimento técnico, a criação de versões personalizadas de LLMs para tarefas específicas (Google, 2025a). Cada "Gem", por exemplo, configura um novo objeto informacional, com seu próprio conjunto de instruções, base de conhecimento, comportamento e, consequentemente, seus vieses e limitações. Essa proliferação de LLMs personalizados culmina em um crescimento exponencial de objetos informacionais de natureza complexa, cuja ausência de padronização documental constitui uma limitação para sua governança. Os repositórios que armazenam esses LLMs personalizados estão disponíveis ao público em geral, inclusive gratuitamente, por empresas como Google, Microsoft e OpenAI. Em outros casos, essas mesmas empresas possibilitam ao usuário que personalizou um LLM compartilhar de forma restrita a pessoas específicas (Google, 2025c).

Diferentemente de recursos informacionais digitais tradicionais, como documentos de texto, imagens ou vídeos, que apresentam conteúdo, ou fontes de conteúdo, previamente definido e previsível, os LLMs personalizados são, por sua natureza, dinâmicos, interativos e configuráveis. Seu comportamento e o conteúdo que geram são o resultado de uma complexa interação com um conjunto de instruções e parâmetros definidos pelo seu criador, ou personalizador, e a entrada fornecida pelo usuário final (Google, 2025b; Google, 2025c; Vaswani, 2017). Esta complexidade impõe um desafio significativo à Ciência da Informação (CI), cuja missão abrange, entre outras funções, a coleta, organização, armazenamento, recuperação e disseminação da informação (Formenton *et al.*, 2017).

Diante desse cenário, emergem questões legítimas relacionadas a como representar um LLM personalizado de forma sistemática, padronizada e interoperável, especialmente sobre a determinação de quais metadados são adequados para representar um LLM personalizado como um recurso informacional que seja confiável, compreensível e passível de avaliação por seus usuários e pela sociedade.

Para desconstruir a complexidade associada ao processo de personalização de um LLM e fundamentar teoricamente a proposição de um perfil de aplicação de metadados, esta pesquisa adota o modelo conceitual *Library Reference Model* (LRM), desenvolvido pela *International Federation of Library Associations and Institutions* (IFLA), que permitiu decompor um LLM personalizado nas entidades Obra, Expressão, Manifestação e Item (Riva; Le Bœuf; Žumer, 2020). Para uma aplicação prática de metodologias relacionadas a CI, em consonância com o LRM, propõe-se especificamente a criação de um Perfil de Aplicação de Metadados (*Metadata Application Profile* - MAP), um instrumento que permite a descrição estruturada de recursos de informação por meio da combinação e refinamento de esquemas de metadados existentes, por exemplo, o conceito de *Model Cards*, o padrão de metadados Dublin Core (DC) e o vocabulário de metadados Schema.org (International Conference on Dublin Core and Metadata Applications (DC), 2015).

1.1 Problema de pesquisa, tese e hipótese

Os LLMs estabeleceram um marco na produção e interação com a informação, ampliado pela possibilidade de personalizar um LLM. Plataformas que permitem essa personalização estão cada vez mais acessíveis a usuários diversos indicando uma crescente tendência à personalização. Esses LLMs personalizados são dinâmicos, interativos e passíveis de configuração, com suas respostas, o *output* informacional, e comportamentos sendo determinados pela interação complexa entre o modelo de base, as instruções definidas pelo

usuário que o personalizou e a solicitação do usuário final, o *prompt*, o *input* do usuário final. A natureza complexa de um LLM personalizado representa um desafio para todas as áreas e sob diversos aspectos. Destaca-se aqui nesta pesquisa a falta de um padrão de metadados consolidado que possa representar as características técnicas, funcionais e contextuais desse objeto informacional em um ambiente digital. A ausência de um padrão de metadados específico, e também a falta do uso de metadados que representem esse tipo de objeto informacional por alguns profissionais, compromete a sua descoberta, recuperação e avaliação comparativa. Além disso, tal lacuna cria barreiras para a interoperabilidade e gerenciamento desses objetos (Longpre *et al*., 2024). Diante deste cenário, **o problema** a ser abordado nesta pesquisa consiste em: como estabelecer uma estrutura formal, eficiente e padronizada para a representação, identificação e recuperação de um LLM personalizado?

Deste modo, **a hipótese** levantada é que os instrumentos de representação da Ciência da Informação, em especial da catalogação, juntamente com a metodologia para estabelecimento de um Perfil de Aplicação de Metadados (Metadata Application Profile - MAP), constituem-se o suporte necessário para a construção de uma representação robusta para os LLMs personalizados. Acredita-se que um Perfil de Aplicação de Metadados possa representar mais adequadamente um LLM personalizado garantindo uma melhora na sua localização, acesso, interoperabilidade e reutilização em ambientes digitais.

Diante do problema de pesquisa apresentado, **a tese** defendida é que os estudos desenvolvidos sobre metadados na área de Ciência da Informação constituem-se como subsídios para a determinação de uma representação mais robusta para LLM personalizados. A tradição da área no tratamento de recursos informacionais complexos viabiliza a estruturação de perfis de aplicação de metadados capazes de explicitar as dimensões paramétricas, instrucionais e contextuais relacionados aos LLMs personalizados.

A presente investigação optou por usar as ferramentas do ecossistema Google para estudar o processo de personalização de LLMs. Tal escolha não restringe ou invalida as conclusões, e justifica-se principalmente, porque outros fornecedores de modelos de base adotam estratégias análogas, ou seja, essas plataformas oferecem ferramentas direcionadas tanto a especialistas em computação e inteligência artificial quanto a profissionais de outras áreas que, mesmo sem formação técnica aprofundada, demandam a exploração e a aplicação prática da personalização de LLMs. Além disso, destaca-se o conhecimento e a experiência profissional prévia do pesquisador na utilização da ferramenta, o que garante maior domínio de sua utilização, com redução de ruídos e uma análise mais consistente da ferramenta.

A empresa Google disponibiliza o Google AI Studio, uma ferramenta frequentemente empregada por especialistas da área de CC. Contudo, a própria empresa indica que profissionais de outras áreas, incluindo entusiastas de IA, podem usufruir de suas funcionalidades (Google, 2025b). Para o público que não detém nenhum conhecimento especializado em CC, a Google oferece o Gemini Gem (Google, 2025c). Tais ferramentas ampliam o acesso ao processo de personalização de LLMs e a relativa simplicidade na sua utilização ressalta a problemática desta pesquisa.

Plataformas que permitem a personalização de LLMs estão cada vez mais acessíveis a usuários diversos, o que reforça a necessidade de estabelecer uma estrutura formal para uma representação eficiente e padronizada. A ausência de um padrão de metadados consolidado para descrever LLMs personalizados dificulta a governança, a rastreabilidade e a confiabilidade, constituindo uma barreira a ser transposta pela proposta deste estudo. Portanto, um perfil de aplicação de metadados para LLMs personalizados, doravante denominado *Metadata Application Profile for Custom Large Language Models* (MAP-CLLM), apresenta-se como uma proposição metodológica destinada a responder a lacuna apresentada no problema de pesquisa, contribuindo na representação, identificação, recuperação e gerenciamento desses recursos informacionais emergentes.

1.2 Objetivos: geral e específicos

O **objetivo geral** desta pesquisa é propor um Perfil de Aplicação de Metadados (MAP) para LLMs personalizados tendo como base os instrumentos de representação da Ciência da Informação, em especial da catalogação, e nos conceitos da Ciência da Computação, para estabelecimento de uma representação, identificação, recuperação e gerenciamento desses objetos informacionais em ambientes digitais.

Para alcançar este objetivo geral, foram definidos os seguintes **objetivos específicos**:

1. Analisar as características e funcionalidades envolvidas no processo de personalização de um LLM com base na literatura científica e documental da CC.
2. Analisar a literatura científica sobre metadados, os instrumentos de representação na Ciência da Informação (catalogação) e a criação de perfil de aplicação de metadados.
3. Determinar os metadados necessários para representar LLMs personalizados tendo como base os instrumentos de representação da CI e da CC.
4. Propor um perfil de aplicação de metadados para LLMs personalizados contendo a lista de elementos proposta, devidamente estruturada, categorizada e justificada.

1.3 Justificativa, relevância e motivação da pesquisa

Esta pesquisa é guiada pelos aspectos abordados pela linha de pesquisa "Informação e Tecnologia" do Programa de Pós-Graduação em Ciência da Informação (PPGCI)/Unesp - Marília, em especial por:

> **Realizar pesquisas e estudos** teóricos, epistemológicos e **práticos relacionados** à produção, ao processamento, **à representação**, ao acesso, à recuperação, à transferência, à visualização, ao design, à arquitetura, à utilização, à gestão e à preservação de dados, **informação** e de documentos em ambientes digitais, **armazenados em espaços ou sistemas informacionais tecnológicos**, organizacionais e **da sociedade em geral**, associados à metodologias, aos instrumentos e ao uso estratégico das Tecnologias de Informação e Comunicação (TIC). **Desenvolve metodologias informacionais** de interface humano e tecnologias, **em diversificados contextos** de tipo, forma e natureza da informação. **Reflete sobre** as questões apresentadas pelos ambientes informacionais digitais para a construção do conhecimento e da experimentação em torno de **novas formas de acesso**; de organização; de representação, de recuperação; de políticas; e de processamento de dados e **de informação** para a otimização e a personalização de processos e de sistemas informacionais em distintas ambiências no campo de conhecimento da Ciência da Informação (PPGCI, 2024,, grifo nosso).

A justificativa desta pesquisa fundamenta-se na aplicação dos princípios de representação e organização da informação à governança e descrição de recursos baseados em IAG, inserindo-se no domínio da IA Confiável (Phillips *et al.*, 2021; Ridley, 2022; Qin; Yu, 2024). O aporte teórico-metodológico da CI provê as estruturas formais necessárias para a descrição pragmática, a identificação de proveniência e a interoperabilidade de objetos informacionais complexos, permitindo que a personalização de LLMs seja acompanhada do devido rigor documental em ambientes digitais.

A relevância desta pesquisa sustenta-se na proposição de um modelo de representação voltado ao contexto emergente dos LLMs personalizados, cuja opacidade e dinamismo demandam estruturas formais para a descrição de seus atributos constitutivos (Gilliland, 2016; Haynes, 2018). O processo de personalização de um LLM gera um objeto informacional complexo, cujos parâmetros de configuração, instruções de sistema e corpora de alinhamento reconfiguram o comportamento informacional do modelo de base (Google, 2025b; Google, 2025c). Nesse âmbito, a aplicação metodológica voltada à elaboração de um MAP provê os instrumentos necessários para organizar tais variáveis em estruturas padronizadas e interoperáveis, permitindo que esses objetos informacionais complexos sejam identificados, rastreados, avaliados e gerenciados ao longo de seu ciclo de vida em ambientes digitais (Alves, 2010; Nilsson; Baker; Johnston, 2008).

A motivação desta pesquisa reside no impacto social e profissional da democratização das ferramentas de personalização de LLMs que permitem a usuários sem conhecimento em

CC personalizar LLMs para cenários específicos. O aumento desses novos objetos informacionais exige uma descrição e representação padronizada para evitar o caos informacional e os riscos atrelados ao uso não documentado desses recursos. Ao determinar um conjunto de metadados, o estudo não apenas facilita a descoberta e recuperação desses objetos informacionais em ambientes digitais, mas também instrumentaliza a governança da IA ao propor uma representação necessária para que usuários e órgãos reguladores de normativas, portarias ou legislação específica tomem decisões fundamentadas sobre a adoção e o uso responsável de cada LLM personalizado.

Portanto, esta investigação se alinha aos preceitos da IA Confiável ao instrumentalizar a representação e a organização da informação para a consolidação da infraestrutura documental da IAG (Phillips *et a*l., 2021; Qin; Yu, 2024). A determinação de um perfil de aplicação de metadados para LLMs personalizados estabelece diretrizes formais que viabilizam a explicabilidade contextual, integrando parâmetros descritivos e administrativos com requisitos sociais de transparência, rastreabilidade e governança informacional (Baca, 2016; Ridley, 2022). A proposição do MAP-CLLM materializa-se, assim, como uma especificação metodológica estruturada para o tratamento sistemático de recursos informacionais complexos e emergentes (Malta; Baptista; Walk, 2017).

2 METODOLOGIA

Esta é uma pesquisa de natureza aplicada, com abordagem qualitativa e objetivo exploratório-descritivo, configurando-se como uma pesquisa fundamentada em revisão de literatura e análise documental. Segundo Gil (2002) pesquisas exploratórias proporcionam maior familiaridade com o problema enquanto a pesquisa descritiva tem como objetivo primordial a descrição das características de uma determinada população ou fenômeno (Costa; Costa, 2001). No presente estudo, o fenômeno investigado são os atributos constitutivos de um LLM personalizado, conforme manifestados em ferramentas de personalização. A pesquisa exploratória e descritiva se justifica pela intenção de observar, registrar, analisar e correlacionar os fatos e variáveis presentes no fenômeno (Gil, 2002).

Nesta pesquisa, a conexão entre os estudos da CI sobre determinação de metadados para objetos informacionais e os estudos da CC sobre IA no contexto de LLMs e seus modelos de base, especificamente no processo de personalização destes modelos de base, constitui-se o cenário a ser explorado e descrito. Visto que o foco específico está no processo de personalização de LLMs, as ferramentas do ecossistema Google, o Google AI Studio e Gemini Gem, bem como suas interfaces de usuário, suas documentações técnicas e seus tutoriais são considerados na análise documental realizada. Portanto, o objeto de pesquisa considerado neste estudo é um LLM personalizado, deste modo, esta metodologia fornece a base teórica e metodológica para investigar a personalização de LLMs focando nos fatores que moldam a criação e o comportamento desses objetos informacionais complexos.

A técnica selecionada para a coleta e análise de dados é a Análise Documental, considerada central para a pesquisa, especialmente ao definir a premissa de que as próprias interfaces das ferramentas e sua documentação associada contêm todos os detalhes necessários para explorar e descrever o processo de personalização de um LLM. A Análise Documental é um método que envolve a identificação, seleção, avaliação e síntese de dados contidos em documentos, que podem ser escritos, visuais ou audiovisuais (Alves *et al*., 2021). Conforme Sá-Silva, Almeida e Guindani (2009, p. 4), quando um pesquisador utiliza documentos para extrair deles informações, está investigando, examinando e usando técnicas apropriadas para seu manuseio e análise. Para esta tese, os documentos analisados são fontes primárias, estáveis e ricas em informações, e incluem:

- As interfaces de usuário das ferramentas Google AI Studio e Gemini Gem.
- A documentação oficial da *Application Programming Interface* (API) Gemini.
- Os guias de início rápido, tutoriais e exemplos fornecidos pela Google.

- As políticas de uso e segurança relacionadas aos modelos.

Esses documentos digitais representam a manifestação explícita e oficial do conhecimento, das práticas e das funcionalidades relacionadas ao processo de personalização de LLMs. A análise dessas fontes, por exemplo, a documentação da API do Gemini, possibilita desvelar o conjunto de regras e protocolos que permite que diferentes softwares se comuniquem, troquem dados e compartilhem funcionalidades, bem como os elementos, configurações, parâmetros e restrições que definem o LLM personalizado. O processo analítico seguiu as etapas de seleção do material, análise crítica do contexto de produção dos documentos, organização das informações em categorias e, por fim, a síntese que culmina na proposição do perfil de aplicação de metadados MAP-CLLM (Alves *et al*., 2021).

A revisão de literatura realizada, com base na literatura disponível sobre LLMs e metadados, especificamente sobre determinação de metadados, permitiu "[...] mapear e discutir uma certa produção acadêmica em diferentes campos do conhecimento [...]" (Ferreira, 2002, p. 258) auxiliando no entendimento de pontos-chave, na compreensão do problema proposto e na construção dos resultados esperados. A literatura estudada ajudou a "[...] responder que aspectos e dimensões vêm sendo destacados e privilegiados em diferentes épocas e lugares [...]" (Ferreira, 2002, p. 258). Segundo Nóbrega-Therrien e Therrien (2004, p. 08) esse estudo da literatura pode incluir a busca "[...] em resumos e catálogos de fontes relacionados a um campo de investigação", enquanto Ferreira (2002) destaca dissertações de mestrado, teses de doutorado e artigos publicados em periódicos.

A revisão de literatura e a análise documental trouxeram a tona as teorias e conceitos sobre como ocorre o processo de personalização de LLMs, e revelou a atuação de dois paradigmas distintos de personalização disponíveis em ferramentas de personalização de LLMs denominada nesta pesquisa de técnico-configuracional e o semântico-instrucional. Sobre metadados, instrumentos de representação na CI (catalogação) e a criação de perfil de aplicação de metadados, a investigação realizada na literatura revelou teorias fundamentais para a determinação de metadados relevantes para representar LLMs personalizados.

Ademais, a revisão de literatura permitiu investigar a própria arquitetura dos LLMs, bem como o seu funcionamento probabilístico característico no processo de geração de textos. Tomar como ponto de partida a literatura disponível sobre esses modelos e os metadados possibilitou compreender os diferentes pontos de vista sobre a determinação de metadados sob a ótica da CI e os detalhes técnicos associados ao processo de personalização investigados pela CC. Desse modo, a convergência teórica fundamentou o entendimento de que a modelagem informacional desses recursos exige uma abordagem interdisciplinar.

Sob essa premissa, a técnica de Análise Documental foi aplicada não apenas nos manuais, guias e documentações técnicas associadas aos modelos de base e às ferramentas de personalização de LLMs, mas abrangeu também as interfaces de usuário e o modelo de representação dos *Model Cards* oriundo da CC. A pertinência de aplicar a análise a esse corpus documental justifica-se pelo fato de ele permitir desvelar como a CC materializa e articula seus conceitos em torno dos modelos de base. Investigar tanto as interfaces quanto os *Model Cards* configurou-se como o procedimento metodológico adequado para identificar os paradigmas implícitos e a trajetória técnica do processo de personalização de LLMs.

A escolha desta metodologia evidenciou que os *Model Cards* possuem uma visão fortemente influenciada pela engenharia e carecem de uma padronização estruturada, e que essa lacuna pode ser preenchida pelas técnicas e métodos consolidados na CI. Portanto, a operacionalização desta metodologia auxilia no objetivo de superar a barreira disciplinar e fundamentar a competência do profissional da informação, munindo o especialista em CI com o aparato técnico e conceitual necessário para atuar no cenário explorado.

Portanto, este percurso metodológico direcionou a escolha de explorar as ferramentas de personalização e de aplicar padrões consolidados como *Model Cards*, LRM, DC e Schema.org, materializando-se de forma prática e formal nesta tese por meio da proposição de um Perfil de Aplicação de Metadados (MAP) para LLMs personalizados, denominado MAP-CLLM, detalhado nas seções subsequentes.

A justificativa central para a metodologia empregada reside na evolução dos Transformers, tecnologia fundacional dos LLMs, que emergiu em 2017. Contudo, somente em fins de 2020, o ChatGPT, um *chatbot* como interface de conversação da empresa OpenAI baseado em Transformers e conectado a um LLM, o GPT-3, foi disponibilizado à comunidade da CC (Brown *et al*, 2020; Vaswani, 2017). É necessário salientar que os Transformers impactaram significativamente o Processamento de Linguagem Natural (PLN), viabilizando, a partir de 2023, e com maior amplitude no Brasil em 2024, o surgimento de plataformas acessíveis que permitem a personalização de um LLM sem a necessidade de conhecimentos aprofundados da área da CC. Consequentemente esta investigação se fundamenta na literatura mais recente concernente a metadados e personalização de LLMs sempre que possível.

Os procedimentos metodológicos foram divididos em 5 etapas, apresentadas mais detalhadamente a seguir:

A **etapa 1, revisão de literatura,** realizada em nível nacional e internacional, em fontes bibliográficas da área da CI e CC como Scopus, Web of Science, SciELO, Brapci, Elsevier, ACM Digital Library, IEEE Xplore, possibilitou a criação da base teórica do estudo proposto.

Em alguns casos não foi possível utilizar uma busca exata dos termos na área da CI e CC em conjunto devido à falta de literatura sobre os temas, tendo que ser adaptada a partir da busca individualizada das palavras-chave em ambas as fontes bibliográficas. A falta de literatura pertinente nesta etapa da pesquisa justifica-se pelo fato, já esclarecido, de que ferramentas que permitem a personalização de LLMs sem conhecimentos aprofundados de programação de computadores tornaram-se acessíveis ao público de interesse desta pesquisa no final de 2023, início de 2024.

Concentrou-se esforços para encontrar trabalhos na CC que destacam o processo de personalização de um LLM e trabalhos na CI que apresentam as últimas conclusões sobre a determinação de metadados para objetos de informação. Como critério de inclusão de bibliografias pertinentes, livros, artigos científicos, teses, dissertações, relatórios técnicos e documentos técnicos relacionados a ferramentas usadas no processo de personalização de LLMs, por exemplo, Google AI Studio e Gemini Gems, foram considerados. Por outro lado, pesquisas de campo, estudos de caso, ou experimentos foram excluídos pois, embora possam ajudar a entender o tema e verificar os resultados de modo aplicado, o estudo buscou verificar a teoria publicada no contexto desta pesquisa.

O período de 10 anos, entre 2014 e 2024, foi priorizado por conta da justificativa apresentada anteriormente, entretanto, algumas exceções foram consideradas, especialmente na área de metadados sob a perspectiva da CI, devido a importância da referência para este estudo. Foram usados os mesmos termos de pesquisa em ambas as fontes bibliográficas das áreas da CC e CI e variações para os idiomas Português, Inglês ou Espanhol quando apropriado. Os termos usados foram *Large Language Model*, *Large Language Models*, LLM e LLMs. Variações com o uso de aspas duplas também foram usadas: "*Large Language Model*" e "*Large Language Models*". Especificamente no caso do tema metadados, os termos no singular e plural, metadado e metadados, foram usados para localizar pesquisas mais recentes realizadas pela CI. Quando variações dos termos da CC e CI foram usados na mesma pesquisa, por exemplo, "*Large Language Model*" AND Metadados, não foram encontrados resultados relevantes para as delimitações, problema de pesquisa e objetivos deste estudo.

Em adição a estratégia tradicional de buscas em bases de dados, visando confirmar que a limitação da busca usando apenas palavras-chave não comprometesse a localização de referências relevantes, esta pesquisa usou ferramentas de IAG nesta etapa, especificamente o Consensus e o Gemini Deep Research. Essas ferramentas permitem ao pesquisador fazer perguntas específicas, por exemplo, “Segundo a área da Ciência da Informação, quais são as últimas orientações sobre como determinar os metadados de um objeto de informação?”,

“Como um *Large Language Model* funciona?”, ou “Quais metadados estão relacionados ao processo de personalização de um Large Language Model?”.

O Consensus é um mecanismo de busca acadêmica com uma inteligência artificial que pode acessar mais de 220 milhões de artigos científicos revisados por pares e vincular suas respostas a um ou mais artigos científicos auxiliando na revisão e entendimento da literatura com maior agilidade (Elechko, 2026). O Gemini Deep Research, segundo a documentação oficial, caracteriza-se como um agente de pesquisa configurado para realizar investigações em fontes acadêmicas com foco em profundidade e verificação de fatos, por isso, pode ser orientado a navegar por centenas de fontes estritamente acadêmicas, por exemplo, artigos científicos, dissertações e teses, permitindo uma “investigação aprofundada de assuntos por meio da comparação e contraste de conceitos-chave, identificação de relações entre ideias e explicação de princípios subjacentes” (Gemini, 2026). Ressalta-se que o uso de tais agentes de pesquisa visou a exaustividade na localização de fontes primárias, mantendo-se a análise crítica e a síntese interpretativa sob estrita responsabilidade do pesquisador.

A etapa 2, Análise Documental, caracterizou-se pela coleta e exame crítico de fontes primárias estáveis que normatizam, orientam e subsidiam o ecossistema tecnológico e conceitual dos LLMs e das estruturas de metadados. Sob a lente da análise documental, as fontes examinadas incluíram as interfaces gráficas de usuário e as documentações técnicas oficiais das ferramentas de personalização Google AI Studio e Gemini Gem, os guias de integração e especificações de protocolos da *Application Programming Interface* (API) do Gemini e os relatórios, normativas e diretrizes organizacionais de referências institucionais, como a *National Information Standards Organization* (NISO) e a legislação europeia sobre Inteligência Artificial (AI Act - Regulamento UE 2024/1689).

A análise desses documentos desvelou os fluxos de trabalho, as restrições operacionais e a terminologia empregada no processo de personalização de LLMs, permitindo o mapeamento de metadados passíveis de representação. É relevante afirmar que a análise documental selecionada como parte desta metodologia, especificamente a análise da documentação técnica relacionada a interface de usuário do Google AI Studio e Gemini Gems, compensou a pouca literatura pertinente identificada na etapa anterior, confirmando acertada a escolha destas ferramentas e suas documentações para o estudo do processo de personalização de LLMs, visto que este tipo de documentação é simultaneamente disponibilizado ao público quando a ferramenta é lançada.

A etapa 3, Análise das Ferramentas de Personalização de LLMs, consistiu na imersão direta e prática nas plataformas laboratoriais a fim de identificar e extrair os parâmetros constitutivos que governam as interações dos LLMs. A investigação detalhada dos ecossistemas de personalização permitiu identificar o paradigma Técnico-Configuracional focado em variáveis de baixo nível expostas na interface do Google AI Studio e o paradigma Semântico-Instrucional focado nas diretrizes em linguagem natural de alto nível configuradas no Gemini Gems. Este exame empírico delimitou a anatomia funcional de um LLM personalizado, permitindo isolar as propriedades reais que necessitam de representação antes que ocorra a dispersão do objeto de informação.

Na etapa 4, Comparação de Esquemas de Metadados, concentrou-se na análise comparativa e no mapeamento semântico dos esquemas de metadados fundamentais selecionados para a pesquisa, buscando convergência, reusabilidade e o alinhamento com o modelo conceitual LRM. A modelagem utilizou a decomposição do LRM para estruturar as entidades que representam um LLM personalizado, delimitando o modelo de base como Obra, as configurações e regras de prompts como Expressão, o aplicativo ou serviço web resultante como Manifestação e as sessões de chat interativas de consulta como Item. Com base nessa arquitetura lógica, os 15 elementos básicos do padrão Dublin Core (DC), que garantem a descoberta de recursos e a governança de proveniência de forma simples e universal, foram mapeados em relação às seções dinâmicas de ética, métricas e limitações estabelecidas pelo framework *Model Cards* proposto pela Ciência da Computação. Essa comparação sistemática determinou quais atributos técnicos e contextuais seriam herdados de padrões consolidados e quais demandavam a especificação de termos locais, assegurando o menor nível de redundância e a maior qualidade semântica possível.

A etapa 5, Proposição e Elaboração do Perfil de Aplicação, consistiu na formalização e codificação das decisões estruturadas nas fases anteriores por meio do desenvolvimento prático do *Metadata Application Profile for Custom Large Language Models* (MAP-CLLM). Nesta etapa, a revisão de literatura e a análise documental adotada nesta metodologia contribuíram com a fundamentação necessária para as decisões tomadas. A estratégia de determinação de metadados para LLMs personalizados foi baseada nas pesquisas dos autores Liu; Fu; Liu (2023), Ulrich *et al*. (2020), Malta; Baptista; Walk (2017), Riley (2017), Baca (2016), Alves (2010), Nilsson; Baker; Johnston (2008) e Heery; Patel (2000). Para o entendimento do processo de personalização de um LLM a pesquisa baseou-se na documentação técnica fornecida pela empresa Google (2025a, 2025b, 2025c, 2025d, 2025e) e

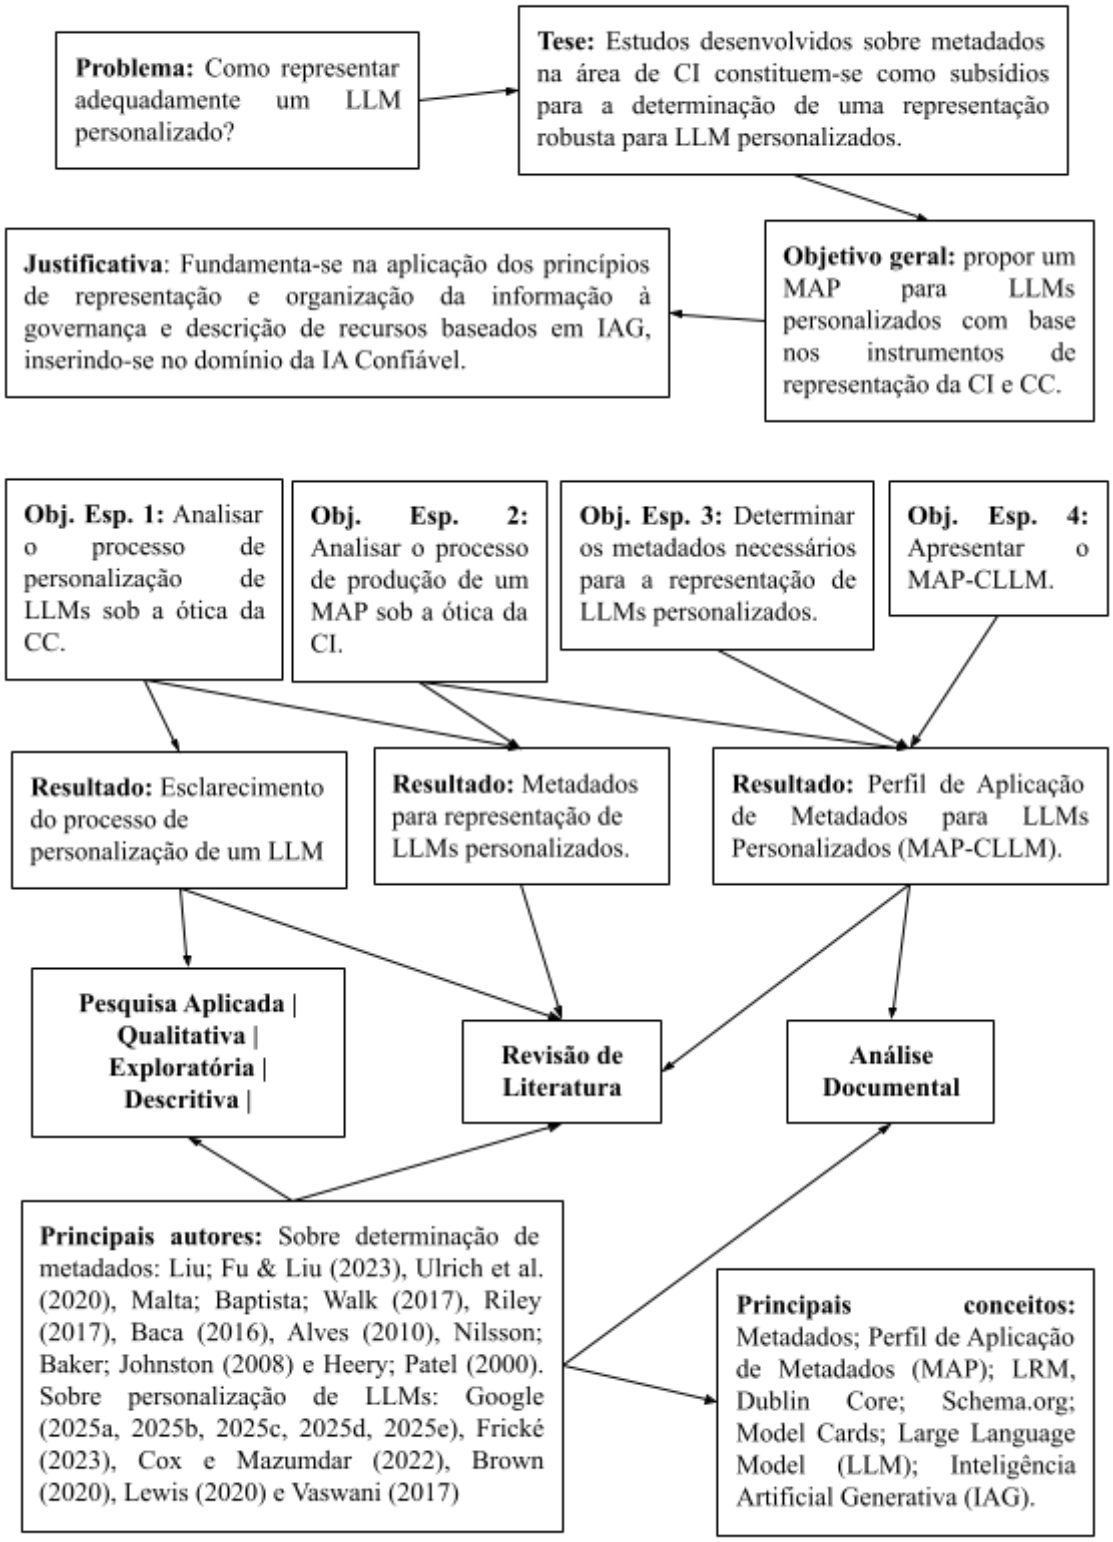
nas pesquisas dos autores Frické (2023), Cox e Mazumdar (2022), Brown (2020), Lewis (2020) e Vaswani (2017).

Adotando a arquitetura de múltiplos níveis de abstração recomendada pelo *Singapore Framework* e refinada pela metodologia Me4MAP recomendadas pela literatura pesquisada, esta etapa resultou na elaboração de componentes técnicos essenciais:

- Requisitos Funcionais: delimitação das tarefas de busca, avaliação, reprodutibilidade e governança de risco que o perfil de metadados deve satisfazer para os usuários finais e curadores de informação;
- Modelo Relacional e *Description Set Profile* (DSP): especificação técnica contendo os templates de descrição para cada uma das quatro entidades modeladas segundo o LRM (Obra, Expressão, Manifestação e Item), acompanhados de suas regras de cardinalidade, obrigatoriedade e restrição de valores;
- Definição da Sintaxe de Codificação e Esquema de Vocabulário: mapeamento semântico de cada elemento do MAP para o vocabulário unificado da Web Semântica, o Schema.org, demonstrando a viabilidade prática do perfil por meio de anotações utilizando a sintaxe JSON-LD para indexação e busca automatizada em escala global.

O diagrama proposto por Sant'Ana (2022) foi usado para facilitar a construção do texto e a estruturação dos elementos da pesquisa visando a coerência entre proposta, elaboração e resultados deste estudo.

Figura 1 – Diagrama proposto por Sant'Ana (2022) desta pesquisa.
Metadados de Large Language Models sob a perspectiva da Ciência da Informação: Proposta de Perfil de Aplicação de Metadados para LLMs Personalizados



Fonte: elaboração do autor com base em Sant'Ana (2022).

3 ESTRUTURA DA PESQUISA

Quanto à sua organização, esta tese apresenta nesta seção questões iniciais e contextualiza a temática proposta referente a importância de identificar os metadados envolvidos no processo de personalização de um LLM e propor um conjunto de elementos de metadados para a sua representação visando facilitar sua organização, recuperação e gerenciamento. Também apresenta a definição do problema, a motivação da execução da tese, o objetivo geral, objetivos específicos, a justificativa e relevância do trabalho.

A seção 2, **"*LARGE LANGUAGE MODEL* - LLM",** apresenta um estudo sobre os aspectos técnicos relacionados a um LLM, detalhes sobre o processo de personalização destes, o cenário considerado na Análise Documental desta pesquisa, e apresenta os *Model Cards*, proposta de representação da informação para LLMs usada pela área da CC, compondo a base teórica necessária para fundamentar as decisões tomadas.

A seção 3, **"METADADOS NO CONTEXTO DA CIÊNCIA DA INFORMAÇÃO",** explora referências relacionadas a área da CI sobre metadados, especialmente sobre determinação de metadados, LRM, o padrão Dublin Core, Schema.org e Perfil de Aplicação de Metadados. Essa seção completa a base teórica e fundamenta a estratégia usada para propor um Perfil de Aplicação de Metadados para LLMs personalizados.

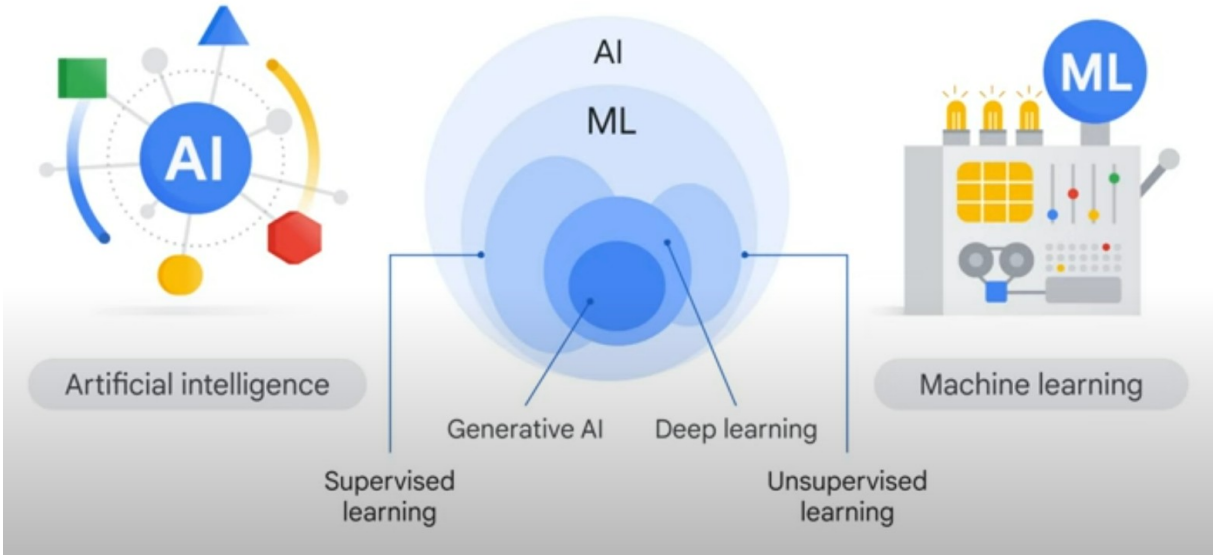
A seção 4, **"PROPOSTA DE UM PERFIL DE APLICAÇÃO DE METADADOS PARA LLMS PERSONALIZADOS",** seguindo orientações encontradas na literatura, apresenta o MAP-CLLM, um conjunto de elementos de metadados determinados para a representação de LLMs personalizados considerando o problema e objetivos desta pesquisa.

A seção 5, **"CONSIDERAÇÕES FINAIS",** destaca os benefícios de um perfil de aplicação de metadados para LLMs personalizados e o papel da CI na determinação de um conjunto de elementos de metadados para a representação deste tipo de recurso informacional. Também provoca reflexões sobre a necessidade da CI aprofundar nas pesquisas relacionadas ao tema visto que tecnologias relacionadas tendem a ficar mais acessíveis para a sociedade em geral impactando na produção de informação não apenas textual, mas também em imagens, vídeos e áudios. A preocupação com a credibilidade da informação é ampliada neste cenário tornando necessário e fundamental a contribuição das pesquisas realizadas pela CI.

4 LARGE LANGUAGE MODEL - LLM

O cenário da IA tem testemunhado um avanço acelerado nas últimas décadas, impulsionado por inovações na CC e pela crescente disponibilidade de dados (Cox; Mazumdar, 2022). Dentre as evoluções mais notáveis, destaca-se a emergência da IAG. No âmbito dos diferentes tipos de IAG, esta seção dedica-se ao *Large Language Model* (LLM), ou Modelo de Linguagem de Grande Escala. Os LLMs constituem sistemas de IA projetados para o processamento e a geração de linguagem natural em profundidade semântica, alterando os padrões de interação entre computadores e a linguagem humana. Por conseguinte, a CI demonstra interesse em investigar o tema, motivada pela sua experiência nos estudos relacionados a metadados e capacidade de avaliar a qualidade de corpus documentais, elementos essenciais para LLMs (Das; Islam, 2021). A figura 2 a seguir, oferece uma síntese do panorama referente ao emprego do termo IA.

Figura 2 – Um panorama referente aos termos relacionados a IA.



Fonte: Google (2025a).

A figura 2 indica que o termo IA cobre o campo mais amplo de pesquisas realizadas pela CC posicionando os estudos sobre Machine Learning (ML) como um subcampo da IA. Com o objetivo de pesquisar como máquinas podem aprender, o chamado aprendizado de máquina (ML), as pesquisas levaram a outra subcategoria, esta dentro de ML, denominada Deep Learning (DL). Os estudos sobre aprendizado profundo de máquinas (DL), predominantemente baseado no estudo e desenvolvimento de redes neurais artificiais (RNAs), levou então ao desenvolvimento da IAG, onde residem os LLMs (Frické, 2023; Cox; Mazumdar, 2022, Das; Islam, 2021).

A figura 2, embora uma síntese das pesquisas realizadas pela CC no contexto da IA, destaca outro ponto importante, as técnicas de aprendizado de máquinas usadas. O aprendizado supervisionado consiste em apresentar exemplos para a IA, para que esta aprenda padrões existentes, por outro lado, no aprendizado não supervisionado, espera-se que a IA consiga encontrar esses padrões sem a necessidade de exemplos. Quando essas técnicas são usadas no contexto da DL, com RNAs, poder de computação e processamento de dados enormes, torna possível o surgimento da IAG (Vaswani, 2017; Frické, 2023).

Essa síntese do panorama atual referente ao emprego do termo IA também inclui entender que RNAs são modelos matemáticos e computacionais inspirados na estrutura e no funcionamento do cérebro humano, constituídas por unidades de processamento denominadas neurônios artificiais, organizadas em camadas (Frické, 2023). Esses neurônios artificiais processam informações através de pesos ajustáveis e funções de ativação, permitindo que a RNA aprenda padrões complexos a partir de grandes volumes de dados. A principal característica das RNAs é sua capacidade de aprender a realizar tarefas sem a necessidade de um algoritmo programado explicitamente para cada tarefa, tornando-as adequadas para problemas como reconhecimento de padrões (Frické, 2023).

Redes Neurais Recorrentes (*Recurrent Neural Networks* - RNNs) e Redes Neurais Convolucionais (*Convolutional Neural Networks* - CNNs) foram, por algum tempo, as arquiteturas usadas para desenvolver RNAs. No entanto, essas abordagens se revelaram menos eficazes para processar textos longos devido a suas limitações em modelar relações distantes entre palavras, o que restringe sua capacidade de capturar dependências de longo alcance (Vaswani, 2017; Frické, 2023).

A arquitetura recente para RNAs que se destacou, Transformer, diferente das RNNs e CNNs, baseia-se em mecanismos de atenção que permitem ao modelo de IA focar em diferentes partes da sequência de entrada simultaneamente, resultando em maior eficiência no processamento de dados sequenciais e na captura de dependências de longo alcance em textos (Vaswani, 2017). O Transformer foi introduzido pela empresa Google em 2017 eliminando a necessidade de mecanismos recorrentes ou convolucionais ao introduzir a técnica de atenção própria, permitindo que o LLM processe todas as palavras de uma sequência simultaneamente e estabeleça relações diretas entre elas (Vaswani, 2017; Frické, 2023; Google 2025a).

Os LLMs, portanto, estão posicionados sob os estudos relacionados a IAG, e para o desenvolvimento de uma proposta de um MAP, faz-se necessário uma compreensão da natureza do objeto a ser descrito. Neste contexto, a presente seção dedica-se à exploração dos princípios tecnológicos essenciais aos LLMs, delimitando, ademais, o escopo específico desta pesquisa

focada no processo de personalização desses modelos. Tal abordagem visa estabelecer uma base conceitual consistente, imprescindível para a construção de um perfil de aplicação de metadados que reflita com precisão as características e funcionalidades desses objetos informacionais complexos.

4.1 Fundamentos da tecnologia Large Language Model - LLM

Um LLM representa uma inovação significativa no campo da IA, caracterizando-se por uma arquitetura de RNAs profundas. Tal modelo é composto por bilhões de parâmetros e desenvolvido a partir de vastas coleções de dados textuais (Frické, 2023). A finalidade primordial deste processo de desenvolvimento é capacitar o modelo a discernir e assimilar padrões complexos, estruturas gramaticais implícitas, conhecimentos factuais, capacidades de raciocínio lógico e as sutis nuances próprias à linguagem humana (Freitag, 2025).

A emergência da atual geração de LLMs foi catalisada por uma notável inovação arquitetônica nas RNAs denominada Transformer, apresentado por Vaswani *et al*. (2017) e Google, como citado (Google 2025a). Em contraposição às arquiteturas preexistentes, sumarizadas na seção anterior, o mecanismo de autoatenção singular da arquitetura Transformer confere ao LLM a capacidade nativa de ponderar a relevância de cada palavra dentro de uma sequência de entrada, independentemente de sua posição sintática ou sequencial. Consequentemente, o LLM adquire uma proficiência superior na captação de contextos de longo alcance, o que se manifesta na produção de textos de elevada coerência e pertinência (Pinheiro, 2024; Vaswani *et al*., 2017). Esta característica é determinante para o avanço das capacidades de processamento de linguagem natural, permitindo que os LLMs processem e gerem informações textuais com uma profundidade semântica e contextual sem precedentes.

O princípio operacional de base dos LLMs pode ser concebido como um processo essencialmente probabilístico. Ao receber uma sequência de texto inicial, denominada *prompt*, o modelo computa a verossimilhança da ocorrência da próxima palavra na sequência, também denominada *token*. Posteriormente, gera o termo com maior probabilidade e reitera este procedimento, utilizando a sequência textual expandida como nova entrada, até que uma resposta completa e coerente seja articulada ou um critério de terminação predefinido seja satisfeito (Frické, 2023; Venturini, 2025). Esta proficiência em fabricar texto contextualmente pertinente é a característica fundamental que posiciona os LLMs como ferramentas de alta capacidade computacional para uma diversidade de aplicações.

Considerando o grande volume de textos acessíveis a um LLM, são necessários milhares de cálculos matemáticos, realizados em alta velocidade, para identificar como as palavras se relacionam, conferindo ao LLM a capacidade de prever, com base em fórmulas matemáticas, estatísticas e probabilidades, a próxima palavra (Vaswani, 2017). Por exemplo, um corpus de documentos da área da CI usado na Faculdade de Filosofia e Ciências da Unesp de Marília, SP, reunido e disponível a um LLM personalizado para a biblioteca local, poderia ser consultado pelo público em geral, usando um chatbot conectado a esse LLM personalizado. Nesse cenário, o usuário da biblioteca poderia digitar "na biblioteca da Unesp de Marília o padrão de metadados usado é …" e esperar que o LLM complete com a resposta. Nesse exemplo, do ponto de vista matemático, não existe uma resposta correta. O que existe é uma probabilidade, baseada no corpus disponível ao LLM personalizado, de "Dublin Core", "MARC" ou "RDA" ser a resposta. Após os cálculos necessários, o LLM atribui uma porcentagem de 30% para "Dublin Core", 50% para "MARC" e 20% para o "RDA" ser a resposta possível. A resposta "MARC" é a mais provável, portanto, o LLM completa a frase com essa palavra (Data Science Academy, 2022).

O uso de um LLM é computacionalmente intensivo visto que para cada palavra digitada como pergunta ou gerada como resposta, muitos cálculos são executados a cada vez porque um processo denominado embeddings é necessário para converter essas palavras em números representados em um espaço vetorial contínuo, onde palavras semanticamente semelhantes são mapeadas para pontos próximos nesse espaço (Lewis, 2020; Vaswani, 2017). Por isso, a compreensão do funcionamento de um LLM requer o entendimento de que a infraestrutura computacional de hardware e software necessária para o desenvolvimento desses modelos de IAG é onerosa quanto ao espaço físico e aos recursos financeiros. Na prática, grandes empresas, por exemplo, Microsoft, Google, OpenAI e outras, desenvolvem um LLM e disponibilizam para o público em geral como modelos de base. Estes modelos são amplamente integrados em interfaces de conversação, tais como *chatbots*, entretanto, existem ferramentas que permitem reunir corpus de documentos e, a partir desses modelos de base, personalizar um LLM para uma necessidade específica (Google 2025b).

Para analisar o cenário envolvido no desenvolvimento de um LLM com a arquitetura de uma RNA Transformer, nesse cenário denominado modelo de base, o desenvolvimento do Generative Pre-trained Transformer (GPT) da empresa OpenAI, amplamente utilizado atualmente, é usado como exemplo. O GPT-3 foi lançado em 2020 e, segundo a OpenAI (2024) empresa responsável, foram usados 45 terabytes de texto no seu desenvolvimento e 175 bilhões de parâmetros, também denominados pesos em RNAs (Brown, 2020). A quantidade de

parâmetros pode ser considerada uma métrica que ajuda no entendimento da capacidade e complexidade de um LLM considerado um modelo de base (Wei; *et al*, 2022).

Considerando que a quantidade de parâmetros é uma métrica que ajuda a entender a capacidade de um LLM, outras empresas, por exemplo, Microsoft e Nvidia, publicaram o código de um modelo denominado *Megatron-Turing Natural Language Generation* (MT-NLG) para compreensão de leitura e inferência de linguagem natural afirmando terem desenvolvido em 530 bilhões de parâmetros (Vaswani, 2017; Wei, *et al.*, 2022; Smith, *et al.*, 2022). A empresa Google afirmou que desenvolveu um modelo de 540 bilhões de parâmetros chamado PaLM, com desempenho de ponta em tarefas de linguagem (Chowdhery, 2022). Sendo uma tecnologia que se desenvolve muito rapidamente, esses números devem ser considerados apenas como exemplos para ajudar a entender o funcionamento de um LLM, por isso, números atualizados estão disponíveis na documentação oficial das empresas fornecedoras (Sharir; Peleg; Shoham, 2020; Wei, *et al.*, 2022).

Retomando o GPT-3 como exemplo, por ser um LLM, este gera uma palavra de cada vez, levando em consideração o contexto anterior e usando amostras da próxima palavra com base em probabilidades condicionais (Frické, 2023). O processo de amostragem pode ser controlado usando alguns dos citados parâmetros, por exemplo, um parâmetro pode ser usado para ajustar a aleatoriedade das amostras, enquanto outro parâmetro pode limitar a quantidade de opções da próxima palavra mais provável (Brown, 2020).

Sobre custos para manter em funcionamento um LLM, um estudo de 2020 estimou as despesas para desenvolver um LLM com 1,5 bilhão de parâmetros em até US$ 1,6 milhão e a previsão para manter em execução o mesmo LLM em uma estrutura de computação em nuvem de no mínimo US$ 87.000 por ano (Sharir; Peleg; Shoham, 2020). É por isso que o processo de personalização de um LLM envolve escolher uma empresa fornecedora desse tipo de IA, por exemplo, Microsoft, Google ou OpenAI, e usar as ferramentas e os modelos de base disponíveis. Essa estratégia torna acessível a possibilidade de personalizar um LLM para contextos e perfis de aplicações com necessidades específicas.

Outra característica relevante para compreender o cenário de desenvolvimento de um LLM como modelo de base é o fato de que atualizações de conhecimento de um LLM são custosas, tanto do ponto de vista de valores monetários como de tempo (Sharir; Peleg; Shoham, 2020; Wei, *et al.*, 2022). Por exemplo, voltando ao GPT-3, seu conhecimento é limitado ao corpus de textos reunidos e usados no seu desenvolvimento disponível até setembro de 2021, sua data de corte no momento desta consulta realizada em setembro de 2024. A versão GPT-4, também consultada em setembro de 2024, tem sua data de corte em setembro de 2023 (OpenAI,

2024). Na prática, ao usar o GPT-4 em setembro de 2024 as respostas estavam limitadas ao conhecimento existente até setembro de 2023. Essa característica dos LLMs é comum atualmente, por isso, torna-se uma das diversas justificativas para personalizar um LLM usando um corpus curado, especializado e atualizado.

Para contornar a defasagem temporal do conhecimento usado por um LLM, a técnica de *Retrieval Augmented Generation* (RAG) foi desenvolvida e atualmente é usada no processo de personalização de um LLM. O RAG é uma técnica que permite a um LLM fazer referência a uma base de conhecimento que não foi usada no seu desenvolvimento inicial, combinando recuperação de informação e geração de texto, permitindo que um LLM recupere informações relevantes de uma fonte de conhecimento e incorpore no seu próprio texto gerado (Lewis, 2020; Frické, 2023). No contexto desta pesquisa, durante o processo de personalização de um LLM, é possível incluir documentos diversos, e em formatos diversos, simplesmente fazendo um *upload* desses arquivos usando a ferramenta disponível. Embora seja simples, o que tornou isso possível foi a técnica RAG, transferindo para quem reúne os documentos usados no processo de personalização de um LLM uma grande responsabilidade, visto que a qualidade desses textos selecionados vai influenciar a relevância e precisão da base de conhecimento usada no processo (Lewis, 2020; Frické, 2023).

Considerando que profissionais da área da biblioteconomia e CI têm habilidades e competências para usar bases de dados confiáveis e utilizar técnicas de buscas avançadas, sua participação no processo de personalização de um LLM em determinados contextos seria um diferencial, por exemplo, se o projeto envolvesse usar RAG para um *chatbot* de aconselhamento nutricional, seria apropriado selecionar textos de artigos científicos, dissertações e teses especializadas. O uso de fontes de textos desatualizadas, de qualidade científica questionável ou sem revisão de pares poderia levar a conselhos imprecisos.

Com o RAG, um LLM personalizado pode apresentar informações precisas retiradas de fontes de conhecimentos adicionais. O texto gerado pelo LLM pode conter inclusive citações e referências bibliográficas, permitindo que a pessoa que está interagindo com um *chatbot* conectado a um LLM que usou a técnica RAG consulte os documentos originais, caso mais esclarecimentos ou detalhes sejam necessários, aumentando a confiança e credibilidade no texto gerado pelo LLM (Lewis, 2020; Frické, 2023). Pensando novamente na prática profissional da biblioteconomia e da CI, é inevitável considerar a importância desses profissionais na equipe de desenvolvimento de um LLM personalizado.

Quando o RAG é usado no processo de personalização de um LLM é necessário entender que a fase de seleção de textos usados tem duas etapas. Como esclarecido

anteriormente, grandes empresas com acesso a toda infraestrutura de hardware e software necessárias para o desenvolvimento de um LLM reúnem quantidades gigantescas, na casa dos terabytes, de textos de fontes diversas para o desenvolvimento do modelo de base. No exemplo do GPT-3 citado, a empresa responsável afirma que 45 terabytes de textos diversificados da internet foram usados, caracterizando aqui a primeira etapa da seleção de textos (OpenAI, 2024). Usando ainda o exemplo do GPT-3 e no cenário de um *chatbot* para aconselhamento nutricional, esse modelo de base, usando o conjunto de textos inicial, é disponibilizado e pode ser usado pelo público em geral por meio do *chatbot* popular da OpenAI. Quando a necessidade de um LLM personalizado é identificada, neste cenário, talvez uma nutricionista desejando ter um auxílio de uma IA, uma segunda etapa de seleção de textos reúne artigos científicos, dissertações e teses da área da nutrição e, usando o RAG, realiza a personalização de um LLM para este cenário. É importante esclarecer que a segunda etapa de seleção de textos ocorre apenas quando o objetivo é personalizar um LLM, portanto, caso isso não seja necessário, o modelo de base apenas com os textos da primeira etapa aqui detalhada pode ser usado pelo público em geral, como ocorre atualmente.

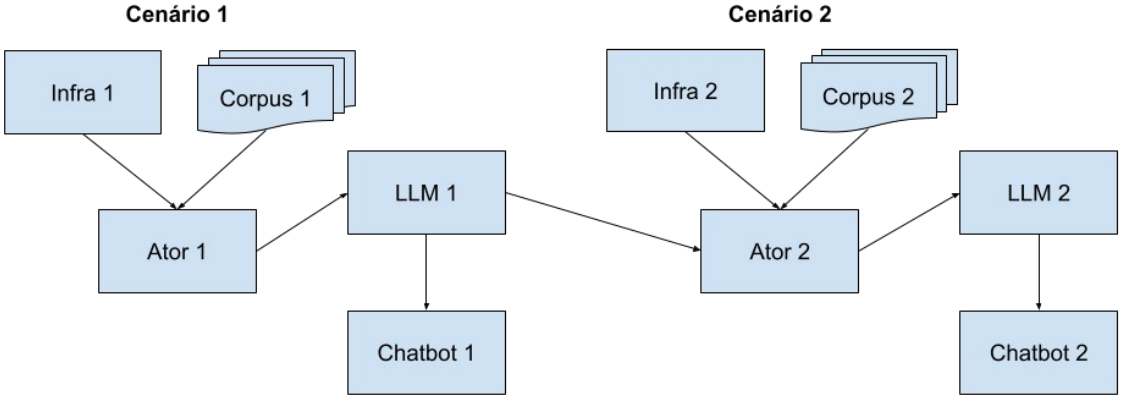
Portanto, um LLM, enquanto modelo de base, pode ser definido como um modelo estatístico desenvolvido a partir de quantidades massivas de textos, um tipo de rede neural artificial específico denominado *Transformer* (Vaswani, 2017). A complexidade envolvida no desenvolvimento deste tipo de IAG, considerada nesta seção, justifica a crescente personalização de LLMs para tarefas e áreas do conhecimento específicas.

Depois de considerar os fundamentos da tecnologia LLM nesta seção, é necessário destacar que esta pesquisa se concentrou na segunda etapa de seleção de textos descrita anteriormente, ou seja, o interesse reside nos metadados de um LLM personalizado, de modo que os bilhões de parâmetros envolvidos no desenvolvimento de modelos de base não são alvo deste estudo (Vaswani, 2017).

No contexto desta pesquisa o processo de personalização de um LLM pode ser resumido nas etapas de 1) selecionar o corpus que será utilizado; 2) escolher dentre as empresas fornecedoras de modelos de base o modelo que será usado; 3) configurar os parâmetros disponíveis na ferramenta usada; 4) testar o LLM personalizado; e 5) disponibilizar seu uso para o público desejado.

A figura 3 acompanhada do quadro 1 e algumas considerações resumem tudo que foi abordado até o momento:

Figura 3 – Cenários relacionados a personalização de um LLM.



Fonte: elaboração do autor.

Quadro 1 – Cenários relacionados a personalização de um LLM.

Cenário 1	Cenário 2
Infra 1: estrutura física própria composta de um prédio com diversos computadores denominados servidores, capacitados com enorme poder de processamento, memória e armazenamento. Geralmente comercializada para outros como computação em nuvem.	**Infra 2:** computação em nuvem contratada de empresas de tecnologia fornecedoras desse tipo de produto, por exemplo, Microsoft (Azure) ou Google (GCloud), com custos acessíveis.
Corpus 1: centenas de milhares de páginas como exemplo para uma possível visualização da enorme quantidade.	**Corpus 2:** milhares de páginas disponíveis em diversos arquivos e em diversos formatos.
Ator 1: grandes empresas da área de tecnologia, por exemplo, Microsoft, OpenAI ou Google, sendo uma pessoa jurídica.	**Ator 2:** profissionais ou empresas de todos os portes de áreas diversas, por exemplo, médica, engenharias, educação ou nutrição, sendo uma pessoa física ou jurídica.
LLM 1: Por exemplo, GPT-5 (OpenAI) ou Gemini 3 PRO (Google).	**LLM 2:** TiaNutri-1, em cenário fictício, um LLM personalizado para a área de nutrição.
Chatbot 1: https://chat.openai.com/ ou https://gemini.google.com/app	**Chatbot 2:** Em cenário fictício, um chatbot**:** https://www.TiaNutri.com/

Fonte: elaboração do autor.

Algumas considerações são necessárias ao observar a figura 3 e o quadro 1 apresentados. É importante compreender que o LLM 1 tem a capacidade de responder perguntas ou gerar textos de diversas áreas como, medicina, engenharias, educação ou nutrição, usadas como exemplos no quadro e que pode ser confirmado acessando os links do Chatbot 1. Contudo, o LLM 2 neste cenário fictício é um LLM personalizado para uma nutricionista específica e, como é possível observar na figura, pode responder perguntas ou gerar textos usando os Corpus 1 e o Corpus 2 porque o Ator 2 usou o LLM 1, um modelo de base, junto com a Infra 2, Corpus 2 e RAG para o desenvolvimento do LLM 2. Deste modo, o LLM 2 teoricamente seria mais confiável quando o assunto for nutrição. Isso conduz para a conclusão de que a qualidade do

LLM 2 depende da qualidade do Corpus 2 usado no processo de personalização do LLM 2. Por fim, como já destacado, o foco desta pesquisa está no cenário 2, os metadados produzidos nesse fluxo que inicia com o LLM 1, um modelo de base disponível e contínua com RAG, na Infra 2, Corpus 2, Ator 2, LLM 2 e Chatbot 2.

4.2 Processo de personalização de um Large Language Model

O presente estudo concentra-se no processo de personalização de LLMs que gera um objeto informacional complexo resultante da adaptação de um modelo de linguagem pré-existente, um modelo de base, para atender a requisitos e finalidades específicas. Esse processo é o foco desta pesquisa e o LLM personalizado resultante caracteriza-se o objeto de pesquisa. Para compreender as informações e os fenômenos informacionais relacionados a este cenário, optou-se por usar as ferramentas do ecossistema Google, o Google AI Studio e Gemini Gem, para estudar o processo de personalização de LLMs em virtude da acessibilidade observada, caracterizando-se uma análise documental. Entretanto, é possível afirmar que este escopo não invalida, restringe ou compromete as conclusões desta pesquisa porque em geral os fornecedores de modelos de base seguem a mesma estratégia, ou seja, oferecem ferramentas direcionadas tanto a um público com conhecimentos em CC, quanto a indivíduos oriundos de áreas diversas que manifestam interesse na exploração das potencialidades advindas da personalização de LLMs (Google, 2025b; OpenAI, 2024).

Adicionalmente, a delimitação exclusiva ao ecossistema Google justifica-se por razões de ordem histórico-tecnológica e pela necessidade analítica de examinar um ambiente que espelhe a evolução das arquiteturas de IAG desde sua origem. Dado que o Google foi pioneiro na introdução da tecnologia fundacional *Transformer*, a investigação do seu ferramental específico viabiliza a análise do processo de personalização a partir da matriz original de desenvolvimento de tais modelos (Vaswani *et al*., 2017; Google, 2025a). Ademais, sob a perspectiva da Ciência da Informação, o ecossistema Google destaca-se ao integrar, em uma mesma infraestrutura, as duas principais dimensões de representação e controle de um modelo de base, o paradigma técnico-configuracional no Google AI Studio e o semântico-instrucional no Gemini Gem (Google, 2025b; Google, 2025c).

Essa arquitetura integrada de múltiplos níveis constitui um locus metodológico ideal para rastrear como diretrizes de alto nível e parâmetros numéricos de baixo nível interagem de modo dinâmico para reconfigurar o comportamento do modelo de base, permitindo analisar as variáveis técnicas, os limites de conhecimento e as restrições éticas de um objeto informacional complexo (Google, 2025b; Google, 2025c). Por conseguinte, a modelagem de metadados

estruturada sob tais premissas de proveniência e governança garante que esses recursos dinâmicos e interativos sejam adequadamente identificados, rastreados, avaliados e gerenciados ao longo de seu ciclo de vida em ambiências digitais (Nilsson; Baker; Johnston, 2008). Consequentemente pode-se afirmar que essas ferramentas, especialmente suas documentações técnicas, a partir das orientações de autores como Sá-Silva, Almeida e Guindani (2009) e Alves *et al.* (2021) sobre a metodologia da análise documental, contribuiu para os objetivos propostos e auxiliou no entendimento do processo de idealização e configuração de LLMs personalizados.

As conclusões desta pesquisa, fundamentada em revisão de literatura e análise documental, conduziu o estudo para uma investigação analítica do processo de personalização de um LLM e permitiu entender como os atores envolvidos articulam seus conhecimentos em torno de modelos de base e ferramentas de personalização. Tal perspectiva justifica a abordagem adotada nesta pesquisa para fundamentar a competência do profissional da informação na representação de LLMs personalizados.

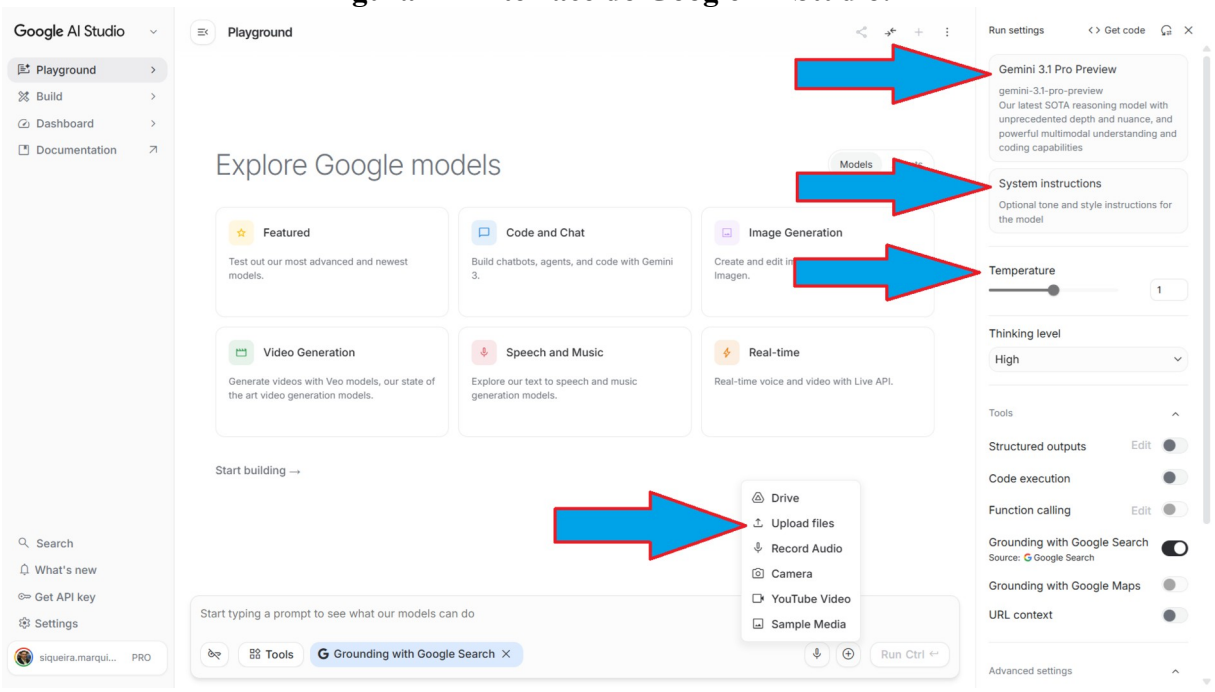
A ferramenta Google AI Studio, como paradigma técnico-configuracional, é uma plataforma web projetada para desenvolvedores e entusiastas de IA, que permite a prototipagem rápida e a interação direta com os modelos de base da família Gemini (Google, 2025b). A análise de sua interface e documentação revela que a personalização de um LLM ocorre primordialmente através do ajuste fino de um conjunto de parâmetros técnicos que governam o processo de geração de texto do modelo. Esses parâmetros constituem os elementos fundamentais para descrever a mecânica interna do LLM personalizado, ou seja, como ele gera suas respostas.

Como parte de uma plataforma tecnológica o Google AI Studio assume a posição de infraestrutura configurando-se como ambiente de prototipagem e personalização de LLMs focado no público com conhecimentos em CC, porém, também a indivíduos oriundos de áreas diversas. Sua funcionalidade primordial reside em proporcionar aos usuários um espaço interativo para a manipulação direta dos modelos de base desenvolvidos pelo Google, viabilizando a experimentação (Google, 2025b).

A base operacional que sustenta esta plataforma é constituída pela família Gemini, os quais, neste contexto, representam os LLMs desenvolvidos e disponibilizados pelo Google, os modelos de base. Observa-se a existência de variantes diversificadas de modelos Gemini, incluindo o Gemini Pro, otimizado para a execução de tarefas que demandam complexas capacidades de raciocínio, e o Gemini Flash, concebido para aplicações que requerem alta velocidade de processamento e elevado volume de dados (Pinheiro, 2024; Google, 2025b). Os modelos que fazem parte da família Gemini constituem-se os chamados modelos de base e

atuam como os pilares que fornecem as capacidades linguísticas gerais ao sistema, as quais serão subsequentemente personalizadas para atender a requisitos específicos. O artefato resultante desse processo de personalização é um Gemini Gem, um LLM personalizado (Google, 2025c). A figura 4 destaca a interface do Google AI Studio e alguns dos seus principais parâmetros que permitem personalizar um LLM, o modelo de base.

Figura 4 – Interface do Google AI Studio.



Fonte: elaboração do autor.

O principal objetivo em apresentar a figura 4 é evidenciar a capacidade de configurar o comportamento de LLMs personalizados por meio do Google AI Studio customizando o seu comportamento sem a necessidade de codificação programática. Não é possível apresentar em uma única figura todas as possíveis configurações disponíveis nesta ferramenta, entretanto, as setas indicam parâmetros determinantes para a personalização, por exemplo, a escolha do modelo de base, que neste caso foi selecionado o Gemini 3.1 Pro Preview, o *System Instructions* que permite usar texto livre em linguagem natural para determinar o comportamento desejado para o LLM personalizado, a *Temperature* que controla o grau de aleatoriedade na seleção da próxima palavra ao compor a resposta completa influenciando, por assim dizer, a criatividade do LLM personalizado e, por fim, o *File Uploads* que permite fornecer ao LLM personalizado arquivos diversos, como PDFs, servindo de base de conhecimento suplementar e contexto específico para suas tarefas.

Além desses parâmetros que controlam a geração do texto, ou resposta, do LLM personalizado, um componente crítico da configuração no Google AI Studio são os filtros de

segurança. A ferramenta permite ajustes de limiares de bloqueio para diferentes categorias de conteúdo potencialmente prejudicial, alinhando o comportamento do LLM personalizado às políticas de IA confiável e responsável. As categorias de dano ajustáveis são *Harassment* (Assédio), *Hate Speech* (Discurso de Ódio), *Sexually Explicit* (Sexualmente Explícito) e *Dangerous Content* (Conteúdo Perigoso). Para cada categoria, é possível definir um limiar de bloqueio, como *Block none* (não bloquear), *Block few* (bloquear apenas com alta probabilidade), *Block some* (bloquear com média ou alta probabilidade) e *Block most* (bloquear com baixa, média ou alta probabilidade) (Google, 2025b).

Os principais parâmetros configuráveis no Google AI Studio definidos como relevantes para esta pesquisa, seguindo orientações de Sá-Silva, Almeida e Guindani (2009) e Alves *et al*. (2021) sobre a utilização de documentos na análise documental, a partir do estudo da documentação disponibilizada pela Google (2025b) são sistematizados no quadro 2.

Quadro 2 – Principais parâmetros de configuração no Google AI Studio.

Parâmetro	Descrição	Tipo de Valor
Model	Identificador do modelo de base a ser utilizado para a geração de conteúdo.	String
System Instructions	O campo principal onde aquele que personaliza insere as diretrizes gerais para o comportamento do LLM personalizado. Este é o núcleo da personalização, pois trata-se de um campo de texto livre onde descreve-se, em linguagem natural, o comportamento desejado para o LLM personalizado. As instruções podem definir uma persona (p. ex., "Aja como um tutor de escrita acadêmica"), o tom (p. ex., "Use uma linguagem formal e encorajadora"), o formato da resposta (p. ex., "Responda sempre em tópicos"), as tarefas a serem executadas e as restrições a serem seguidas.	Texto livre
File Uploads	Permite o carregamento de arquivos, por exemplo, PDFs e outros, para fornecer ao LLM personalizado um contexto adicional e específico para suas tarefas. Esses documentos de texto servem como uma base de conhecimento suplementar. O LLM personalizado pode consultar esses documentos para fornecer respostas mais contextuais e precisas, indo além da sua base de conhecimento original do modelo de base.	Referência a arquivo

Temperature	Controla o grau de aleatoriedade na seleção da próxima palavra a compor a resposta completa, também denominada token. Valores mais baixos (próximos a 0.0) resultam em respostas mais determinísticas e focadas. Valores mais altos (próximos a 2.0) geram respostas mais diversas.	Numérico (0.0 a 2.0)
Top-P	Controla a diversidade através da amostragem por núcleo, um subconjunto da "possível próxima palavra", controlando a aleatoriedade de outra forma. O modelo considera apenas palavras ou tokens cuja probabilidade acumulada atinge, percentualmente, o valor de Top-P. Valores mais baixos restringem a seleção a tokens mais prováveis, tornando a resposta menos aleatória.	Numérico (0.0 a 1.0)
Top-K	Atua exatamente como o Top-P, entretanto, restringindo a seleção de tokens aos k mais prováveis, um valor fixo, em cada etapa da geração. Um valor menor limita a aleatoriedade.	Inteiro (p. ex., 1 a 40)
Max Output Tokens	Define o número máximo de tokens que podem ser gerados na resposta. Um token corresponde a aproximadamente quatro caracteres.	Inteiro
Stop Sequences	Uma lista de sequências de texto que, se encontradas na saída, interrompem a geração de conteúdo pelo modelo.	Lista de Strings

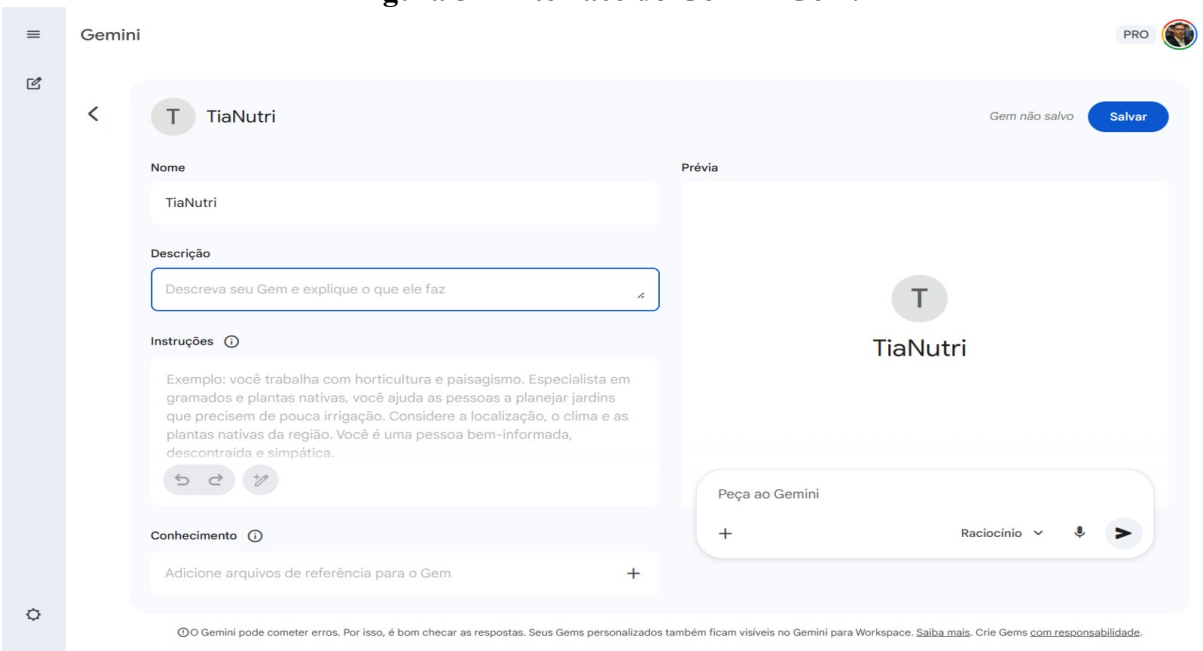
Fonte: elaboração do autor.

A outra ferramenta disponível no ecossistema Google é o Gemini Gem, como paradigma semântico-instrucional, representando uma abordagem de personalização de LLMs de mais alto nível, voltada para o público em geral sem a necessidade de conhecimentos específicos da área da CC. A análise da interface de criação do Gemini Gem, bem como sua documentação técnica, a partir da metodologia de análise documental conforme Sá-Silva, Almeida e Guindani (2009) e Alves *et al*. (2021), revela um paradigma de personalização focado não em parâmetros técnicos, mas em diretrizes semânticas, expressas em linguagem natural, que moldam o propósito do LLM personalizado, por assim dizer. O foco está em definir o quê o LLM personalizado deve fazer e quem ele deve ser (Google, 2025c).

Um Gem, produto do processo de personalização de um LLM a partir da ferramenta Gemini Gem, é concebido como uma versão personalizada de um dos modelos de base da família Gemini projetada para a execução de tarefas específicas ou recorrentes, ou para atuar como um especialista em um tema específico (Google, 2025c). A análise pormenorizada da interface de desenvolvimento e da documentação técnica relacionada a ferramenta Gemini Gem elucida uma estrutura conceitual nítida, cujos elementos também constituem as fontes basilares para a subsequente extração de metadados.

A Figura 5 apresenta a interface de usuário do Gemini Gem e destaca ainda mais a relativa facilidade de personalizar um LLM ao oferecer basicamente 2 parâmetros que podem influenciar significativamente todo o comportamento de um Gem.

Figura 5 – Interface do Gemini Gem.



Fonte: elaboração do autor.

Na figura 5 o destaque é para “Instruções” e “Conhecimento”, correspondendo ao *System Instructions* e *File Uploads* disponíveis no Google AI Studio. Embora no Gemini Gem a quantidade de possíveis configurações seja bem limitada em comparação com o Google AI Studio, é possível instruir o comportamento do LLM personalizado usando linguagem natural e oferecendo ao modelo uma base de conhecimento específica para suas respostas.

Aplicando a análise documental, os principais componentes instrucionais disponíveis na ferramenta Gemini Gem são sistematizados no quadro 3 (Google, 2025c).

Quadro 3 – Componentes Instrucionais para a Criação de um Gemini Gem.

Componente	Descrição	Tipo de Valor
Name	O nome formal e identificador do Gem, o LLM personalizado. Um identificador textual único que nomeia o Gem e o distingue de outros. É o seu rótulo formal.	Texto livre
Description	Descrição breve do Gem, o LLM personalizado, incluindo sua função.	Texto livre
Instructions	O campo principal onde aquele que personaliza insere as diretrizes gerais para o comportamento do LLM personalizado. Este é o núcleo da personalização, pois trata-se de um campo de texto livre onde descreve-se, em linguagem natural, o comportamento desejado para o LLM personalizado. As instruções podem definir uma persona (p. ex., "Aja como um tutor de escrita acadêmica"), o tom (p. ex., "Use uma linguagem formal e encorajadora"), o formato da resposta (p. ex., "Responda sempre em tópicos"), as tarefas a serem executadas e as restrições a serem seguidas.	Texto livre
File Uploads	Permite o carregamento de arquivos, por exemplo, PDFs e outros, para fornecer ao LLM personalizado um contexto adicional e específico para suas tarefas. Esses documentos de texto servem como uma base de conhecimento suplementar. O LLM personalizado pode consultar esses documentos para fornecer respostas mais contextuais e precisas, indo além da sua base de conhecimento original.	Referência a arquivo

Fonte: elaboração do autor.

É fundamental compreender que os dois paradigmas, técnico e semântico, ou seja, Google AI Studio e Gemini Gem, não são mutuamente exclusivos. Eles representam duas camadas de abstração para controlar o mesmo objeto alvo, um LLM ou modelo de base. As instruções semânticas de alto nível fornecidas a um Gem usando a ferramenta Gemini Gem são, em última instância, traduzidas pela plataforma em configurações que o modelo pode interpretar, o que inclui ajustes implícitos nos parâmetros técnicos (Google, 2025b; Google, 2025c). Por exemplo, instruir um Gem a ser altamente criativo e original, uma diretriz semântica, provavelmente resulta em uma configuração interna com um valor de *Temperature* elevado, um parâmetro técnico. Portanto, o paradigma semântico-instrucional oferecido pela ferramenta Gemini Gem pode ser visto como uma abstração amigável do paradigma técnico-

configuracional disponível no Google AI Studio. Um perfil de aplicação de metadados completo deve ser capaz de capturar ambas as camadas de descrição.

A interface de criação de um LLM personalizado, disponível nas ferramentas Gemini Gem ou Google AI Studio, vai muito além da simples escolha de uma ferramenta, e nesta pesquisa materializou-se como o locus laboratorial que torna possível compreender as informações e os fenômenos informacionais relacionados ao processo de personalização de um LLM. A metodologia fundamentada em revisão de literatura e análise documental aplicada nesta pesquisa trouxe à tona uma anatomia explícita que serve como um ponto de partida fundamental para a proposição de um perfil de aplicação de metadados, uma vez que ela revela os atributos mais proeminentes para representação relacionados aos LLMs.

4.3 Inteligência Artificial Confiável fundamentada em Metadados

A Inteligência Artificial Confiável (*Trustworthy AI*) surge como um paradigma influente para reduzir os riscos associados à crescente autonomia de sistemas automatizados. Segundo Phillips *et al.* (2021, p. ii), a busca por explicabilidade é uma das características desejáveis para cultivar a confiança em sistemas de IA, integrando um conjunto de propriedades técnicas que sustentam a aceitação social dessas tecnologias. No entanto, a explicabilidade não opera isoladamente, mas interage com outros atributos técnicos, de segurança e redução de vieses prejudiciais ao longo de todo o ciclo de vida do sistema.

A fundamentação teórica da IA Confiável estabelecida pelo *National Institute of Standards and Technology* (NIST) identifica dimensões sócio-técnicas que ultrapassam o contexto da eficácia algorítmica pura. De acordo com Phillips *et al.* (2021, p. ii), além da explicabilidade e interpretabilidade, a confiança é sustentada pela precisão, privacidade, resiliência e responsabilidade. Essa visão multidimensional reconhece que não existe uma explicação universal, visto que diferentes usuários e cenários exigem diferentes tipos de evidências para validar os processos de decisão de um artefato tecnológico.

Dentro deste espectro, a explicabilidade assume um papel central na comunicação entre a máquina e o receptor humano da informação. Conforme Phillips *et al.* (2021, p. 1), a falha em articular a lógica por trás de uma resposta pode impactar diretamente o nível de confiança concedido pelos usuários, gerando suspeitas de injustiça ou opacidade. Assim, o desenvolvimento de sistemas explicáveis visa não apenas a conformidade regulatória, mas a criação de uma parceria informada entre humanos e sistemas de IA em cenários críticos, onde o entendimento dos processos implícitos é indispensável.

A formalização de princípios para a IA explicável permite medir a qualidade das respostas fornecidas por esses sistemas. Phillips *et al.* (2021, p. 2) introduzem quatro princípios fundamentais: a explicação, a significância (*meaningful*), a precisão da explicação e os limites de conhecimento. Enquanto a precisão garante que a justificativa reflita o processo real do sistema, a significância assegura que o conteúdo seja compreensível para o consumidor pretendido, adaptando-se ao seu nível de expertise e ao contexto da consulta.

No contexto da CC, a abordagem da IA Confiável concentra-se predominantemente em métodos computacionais para elucidar o funcionamento algorítmico de um LLM. Qin e Yu (2024, p. 3) destacam que essa perspectiva foca no comportamento matemático da arquitetura computacional, na otimização de parâmetros e algoritmos, tratando muitas vezes os dados como uma entrada estática. Nessa visão técnica, o objetivo reside frequentemente em transformar modelos denominados caixas-pretas em estruturas mais transparentes por meio de visualizações matemáticas e métricas de desempenho algorítmico.

As metodologias de *Explainable AI* (XAI) desenvolvidas pela CC, como a *Local Interpretable Model-agnostic Explanations* (LIME) e *SHapley Additive exPlanations* (SHAP), exemplificam técnicas que visam aproximar o comportamento de modelos opacos. Ridley (2022, p. 2) observa que essas técnicas se classificam conforme o escopo e o mecanismo, podendo fornecer explicações locais para decisões específicas ou globais para o modelo de forma generalizada. Contudo, existe uma distinção crítica, ou seja, enquanto a CC foca na explicabilidade da inferência concentrando-se no processamento algorítmico durante a execução, muitas vezes negligencia as variáveis contextuais e a procedência dos dados que alimentam tais modelos. No contexto de LLMs personalizados isso se torna um problema.

A carência de metadados detalhados sobre os conjuntos de dados e parâmetros de configurações usados na personalização de um LLM representa um obstáculo significativo para a confiabilidade, mesmo sob a ótica computacional. Segundo Qin e Yu (2024, p. 3), detalhes necessários sobre a qualidade dos dados são frequentemente perdidos, resultando em LLMs personalizados em dados ruidosos sem a devida documentação. A ausência de metadados para descrever o design dos dados compromete a rastreabilidade e a reprodutibilidade, pilares fundamentais para uma IA considerada ética e confiável.

A consolidação da confiança e da credibilidade nos sistemas de IAG, especialmente no âmbito dos LLMs personalizados, está condicionada à transparência sobre a origem e as transformações sofridas pelos corpora de dados e parâmetros de configuração. Nesse contexto, a incorporação de metadados de proveniência estruturados sob a especificação PROV-O pode atuar como um suporte para sustentar a confiabilidade da IA, haja vista que, como aponta

Arakaki (2019), a preservação da integridade e da persistência por meio do registro detalhado da proveniência dos dados constitui a base para assegurar a fidedignidade das informações em ecossistemas digitais. Ao mapear de forma inequívoca as interações entre os atores, desenvolvedores e curadores, as atividades de personalização e as entidades informacionais utilizadas, o modelo estabelece uma trilha de auditoria e verificação necessária para a governança de dados, confirmando que "a identificação clara da proveniência dos dados a partir dos metadados administrativos é fundamental para promover a credibilidade das informações reutilizadas em ambientes digitais" (Arakaki, 2019, P. 19).

Sob a perspectiva da CI, o LLM personalizado constitui um objeto informacional complexo, cuja confiabilidade requer a integração entre a explicabilidade algorítmica e a explicabilidade contextual (Baca, 2016; Gilliland, 2016; Haynes, 2018). A caracterização de um LLM personalizado como um objeto informacional complexo fundamenta-se, sob a ótica da CI, na superação da estática dos recursos digitais tradicionais, cujos conteúdos e limites são previamente fixados. Diferentemente de documentos textuais ou arquivos multimídia convencionais, o LLM personalizado constitui uma entidade dinâmica, probabilística e sociotécnica, cuja existência informacional emerge da integração em camadas que articulam a capacidade do modelo de base, as instruções do sistema, o alinhamento instrucional e os corpora suplementares. Objetos digitais complexos caracterizam-se por sua arquitetura multinível e pela dependência contínua de metadados para preservar a proveniência, a inteligibilidade e o contexto de uso ao longo do tempo (Gilliland, 2016; Haynes, 2018). Complementarmente, salienta-se que artefatos dotados de propriedades comportamentais e mutáveis demandam esquemas de representação capazes de explicitar não apenas o seu conteúdo, mas a própria lógica operacional e os fluxos de mediação que condicionam a geração da informação (Pomerantz, 2015; Zeng; Qin, 2016).

A complexidade de um LLM personalizado manifesta-se no fato de que o produto informacional gerado não se encontra previamente armazenado, mas é sintetizado em tempo real a partir da interação entre a arquitetura algorítmica, o direcionamento semântico estabelecido pelo personalizador e as solicitações fornecidas pelo usuário final. Sob esse prisma se reitera que a representação de recursos cujos atributos e comportamentos sofrem constante reconfiguração exige o aporte de instrumentos de catalogação capazes de fixar a rastreabilidade e a autenticidade do objeto informacional (Baca, 2016; Alves, 2010). Nessa perspectiva, o LLM personalizado desafia a CI a expandir os limites da transparência puramente algorítmica, exigindo uma explicabilidade contextual que documente as condições de concepção, restrições

éticas e limites de conhecimento desse objeto informacional, contribuindo para governança em ambientes digitais (Qin; Yu, 2024; Ridley, 2022).

A transição para uma perspectiva da CI permite preencher essa lacuna por meio da gestão estruturada e sistemática de metadados. Qin e Yu (2024, p. 1) argumentam que os metadados desempenham um papel crítico na transparência da IA, servindo como uma ponte entre os artefatos de dados e o comportamento final do LLM personalizado. Diferente da abordagem algorítmica, a CI visualiza a confiabilidade como um problema de governança e organização da informação, onde a descrição precisa de todo o ciclo de vida informacional é essencial para a auditoria e validação.

A adoção de metadados estruturados transforma a relação de confiança entre usuários e sistemas de IAG. Conforme Ridley (2022, p. 3), a explicabilidade pode ser vista como um conjunto de provas e validações que permitem o gerenciamento eficaz entre parceiros humanos e artificiais, sendo este último, por exemplo, um LLM personalizado. Para a CI, a confiança não é simplesmente delegada à tecnologia, mas mediada por uma supervisão informada, onde o conhecimento sobre a natureza e os mecanismos da delegação algorítmica é um requisito indispensável para a manutenção da agência humana.

No contexto da personalização de LLMs a partir de modelos de base existentes, os metadados emergem como o substrato necessário para o que se define nesta pesquisa como explicabilidade contextual. Qin e Yu (2024, p. 5) reiteram que a garantia das propriedades de responsabilidade, ética e verificabilidade de modelos de IA, especificamente nesta pesquisa os LLMs personalizados, depende da qualidade dos metadados associados. Portanto, a descrição de requisitos funcionais e estruturais específicos torna-se uma prática de controle de qualidade e uma política de informação para o desenvolvimento de uma IA documentada.

Neste cenário de IA Confiável, a contribuição desta pesquisa reside na proposição da explicabilidade fundamentada em metadados, diferenciando-se das abordagens tradicionais da CC focadas estritamente na lógica da inferência. Enquanto a CC busca responder as razões internas a uma decisão específica do LLM, esta proposta foca em variáveis determinantes para a construção da confiança contextual. Como aponta Qin e Yu (2024, p. 5), a explicabilidade fundamentada em metadados, como *Model Cards,* pode permitir que os usuários determinem se um sistema de IA é confiável para sua finalidade específica confirmando se o LLM personalizado atende a expectativas esperadas.

O MAP proposto nesta pesquisa contribui para uma visão da explicabilidade fundamentada em metadados ao oferecer uma camada de explicação que supera justificativas puramente técnicas focadas no funcionamento de algoritmos e saídas pontuais. Sob essa

premissa, cumpre delimitar com clareza que o MAP-CLLM não se destina a representar o processo de tokenização em si, no qual constitui um mecanismo matemático-computacional de vetorização e amostragem estatística em nível de subpalavras durante a inferência, nem se limita estritamente à interação isolada do usuário ou aos resultados pontuais gerados. Em vez disso, seguindo o modelo LRM, o MAP-CLLM representa o LLM personalizado em sua totalidade enquanto objeto informacional complexo, articulando de forma integrada o modelo de base como Obra, as diretrizes de personalização e parâmetros como Expressão, o serviço acessível como Manifestação e os registros auditáveis das interações como Item, nos quais a tokenização transparece apenas por meio de suas restrições paramétricas. Ao padronizar a representação dessas dimensões, o MAP-CLLM estabelece as bases para uma governança que exige reflexão explícita sobre o propósito, as limitações e os riscos desses objetos informacionais. Assim, conclui-se que o registro de metadados estruturado atua como um instrumento de transparência e responsabilidade, configurando-se como requisito para a tomada de decisão informada sobre a confiabilidade de um LLM personalizado.

4.4 Model Cards: representação da informação para LLMs personalizados

Diante do desafio representacional imposto pelos artefatos de IA, a própria comunidade de pesquisa e desenvolvimento em IA gerou uma resposta pragmática. Em resultado de suas pesquisas, Mitchell *et al.* (2019) propuseram os *Model Cards*, concebidos como uma intervenção crítica para promover a transparência, a justiça e a responsabilização no ecossistema de IA. A proposta original visava à criação de documentos curtos, análogos a rótulos nutricionais, para modelos de ML, um subconjunto da IA, com o objetivo de comunicar de forma clara e padronizada as características, capacidades e limitações de um modelo a um espectro diversificado de partes interessadas, incluindo desenvolvedores, formuladores de políticas públicas e a sociedade em geral (Mitchell *et al*., 2019).

Embora a proposta original de Mitchell *et al.* (2019) tenha sido concebida para modelos de ML no geral, o uso de *Model Cards* é amplamente adotado para LLMs, por exemplo, a Google utiliza variações da documentação do tipo *Model Card* para promover a transparência de seus LLMs (Google, 2025d; Google, 2025e). A necessidade de documentação detalhada para um LLM é mais urgente devido às suas características consideradas na seção anterior, por exemplo, sua enorme e complexa quantidade de parâmetros configuráveis, na casa dos bilhões, e a arquitetura de RNAs baseadas em Transformer torna difícil entender exatamente como funcionam e por que tomam certas decisões. A versatilidade de um LLM, usados para tarefas de geração de código de programação de computadores, resumos, produção de textos e chat,

aumentam o potencial de usos indevidos ou danos não intencionais, como a geração de desinformação ou conteúdo nocivo, justificando a necessidade de documentação. Por fim, considerando que para o desenvolvimento dos modelos de base, conjuntos de dados massivos e não curados, também oriundos da internet, são usados, podendo resultar de um LLM incorporar e amplificar vieses sociais, a seção de considerações éticas do *Model Card* torna-se necessária.

A estrutura fundamental de um *Model Card*, conforme delineada por Mitchell *et al.* (2019), já prenunciava sua vocação como um esquema de metadados. O *framework* é decomposto em seções lógicas que funcionam como agrupamentos de elementos, por exemplo, seções para detalhes do modelo, uso pretendido, fatores, métricas e considerações éticas abrigam elementos específicos, como a versão do modelo, seus usuários primários, as medidas de desempenho em subgrupos demográficos e os riscos de uso indevido (GOOGLE, 2025d). Essa organização naturalmente estruturada representa o primeiro passo na transição de um guia de documentação para um esquema de metadados formalizável, capaz de capturar as múltiplas facetas de um LLM personalizado.

Um *Model Card* completo, baseado na estrutura proposta por Mitchell *et al.* (2019), deve conter metadados suficientes que visem a transparência, a rastreabilidade e a avaliação ética de um LLM, entretanto, é necessário esclarecer, corroborando para a importância da proposta de um MAP para um LLM personalizado, que na proposta de Mitchell *et al.* (2019) o número de metadados de um *Model Card* não é fixo e pode variar bastante. Essa estrutura flexível se expande para incluir muitos metadados específicos dependentes da plataforma usada para armazenar os LLMs, tipo de LLM personalizado e profundidade da análise ética pretendida, ou seja, a quantidade de metadados representada por um *Model Card* será influenciada pelo contexto do estudo relacionado ao processo de personalização do LLM. A lista a seguir, também baseada na documentação oficial da Google (2025d; 2025e) detalha os elementos-chave que podem compor um *Model Card* completo, agrupados por função.

Na função de apresentar detalhes básicos e identificar o LLM, podendo ser classificado como metadados descritivos, os elementos que fornecem essa **identificação formal do modelo** são:

- **Nome e Versão:** Nome completo e número da versão atual.
- **Desenvolvedores:** Ator, pessoa ou organização, responsável pela criação e manutenção.

- **Data de Criação:** Quando o modelo foi personalizado e disponibilizado pela primeira vez.
- **Modelo:** LLM usado como modelo de base no processo de personalização.
- **Recursos/Citação:** Links para o *Model Card* do modelo de base usado, artigos científicos e/ou a citação bibliográfica do modelo.
- **Licença:** Condições de uso e distribuição.

Quando a função é definir **o escopo do modelo** e esclarecer a quem ele se destina, sendo os metadados administrativos de uso e contexto vitais para o uso responsável, os elementos que define o uso pretendido são:

- **Casos de Uso Primários:** O que o modelo foi especificamente personalizado para fazer e para resolver.
- **Usuários Pretendidos:** Quem são os usuários finais que devem usar o modelo personalizado, por exemplo, gerentes de produto, professores, nutricionistas.
- **Casos de uso para os quais o modelo não é recomendado ou que representam risco:** Por exemplo, modelo personalizado para nutricionistas não deve ser usado para fazer diagnóstico ou prescrição nutricional.

Na função de detalhar os **fatores de impacto de desempenho** do LLM personalizado no mundo real, os elementos relevantes são:

- **Fatores Demográficos:** Grupos populacionais, por exemplo, gênero, idade ou etnia, para os quais os resultados podem variar.
- **Fatores Ambientais:** Condições de contorno, por exemplo, iluminação, qualidade do áudio, idioma ou tipo de câmera, para LLMs personalizados para imagens ou vídeos.
- **Fatores Instrumentais:** Especificações técnicas, por exemplo, hardware de execução, sensores necessários ou latência aceitável da comunicação para a performance do LLM conectado a dispositivos físicos.

Quanto a **estabelecer a proveniência** e a base de conhecimento do LLM personalizado, função que esclarece quais dados foram usados no processo de personalização do LLM e quais foram usados para avaliar a performance do modelo, sugere-se os seguintes:

- **Descrição do corpus utilizado na personalização do LLM:** Detalhes do conjunto de documentos ou dados selecionados e coletados para serem usados.
- **Informação sobre a distribuição de fatores relevantes:** Por exemplo, demográficos ou geográficos contidos no corpus usado na personalização.

- **Descrição do corpus usado para testar o LLM personalizado:** Sempre diferente do corpus usado no processo de personalização.
- **Justificativa para a escolha do corpus usado para testar o LLM personalizado:** Por exemplo, um corpus representativo do uso real ou escolhido para testar casos extremos e desafiadores.

Por fim, quando a função é analisar o desempenho e ética, o coração da transparência e responsabilidade, detalhando como o LLM personalizado realmente funciona na prática, os elementos relacionados a **métricas de desempenho** são:

- **Quais métricas de desempenho foram escolhidas:** Por exemplo, BLEU (*Bilingual Evaluation Understudy*), ROUGE (*Recall-Oriented Understudy for Gisting Evaluation*), Métricas de similaridade semântica ou Perplexidade, apenas para citar algumas. Também espera-se uma justificativa do porque são relevantes para o perfil da aplicação em questão, o LLM personalizado.
- **Resultados da Análise Quantitativa:** O desempenho do modelo quebrado por métricas e, principalmente, desagregado pelos fatores relevantes já mencionados, fatores demográficos, ambientais e instrumentais.

Ainda na função de analisar o desempenho e ética, os elementos relacionados às **considerações éticas** são:

- **Vieses Conhecidos:** Quais vieses ou deficiências sistemáticas nos dados ou no LLM personalizado foram identificados.
- **Mitigação de Riscos:** Medidas tomadas para reduzir impactos negativos.
- **Monitoramento:** Recomendações sobre como e com que frequência o LLM personalizado deve ser monitorado em uso para garantir segurança contínua.
- **Riscos de Uso Indevido:** Quais são os danos potenciais do uso indevido do LLM personalizado.

É necessário reafirmar que o número de elementos, ou metadados, que um *Model Card* sugere não é fixo e pode variar, visto que a proposta de Mitchell *et al.* (2019) permite uma representação flexível e expansível para a inclusão de metadados específicos do perfil da aplicação, nesta pesquisa, um LLM personalizado. Baseando-se na afirmação de Qin e Yu (2024, p. 5) de que vale a pena considerar a personalização de um *Model Card* voltada para um cenário específico, na construção do MAP proposto nesta pesquisa ocorre a definição de quais elementos, ou metadados, de um *Model Card* de fato serão usados.

O que contribuiu para a posição dos *Model Cards* como um padrão de fato não foi um processo de padronização acadêmico, mas uma evolução pragmática impulsionada pela

necessidade de gerenciar informação em larga escala. À medida que repositórios de modelos de IA cresceram para hospedar centenas de milhares de artefatos de IA, a gestão de documentação puramente textual tornou-se insustentável para fins de busca, comparação e governança (Liang *et al*., 2024). Em resposta a essa necessidade prática de engenharia, esses repositórios implementaram os *Model Cards* incluindo arquivos com um bloco de metadados estruturado (Hugging Face, 2025). Esses arquivos, legíveis por máquina, passaram a alimentar funcionalidades essenciais desses repositórios, como a filtragem de modelos por licença, tarefas, tags e conjuntos de dados associados. Essa decisão transformou o *Model Card* de um mero documento em um artefato híbrido, um texto legível por humanos com um cabeçalho de metadados processável por máquinas, validando organicamente a relevância e a utilidade dos seus elementos centrais para a gestão programática da informação (Liang *et al*., 2024; Hugging Face, 2025).

A tendência de formalização foi posteriormente reforçada pelo desenvolvimento de ferramentas especializadas, notadamente o *Model Card Toolkit* (MCT) do Google (Tensorflow, 2025). O MCT foi explicitamente projetado para otimizar e automatizar a geração de *Model Cards*, utilizando um formato de arquivo denominado esquema JSON para armazenar e estruturar os campos do documento. A sua integração com plataformas de ML como *TensorFlow Extended (TFX)* evidencia a transição da documentação de uma tarefa manual e estática para um componente automatizado e dinâmico dentro do ciclo de vida do desenvolvimento de modelos de IA (Tensorflow, 2025). Esse movimento em direção à automação baseada em esquemas categoriza o *Model Card* como um formato de dados estruturados, e não apenas um guia de boas práticas.

A institucionalização dos *Model Cards* pelo Regulamento (UE) 2024/1689 (*AI Act*) também destaca a relevância deste padrão de metadados introduzido por Mitchell *et al.* (2019). A legislação europeia reconhece explicitamente os *Model Cards* como uma das melhores práticas da indústria e incentiva sua adoção para a documentação técnica ao longo da cadeia de valor da IA, incluindo LLMs personalizados (União Europeia, 2024).

A recomendação explícita para o uso de *Model Cards* pela legislação europeia aparece nos itens 89 e 165 do regulamento. No item 89, focado na cadeia de valor e componentes de IA, o regulamento incentiva os desenvolvedores de ferramentas, serviços e componentes de IA a implementar práticas de documentação amplamente adotadas, citando os *Model Cards* como forma de acelerar o compartilhamento de informações ao longo da cadeia de valor e promover sistemas de IA confiáveis (União Europeia, 2024, p. 24). No item 165, focado em sistemas de menor risco e códigos de conduta, o regulamento encoraja provedores de sistemas de IA que

não sejam de alto risco a criar códigos de conduta voluntários. O texto orienta que esses códigos levem em consideração as melhores práticas da indústria, citando nominalmente os *Model Cards* (União Europeia, 2024, p. 41).

Apesar dessa evolução e ampla adoção, a ausência de um padrão formal e universal resultou em uma implementação heterogênea e inconsistente. Estudos sobre repositórios de modelos revelam que a prática de documentação é falha, com uma parcela significativa de *Model Cards* estando incompletos (Liang *et al*., 2024; Siqueira; Moreira; Alves; Sant'ana, 2026). As seções que abordam as limitações, os riscos e as considerações éticas, cruciais para a confiança e o uso responsável, são as mais frequentemente negligenciadas ou preenchidas de forma superficial (Rao *et al*., 2025). Essa inconsistência sugere que, sem a imposição de restrições formais, os desenvolvedores tendem a omitir informações que são difíceis de gerar ou que poderiam ser percebidas negativamente.

A falta de um esquema unificado também gera desafios de portabilidade e ambiguidade semântica, dificultando a comparação de modelos de IA entre diferentes plataformas e provedores (Rao *et al*., 2025). O *framework do Model Card,* em sua forma, pode ser entendido como uma abstração que fornece as categorias conceituais corretas, mas carece das restrições formais, por exemplo, a definição de campos obrigatórios, vocabulários controlados e sintaxes de codificação, necessárias para garantir a qualidade, a completude e a interoperabilidade dos registros de metadados.

É precisamente essa lacuna, entre um padrão de fato consistente em seus conceitos, mas falho em sua aplicação prática, que justifica a presente pesquisa. A evolução do *Model Card* demonstra um consenso comunitário sobre os elementos essenciais para descrever um LLM personalizado, contudo, suas inconsistências práticas necessitam de uma formalização, encontrando na metodologia de criação de um MAP, oriunda da CI, o instrumental teórico e prático para transformar esse padrão de fato em um esquema de padrão formalmente reconhecido, estabelecido e regulamentado. Um MAP pode não apenas selecionar e refinar os elementos do *Model Card*, mas também instituir as políticas de obrigatoriedade e as diretrizes de preenchimento que são essenciais para concretizar, de forma sistemática e verificável, o espírito original de transparência e responsabilidade que motivou sua criação.

Portanto, é possível reconhecer que um *Model Card* é uma ferramenta de engenharia de metadados e documentação de informação aplicada à modelos de IA. Enquanto a CC cria o modelo de IA, a CI oferece o *framework* teórico e as metodologias para estruturar e padronizar a documentação dos metadados necessários para que um LLM personalizado seja compreendido, avaliado de forma ética e justa e recuperado por outros usuários e pesquisadores.

A proposta de Mitchell *et al.* (2019) reitera a exigência de contextualizar objetos informacionais complexos, contudo, é a CI que fornece os fundamentos conceituais do tratamento descritivo necessários para converter o framework *Model Cards* em um Perfil de Aplicação de Metadados interoperável e voltado à IA Confiável.

5 METADADOS NO CONTEXTO DA CIÊNCIA DA INFORMAÇÃO

A Ciência da Informação (CI) caracteriza-se como um campo interdisciplinar voltado à análise, coleta, classificação, manipulação, armazenamento, recuperação e disseminação da informação registrada, investigando-a desde a sua gênese até a sua efetiva transformação em conhecimento (Nhacuongue; Ferneda, 2015). A despeito de a informação ser insumo para as demais ciências, a CI destaca-se por tomá-la como seu próprio objeto de estudo no âmbito dos processos de geração, transferência e comunicação informacional. Essa abrangência sustenta diversas correntes teóricas na área, que contemplam desde abordagens quantitativas, como estudos bibliométricos, até investigações sobre a produção e comunicação científica, estudos de usuários voltados ao planejamento informacional e teorias dedicadas à classificação e representação do conhecimento (Nhacuongue; Ferneda, 2015).

No domínio do tratamento descritivo, as preocupações da CI voltam-se historicamente às formas de representação dos objetos informacionais, consolidadas nas práticas de catalogação oriundas da Biblioteconomia e expandidas pelo emprego de padrões de metadados (Alves, 2010). Diante do avanço do cenário web e do esforço interdisciplinar para o estabelecimento de esquemas genéricos e específicos de representação, a área tem se debruçado sobre a qualidade, a padronização e a interoperabilidade desses recursos. Nessa perspectiva, as metodologias e instrumentos desenvolvidos pela CI asseguram a eficácia dos metadados na gestão do conhecimento, na governança de dados e na preservação da herança cultural em ambientes digitais e instituições de memória (Gilliland, 2016; Haynes, 2018; Greenberg; Wu; Liu; Liu, 2023).

Do ponto de vista conceitual, embora a literatura apresente uma pluralidade de interpretações contextuais para o termo "metadados", sobressai a compreensão convergente de que estes constituem uma representação formal, padronizada e estável destinada a definir, explicitar e estruturar recursos informacionais (Zeng; Qin, 2016; Ulrich *et al.*, 2020, p. 4). Superando a definição intuitiva que os reduz ao aforismo "dados sobre dados", os metadados atuam como uma infraestrutura informacional e uma camada estruturada de conhecimento que torna manifestos o conteúdo, a estrutura, o formato e a proveniência dos objetos, conferindo-lhes contexto e significado (Alves, 2010, p. 14; Pomerantz, 2015; Mayernik, 2021). Suas tipologias funcionais, incluindo as dimensões descritiva, estrutural, administrativa, técnica e de preservação, materializam-se em padrões consagrados, a exemplo do Dublin Core (DC), e viabilizam desde a busca precisa em repositórios digitais até o controle de acesso, a governança

e a reprodutibilidade da pesquisa científica em ecossistemas abertos (Alves, 2010, p. 22; Haynes, 2018).

Em termos operacionais, a determinação de metadados exige a identificação criteriosa das propriedades essenciais de um objeto para torná-lo localizável, compreensível, interoperável e reutilizável tanto por humanos quanto por aplicações computacionais (Zeng; Qin, 2016). Esse processo sistemático compreende a análise do recurso, a seleção dos esquemas e elementos pertinentes, a atribuição dos valores descritivos de forma manual ou automatizada, e o armazenamento integrado em repositórios (Alves, 2010, p. 47). Como destacam Alves (2010, p. 111) e Gilliland (2016), a aplicação consistente dessas diretrizes e a adoção de padrões rigorosos criam representações unívocas e enriquecidas, indispensáveis para assegurar a usabilidade, a autenticidade e a acessibilidade de longo prazo dos dados em múltiplos contextos institucionais, como arquivos, bibliotecas, museus e ecossistemas web. É precisamente sobre esse contexto teórico-prático que se fundamentam os procedimentos relacionados à determinação de metadados, conforme detalhado na sequência.

5.1 Determinação de Metadados

A determinação dos metadados orientados à representação de um objeto informacional constitui um processo sistemático de análise, seleção e determinação final de atributos essenciais destinados a assegurar a identificação, a encontrabilidade, a compreensão, a interoperabilidade e o reuso de recursos por agentes humanos e aplicações computacionais (Alves, 2010; Gilliland, 2016). Importa ressaltar que o emprego do termo "determinação" nesta tese, em preterição à rubrica "definição", fundamenta-se na necessidade de afastar ambiguidades semânticas, visto que, não busca-se apenas conceituar o vocábulo "metadados", mas identificar e delimitar as propriedades descritivas, estruturais e administrativas pertinentes a um LLM personalizado. Afastando-se de prescrições rígidas ou dogmáticas, esta seção articula as teorias da CI que sustentam a construção do MAP proposto (Ulrich *et al.*, 2020; Liu; Fu; Liu, 2023).

Sob a perspectiva conceitual da CI, os metadados superam a simplificação reducionista do aforismo "dados sobre dados" já mencionada, consolidando-se como uma infraestrutura informacional e uma camada estruturada de conhecimento responsável por conferir contexto, proveniência e significado aos objetos digitais (Zeng; Qin, 2016; Pomerantz, 2015). O avanço dos ecossistemas de dados complexos evidencia, contudo, que a presença de equívocos na conceituação dos metadados permanece um desafio central na área (ULRICH *et al.*, 2020). Conforme demonstram Ulrich *et al.* (2020, p. 2), constata-se frequentemente uma divergência

de fronteiras conceituais entre os especialistas de um domínio e os profissionais de metadados; nesse cenário, a harmonização terminológica e semântica emerge como um requisito indispensável para viabilizar a integração significativa de dados heterogêneos e a construção de representações estáveis e compartilhadas.

Essa complexidade exige que o tratamento descritivo seja compreendido como um quadro metodológico e sistemático voltado à modelagem de arquiteturas de conhecimento, e não apenas como preenchimento de campos formais (Liu; Fu; Liu, 2023). Ao analisar a trajetória histórica dos metadados, Liu, Fu e Liu (2023, p. 291-293) destacam a dificuldade de balançar fatores concorrentes tais como conveniência, custos operacionais, extensibilidade, compatibilidade e a centralidade da análise humana do especialista, especialmente diante das exigências de difusão de recursos e preservação em longo prazo inerentes às redes contemporâneas. Essa visão se alinha à abordagem de Haynes (2018), para quem a governança informacional e o gerenciamento de metadados em ambientes digitais dependem do equilíbrio preciso entre o rigor metodológico e a flexibilidade necessária para responder às dinâmicas do fluxo comunicacional da informação.

No âmbito funcional, a literatura da CI converge para a sistematização dos metadados em tipologias complementares, fundamentando-se nas categorizações estabelecidas pela *National Information Standards Organization* (NISO) e expandidas pela área (Baca, 2016; Riley, 2017). A dimensão descritiva atua diretamente na descoberta, identificação e compreensão do recurso, destacando atributos como título, autoria e assunto; a dimensão estrutural expressa as relações lógicas e hierárquicas entre as partes de um objeto; e a dimensão administrativa subdivide-se nas esferas técnica com parâmetros de decodificação, formato e renderização, de preservação para gestão de ciclo de vida e sustentabilidade digital e de direitos de propriedade intelectual (Riley, 2017; Ulrich *et al.*, 2020). A articulação dessas tipologias garante que o objeto informacional permaneça autêntico, acessível e funcional ao longo do tempo em diferentes contextos institucionais e tecnológicos (Gilliland, 2016; Baca, 2016).

A aplicação consistente dessas categorizações impõe reflexões profundas sobre a granularidade e o nível de detalhamento da descrição. Como adverte Alves (2010), a variedade de padrões disponíveis gera diferentes níveis de representação para um mesmo recurso, de modo que ambientes altamente específicos ou especializados demandam esquemas mais estruturados e o rigor analítico de um profissional da informação. Por outro lado, Baca (2016) salienta que a granularidade da descrição deve buscar o equilíbrio ideal, destacando que a representação não pode ser deficitária a ponto de omitir atributos essenciais para a recuperação, tampouco excessiva a ponto de inviabilizar a manutenção e o gerenciamento do sistema. A

determinação de metadados para um LLM personalizado exige, portanto, equilíbrio entre a densidade descritiva para atender às especificidades do modelo sem impor encargos operacionais desproporcionais (Alves, 2010; Baca, 2016).

Para além da seleção do esquema estrutural, a literatura enfatiza que a interoperabilidade semântica e sintática depende criticamente do controle dos valores atribuídos aos elementos de metadados (Alves, 2010; Riley, 2017). Conforme ressalta Riley (2017, p. 16-17), o emprego de vocabulários controlados, tesauros e listas de autoridades pré-definidas possibilita mapear termos preferenciais e sinônimos, garantindo que tanto aplicações computacionais quanto usuários interpretem o conteúdo de forma idêntica. Baca (2016) e Alves (2010, p. 115) reiteram que o mapeamento isolado dos campos de um esquema é insuficiente se não houver a harmonização das regras de catalogação e dos padrões de conteúdo, uma vez que a capacidade de troca de informações entre sistemas heterogêneos pressupõe consistência terminológica e conformidade a regras preestabelecidas pela comunidade de prática.

Na implementação de ecossistemas de metadados, princípios de simplicidade intencional e sustentabilidade devem guiar as decisões de projeto (Baca, 2016; Riley, 2017). Analisando o desenvolvimento histórico do padrão Dublin Core, por exemplo, Riley (2017, p. 23) evidencia que a opção deliberada por um conjunto enxuto e essencial de elementos foi o fator determinante para sua rápida e ampla adoção global. De forma convergente, Baca (2016) defende a produção de registros enxutos e o entendimento do ciclo de vida dos metadados como um processo incremental e de responsabilidade compartilhada, no qual um registro básico pode ser progressivamente enriquecido por diferentes atores, incluindo comunidades de usuários e sistemas automatizados, ao longo de sua circulação informacional (Pomerantz, 2015; Baca, 2016).

A forma de armazenamento e a arquitetura de conexão dos metadados também desempenham papel decisivo na usabilidade e na disseminação dos recursos. A incorporação direta dos metadados ao arquivo digital garante a preservação do contexto informacional mesmo quando o objeto é desvinculado de seu repositório de origem (Riley, 2017; Baca, 2016). Simultaneamente, na perspectiva dos dados abertos conectados, *Linked Open Data*, a criação de metadados desloca-se do preenchimento de formulários isolados para o estabelecimento de triplas e conexões semânticas em grafos de conhecimento mais amplos (Pomerantz, 2015; Riley, 2017). Essa abertura possibilita integrar os metadados formais gerados por profissionais às descrições produzidas por comunidades temáticas especializadas, combinando rigor técnico e granularidade colaborativa em interfaces de uso simplificadas (Riley, 2017; Baca, 2016).

Em se tratando de objetos informacionais complexos como os LLMs personalizados, cujo processo de personalização envolve o encadeamento de arquiteturas algorítmicas e a seleção de corpora textuais, os metadados de direitos e proveniência assumem centralidade crítica (Gilliland, 2016; Baca, 2016). Conforme apontam Baca (2016) e Haynes (2018), a documentação explícita do status de direitos autorais, das licenças de uso, da autoria, da jurisdição e do histórico de modificações é indispensável para garantir a governança de dados, a conformidade legal, a transparência e a auditabilidade dos recursos digitais. A investigação e o registro contínuo dos metadados de direitos devem, portanto, integrar o fluxo de trabalho rotineiro do tratamento informacional (Baca, 2016; Haynes, 2018).

Sintetizando a consolidação teórica e metodológica do tratamento descritivo da informação, Alves (2010, p. 85) postula que a representação de um recurso informacional em um cenário específico conduz o pesquisador a três caminhos possíveis, a) criar um novo esquema de metadados; b) adotar integralmente um esquema existente; ou c) modificar e combinar esquemas preexistentes. Considerando que não existe um padrão único capaz de abranger universalmente todas as dimensões de objetos emergentes e que a especificidade do ambiente informacional exige elevado rigor de estruturação, esta tese se alinha à terceira via metodológica (Alves, 2010, p. 124; Baca, 2016). Conclui-se, fundamentadamente, que a resposta metodológica ideal para a representação de LLMs personalizados consiste na elaboração de um Perfil de Aplicação de Metadados, MAP, denominado nesta pesquisa como MAP-CLLM, resultante do mapeamento, combinação e recontextualização dos padrões Dublin Core, *Model Cards*, *Library Reference Model* (LRM) e Schema.org.

5.2 Library Reference Model – LRM

Com o objetivo de desmembrar a complexidade relacionada ao processo de personalização de um LLM e oferecer uma base teórica para a proposição de um perfil de aplicação de metadados, esta pesquisa adota o *Library Reference Model* (LRM) (Riva; Le Bœuf; Žumer, 2020). O LRM atua como um modelo conceitual de alto nível que trata os dados em um sentido amplo, explicitando os princípios gerais que governam a estrutura lógica da informação e servindo de alicerce consistente para a implementação de sistemas informacionais (Oliveira; Castro; Jesus, 2021).

O desenvolvimento do LRM é o resultado da evolução dos modelos conceituais oriundos da "Família FR". Esse histórico iniciou-se em 1998 com a publicação do *Functional Requirements for Bibliographic Records* (FRBR), ganhando desdobramentos posteriores com o *Functional Requirements for Authority Data* (FRAD) em 2009 e com o *Functional*

Requirements for Subject Authority Data (FRSAD) em 2010 (Oliveira; Castro; Jesus, 2021). Embora operassem sob a mesma metodologia de Entidade-Relacionamento, esses modelos foram criados de maneira independente ao longo dos anos por distintos grupos de trabalho da IFLA, lidando separadamente com as perspectivas de registros bibliográficos, dados de autoridade e dados de assunto (Riva; Le Bœuf; Žumer, 2020).

A principal motivação técnica para a criação do LRM surgiu das divergências conceituais estabelecidas pelos seus predecessores ao lidarem com dilemas comuns do universo bibliográfico. Na prática, a tentativa de implementar o FRBR, o FRAD e o FRSAD simultaneamente em um único sistema "exigia a solução de problemas complexos de maneira ad hoc, com orientação mínima dos modelos" (Riva; Le Bœuf; Žumer, 2020, p. 5-6). Para sanar essa barreira técnica e remover as dificuldades de implementação, o projeto de harmonização adotou a modelagem de Entidade-Relacionamento Estendido (EER), o que permitiu tratar os dados de maneira hierárquica por meio de superclasses e subclasses, culminando na aprovação do documento consolidado do LRM em 2017 (Oliveira; Castro; Jesus, 2021).

Mesmo diante das inovações técnicas impostas pela consolidação, como a inserção da superclasse fundamental Res, englobando qualquer entidade do universo do discurso, as entidades Obra, Expressão, Manifestação e Item preservam uma importância capital na modelagem do LRM. O próprio documento de definição teórica do padrão assevera que "os relacionamentos entre obras, expressões, manifestações e itens são considerados como o núcleo estrutural do modelo" (Riva; Le Bœuf; Žumer, 2020, p. 60). Essa importância advém da necessidade de conectar organicamente a abstração do conteúdo intelectual ou artístico (Obra e Expressão) com a sua forma tangível e distribuição física (Manifestação e Item), viabilizando o correto agrupamento de realizações equivalentes nos catálogos e facilitando as tarefas de busca pelo usuário final (Riva; Le Bœuf; Žumer, 2020).

A centralidade dessas quatro entidades é tão imperativa que a adesão ao LRM é condicionada à presença estrutural delas. A literatura científica que analisa os impactos deste modelo destaca que, embora haja flexibilidade para omitir determinados atributos ou outros relacionamentos dependendo da aplicação, é "necessário reter os relacionamentos entre as entidades para uma aplicação ser considerada implementação do modelo" (Oliveira; Castro; Jesus, 2021, p. 372). Por conseguinte, a manutenção imperativa de Obra, Expressão, Manifestação e Item assegura que o modelo unificado continue provendo a sustentação funcional que permite representar o ciclo de vida do recurso informacional com rigor lógico e precisão semântica (Riva; Le Bœuf; Žumer, 2020).

Distanciando-se, portanto, de modelagens de estruturas monolíticas, o LRM é fundamentado a partir da modelagem Entidade-Relacionamento Estendido (EER), o que lhe confere uma arquitetura hierárquica na qual as entidades operam de forma interconectada como superclasses e subclasses (Oliveira; Castro; Jesus, 2021). O ponto central dessa modelagem é a introdução da entidade superior Res ("coisa", em latim), conceituada como "qualquer entidade no universo do discurso", englobando, portanto, absolutamente tudo aquilo que faz-se relevante em cenários diversos (Riva; Le Bœuf; Žumer, 2020, p. 21).

Sob o escopo abrangente da superclasse Res, o modelo consolida a análise dos recursos intelectuais e físicos por meio de quatro entidades fundamentais, que compõem o núcleo estrutural do universo da informação: Obra, Expressão, Manifestação e Item (Riva; Le Bœuf; Žumer, 2020). A transposição dessa hierarquia conceitual para a arquitetura de um LLM personalizado reflete as adequações necessárias para a representação do ambiente tecnológico vigente, viabilizando o controle, o compartilhamento e o reuso de dados em ecossistemas conectados da web (Oliveira; Castro; Jesus, 2021). Diante disso, o mapeamento destas quatro entidades bases permite delimitar metodologicamente as camadas que compõem a IAG abordada nesta tese na construção de um MAP.

A entidade Obra consiste em uma abstração, formalmente definida como "o conteúdo intelectual ou artístico de uma criação específica" (Riva; Le Bœuf; Žumer, 2020, p. 22). No cenário delineado por esta investigação, a Obra atua como o modelo de base, ou seja, o próprio LLM fundacional primário, por exemplo, o Gemini 3.5, que carrega em si a capacidade de processamento e os dados de treinamento, o conhecimento encapsulado e as capacidades fundamentais de raciocínio, codificação e escrita criativa que esses modelos de base oferecem, independentemente de qualquer personalização (Oliveira; Castro; Jesus, 2021; Google, 2025a).

Em seguida, a Expressão é caracterizada como "uma combinação específica de sinais que transmitem conteúdo intelectual ou artístico", existindo como a realização intelectual e singular de uma Obra (Riva; Le Bœuf; Žumer, 2020, p. 24). Para o MAP-CLLM, a Expressão reflete diretamente a personalização do LLM, materializando-se nas configurações paramétricas, nas diretrizes de comportamento e nas regras estabelecidas pelo curador permitidas pelas ferramentas de personalização, configurando o esforço intelectual que confere um escopo direcionado ao modelo de base. Cada conjunto de configurações cria uma nova Expressão da mesma Obra (Riva; Le Bœuf; Žumer, 2020; Google, 2025b).

A entidade Manifestação engloba a instância tangível e distribuível, sendo compreendida pelo modelo como um "conjunto de todos os suportes que supostamente compartilham as mesmas características do conteúdo intelectual ou artístico e aspectos da forma

física" (Riva; Le Bœuf; Žumer, 2020, p. 26). Nesse cenário, a Manifestação é a instância técnica e implementável do LLM personalizado, o aplicativo ou o serviço web resultante, a exemplo de um terminal interativo ou uma *Application Programming Interface* (API), que hospeda a Expressão e a converte em um produto técnico acessível ao público. É o serviço que encapsula a Expressão (Oliveira; Castro; Jesus, 2021; Google, 2025b).

Completando a modelagem e fechando a escala de granularidade, a entidade Item é a corporificação unitária, definida como "um ou vários objetos que carregam sinais destinados a transmitir conteúdo intelectual ou artístico" e que exemplifica uma Manifestação no mundo real (Riva; Le Bœuf; Žumer, 2020, p. 28). Transpondo essa definição para interações com a IAG, o Item descreve de forma atômica as sessões de chat interativas, compreendendo o par específico e temporal composto pela entrada enviada pelo usuário final, o prompt, e a respectiva resposta devolvida pelo LLM personalizado gerando um resultado particular e irrepetível (Riva; Le Bœuf; Žumer, 2020; Google, 2025c).

A caracterização da sessão interativa, o par atômico prompt e resposta, sob a entidade Item decorre da transposição ontológica necessária para a descrição de recursos informacionais dinâmicos e probabilísticos (Vaswani *et al.*, 2017; Riva; Le Bœuf; Žumer, 2020). No modelo LRM, o Item é definido como a corporificação concreta individualizada que carrega sinais destinados a transmitir o conteúdo intelectual de uma Manifestação (Riva; Le Bœuf; Žumer, 2020, p. 28). Ao transpor esse constructo para a IAG, observa-se que, enquanto a Manifestação constitui o serviço ou aplicação web funcionalmente disponibilizado, a informação gerada não se encontra pré-gravada em um suporte estático, mas é sintetizada sob demanda em um evento temporalmente discreto e irrepetível (Oliveira; Castro; Jesus, 2021). Sob a ótica do tratamento descritivo e da determinação de metadados, é possível afirmar portanto, que cada transação conversacional materializa-se como o único exemplar factual portador dos signos resultantes da operação daquela Manifestação. Ademais, conforme Arakaki (2019), a garantia de persistência e fidedignidade em ecossistemas digitais exige o registro exaustivo da proveniência dos dados, o que se alinha aos preceitos de explicabilidade contextual e governança preconizados para a IA Confiável (Qin; Yu, 2024). Desse modo, modelar o par prompt e resposta como Item satisfaz tanto a definição formal do LRM quanto os requisitos de auditabilidade algorítmica, fixando o registro da interação mediante identificadores unívocos de integridade sem descaracterizar a natureza do objeto informacional.

A adoção da modelagem EER do LRM permite que o MAP-CLLM individualize de modo sistemático e logicamente fundamentado as diferentes facetas operacionais da personalização tecnológica de um LLM (Oliveira; Castro; Jesus, 2021). Por meio desta

modelagem padronizada, assegura-se que a representação de LLMs personalizados ocorra com rigor e sem ambiguidades, consolidando o caminho para um ecossistema de metadados transparente, interoperável e coerente (Oliveira; Castro; Jesus, 2021).

A pertinência da aplicação do modelo LRM nesta pesquisa justifica-se primordialmente pela sua capacidade de fornecer o alicerce metodológico necessário para desmembrar a estrutura técnica de um LLM personalizado como um novo tipo de objeto informacional complexo (Oliveira; Castro; Jesus, 2021). O ecossistema de personalização da IAG produz objetos informacionais altamente dinâmicos que não podem ser descritos com precisão através de metadados genéricos de granularidade superficial (Riva; Le Bœuf; Žumer, 2020).

Ao transpor o rigor biblioteconômico para o cenário tecnológico, esta pesquisa demonstra que a personalização de um LLM alinha-se de forma estrutural ao LRM. Nessa dimensão, o modelo de base assume o "ser" da Obra abstrata, a parametrização algorítmica e o corpus injetado corporificam a Expressão intelectual do curador, a interface digital implementada constitui sua Manifestação tangível, e, por fim, cada sessão de chat pontual irreproduzível formaliza o Item (Riva; Le Bœuf; Žumer, 2020).

Adicionalmente, a adoção do LRM justifica-se pelo seu papel vital na viabilização da interoperabilidade, um requisito mandatório para a estruturação do MAP proposto neste trabalho (Oliveira; Castro; Jesus, 2021). Ao adotar as categorias deste modelo como infraestrutura de metadados, esta pesquisa assegura que a representação do LLM personalizado seja dotada de uma sintaxe coerente e de uma semântica passível de processamento automatizado oferecendo uma forma de acessar a informação sem ambiguidades (Oliveira; Castro; Jesus, 2021; Riva; Le Bœuf; Žumer, 2020).

Portanto, nesta pesquisa, este mapeamento revelou e destacou que as características distintivas de um LLM personalizado residem na sua Expressão e Manifestação, o conjunto de configurações e instruções que moldam o comportamento da Obra, o LLM usado como modelo de base. Portanto, um perfil de aplicação de metadados eficaz não pode se limitar a descrever o modelo de base e a interação com o usuário final, um Item, mas deve ser capaz de capturar os elementos que constituem a Expressão e a Manifestação.

5.3 O padrão Dublin Core

Esta seção apresenta o Dublin Core (DC) e a relação deste com a proposta de criação de um MAP para LLMs personalizados. A necessidade de representação da informação exige a definição de métodos e padrões que permitam a descrição e a recuperação eficaz de recursos informacionais. No ambiente digital, especialmente a web, a necessidade de representação

encontrou uma de suas respostas mais eficaz no padrão de metadados DC, entretanto, a crescente complexidade dos recursos digitais contemporâneos, como os LLMs personalizados, exige a consideração de outras abordagens para uma representação adequada. Contudo, ao analisar os fundamentos do DC foi possível pensar na sua aplicabilidade para o desenvolvimento de um MAP para LLMs personalizados.

O padrão DC emergiu em um momento marcante da história da informação digital e sua origem remonta ao "OCLC/NCSA Metadata Workshop", realizado em 1995 em Dublin, Ohio, como uma resposta direta ao desafio da descoberta de recursos na então nascente World Wide Web (Formenton *et al*., 2017). Profissionais de diversas áreas, incluindo biblioteconomia, ciência da computação e museologia, reuniram-se para conceber um conjunto semântico que fosse simples o suficiente para ser aplicado por não especialistas, mas eficiente o bastante para facilitar a interoperabilidade entre sistemas distintos, resultando o núcleo do padrão *Dublin Core Metadata Element Set* (DCMES) composto por 15 elementos (Formenton *et al*., 2017). Essa gênese permitiu sua ampla adoção e longevidade.

À medida que a web evoluiu e a complexidade dos objetos informacionais digitais se ampliou, as limitações de um conjunto puramente minimalista de metadados tornaram-se evidentes. Nesse cenário, o DCMI *Metadata Terms* foi formalmente proposto no início dos anos 2000 pela *Dublin Core Metadata Initiative* (DCMI) como uma expansão necessária para prover maior granularidade e precisão descritiva (International Conference on Dublin Core and Metadata Applications (DC), 2015). Essa evolução decorreu da emergência da Web Semântica e da consolidação do modelo *Resource Description Framework* (RDF), que demandavam vocabulários capazes de expressar relações semânticas mais complexas, refinamentos de propriedades e esquemas rígidos de codificação de dados, viabilizando o processamento automatizado e a interoperabilidade no contexto dos dados abertos e interconectados (Dublin Core Metadata Initiative, 2020).

A proposição do *DC Terms* operacionalizou-se mediante a criação de qualificadores e o acréscimo de novos termos, propriedades, classes e vocabulários que refinam os conceitos genéricos do vocabulário original (Dublin Core Metadata Initiative, 2020). Por meio de mecanismos como a subpropriedade e a definição explícita de domínios e alcances, o DC *Terms* permitiu que comunidades especificassem atributos como público-alvo, licenças, proveniência e direitos de forma rigorosa. Assim, a DCMI estabeleceu um modelo normativo expandido, viabilizando a representação detalhada de recursos digitais sem a necessidade de romper com a arquitetura conceitual e com os princípios fundacionais do projeto DC (Dublin Core Metadata Initiative, 2026).

É fundamental ressaltar, contudo, que a especificação do DC *Terms* não invalida nem substitui o conjunto original de metadados. Os 15 elementos básicos do DC continuam a constituir a espinha dorsal de todo o padrão, sendo mantidos de forma permanente pela DCMI como um padrão internacional estável (International Conference On Dublin Core And Metadata Applications (DC), 2015). Essa estrutura simplificada preserva seu papel histórico e prático de atuar como um denominador comum para a interoperabilidade global de dados, garantindo que sistemas heterogêneos e de diferentes graus de complexidade possam compartilhar e recuperar informações essenciais de maneira universal e inequívoca (Dublin Core Metadata Initiative, 2009).

As características fundamentais do DC que o distinguem de outros esquemas mais complexos são, portanto, a simplicidade, o entendimento semântico e a extensibilidade (Baptista, 2007). A simplicidade visa permitir que os próprios criadores de conteúdo possam descrever seus recursos (International Conference nn Dublin Core and Metadata Applications (DC), 2015). O entendimento semântico é alcançado por meio de um vocabulário cujos termos são intencionalmente intuitivos e independentes de domínio, promovendo a interoperabilidade semântica (Baptista, 2007). Por fim, a extensibilidade permite que o conjunto básico de elementos seja adaptado por comunidades específicas para a necessidade de representação mais detalhada (Baptista, 2007).

O núcleo do padrão DC composto por 15 elementos possui uma estrutura definida que distingue o *name*, um identificador único para processamento por máquina, por exemplo, *creator*, do *label*, um rótulo para leitura e compreensão humana, por exemplo, "Criador" (Souza; Vendrusculo; Melo, 2000). Essa dualidade é fundamental para a sua aplicação tanto em interfaces humanas quanto em sistemas automatizados de recuperação da informação (International Conference on Dublin Core and Metadata Applications (DC), 2015). O quadro 4 detalha os 15 elementos do DCMES.

Quadro 4 – Os 15 Elementos do Dublin Core Metadata Element Set (DCMES).

Nome (name)	Rótulo (label)	Definição
title	Título	Um nome dado ao recurso.
creator	Criador	Uma entidade primariamente responsável pela criação do recurso.
subject	Assunto	O tópico do recurso. A melhor prática recomenda

		o uso de um vocabulário controlado.
description	Descrição	Um relato sobre o recurso.
publisher	Editor	Uma entidade responsável por tornar o recurso disponível.
contributor	Colaborador	Uma entidade responsável por fazer contribuições ao recurso.
date	Data	Um ponto ou período de tempo associado a um evento no ciclo de vida do recurso.
type	Tipo	A natureza ou gênero do recurso. A melhor prática recomenda o uso de vocabulário controlado.
format	Formato	O formato do arquivo, meio físico ou dimensões do recurso.
identifier	Identificador	Uma referência inequívoca ao recurso dentro de um determinado contexto.
source	Fonte	Um recurso relacionado do qual o recurso descrito é derivado.
language	Idioma	Um idioma do recurso.
relation	Relação	Um recurso relacionado.
coverage	Cobertura	O tópico espacial ou temporal do recurso, a aplicabilidade espacial do recurso ou a jurisdição sob a qual o recurso é relevante.
rights	Direitos	Informações sobre os direitos detidos no, e sobre o recurso.

Fonte: Dublin Core Metadata Initiative, 2009, tradução nossa.

O MAP para LLMs personalizados proposto nesta pesquisa, o MAP-CLLM, foi estruturado a partir da combinação estratégica do LRM, do framework *Model Cards*, do DC e do vocabulário Schema.org, consolidando uma arquitetura de representação informacional híbrida (Riva; Le Bœuf; Žumer, 2020; Mitchell *et al.*, 2019). Nesta concepção metodológica, a interoperabilidade semântica é atingida pela união de vocabulários padronizados, atendendo ao propósito de um perfil de aplicação, o qual define-se rigorosamente como uma especificação que "[...] utiliza uma seleção de termos de múltiplos vocabulários de metadados, com restrições adicionais, para atender a requisitos específicos da aplicação" (Dublin Core Metadata Initiative, 2026, tradução nossa).

A opção metodológica por adotar exclusivamente os 15 elementos básicos do DC fundamenta-se na necessidade de estabelecer uma camada de descoberta ampla e genérica, atuando como um "mínimo denominador comum" para a recuperação da informação (Baptista, 2007). Essa escolha alinha-se ao conceito formal de *Simple Dublin Core*, que prescreve a elaboração de "[...] metadados sobre um único recurso, utilizando apenas as quinze propriedades do DCMES" (Dublin Core Metadata Initiative, 2026, tradução nossa). A simplicidade desse conjunto original foi um aspecto intencional em sua concepção, visando facilitar a adoção global e garantir o intercâmbio básico de dados entre sistemas heterogêneos na Web (Riley, 2017).

A validade técnica e normativa dessa abordagem é atestada pela agência mantenedora do padrão, a qual garante a perenidade do conjunto original de propriedades ao longo do tempo. Conforme estabelece a documentação do DC *Terms*, o *namespace* tradicional do DC "[...] será suportado indefinidamente" (Dublin Core Metadata Initiative, 2020, tradução nossa). Desse modo, o uso rigoroso do conjunto básico não constitui uma deficiência metodológica, mas sim o emprego de um padrão consolidado que serve perfeitamente como base interoperável sobre a qual elementos mais especializados são acoplados para descrever objetos complexos de informação (Formenton; Gracioso, 2022).

A decisão de não incorporar o *namespace* do DC *Terms*, que inclui dezenas de propriedades, classes, tipos de dados e esquemas de codificação de vocabulário, justifica-se pelo princípio fundamental de um MAP, a reutilização e refinamento de elementos e termos já estabelecidos e padronizados, e pela busca premente em produzir registros de metadados enxutos e focados, evitando redundâncias (Baca, 2016; Heery; Patel, 2000; International Conference on Dublin Core and Metadata Applications (DC), 2015). Como os requisitos deste estudo demandam a documentação de características específicas de modelos de IAG, os metadados técnicos, as métricas de testes e as considerações éticas foram extraídos de forma

mais aderente diretamente da proposta dos *Model Cards* (Mitchell *et al.*, 2019). Acrescentar as propriedades e subclasses granulares do DC *Terms* resultaria em uma sobreposição de atributos e um excesso de complexidade desnecessário para o escopo desta representação, visto que a granularidade informacional e as necessidades documentais da IAG já haviam sido asseguradas pelo mapeamento das propriedades originais da Ciência da Computação por meio dos *Model Cards*.

As restrições semânticas formais introduzidas pelo DCMI *Terms*, como a definição estrita de domínios, intervalos e esquemas de sintaxe acionáveis por máquina, foram estrategicamente substituídas e contempladas pela adoção do Schema.org como vocabulário de codificação e publicação nativo da Web (Payne, 2022). A documentação oficial do DCMI reconhece que a duplicação dos 15 elementos no *namespace /terms/* visava atender às restrições de aplicações RDF mais sofisticadas, ressaltando explicitamente que "[...] a maioria dos usuários pode tratar com segurança as quinze propriedades paralelas como equivalentes." (Dublin Core Metadata Initiative, 2020, tradução nossa). Considerando que o MAP proposto já se vale da flexibilidade do Schema.org para o processamento estruturado, considerou-se tecnicamente dispensável o uso das classes e dos esquemas de codificação complementares do DC *Terms*, mantendo assim a coerência, a simplicidade estrutural e a interoperabilidade do MAP-CLLM (Schema.org, 2025).

Portanto, o DC, com seus 15 elementos básicos, desempenha um papel indispensável como a camada fundamental do MAP proposto para LLMs personalizados. Ele fornecerá o esqueleto básico da representação, garantindo que o LLM personalizado, como recurso de informação, seja identificável, gerenciável e citável em ecossistemas de informação mais amplos. Elementos canônicos como *dc:creator*, por exemplo, a equipe que personalizou o LLM, *dc:date* como a data da versão, *dc:identifier* para um identificador único para o LLM personalizado, *dc:publisher*, sendo a instituição que o disponibiliza e *dc:rights* como a licença de uso são essenciais para a gestão do ciclo de vida do recurso (Souza; Vendrusculo; Melo, 2000). A capacidade preexistente do DC de descrever recursos do tipo software por meio do elemento *dc:type* e vocabulários controlados reforça sua pertinência como ponto de partida para a descrição de objetos tecnológicos (International Conference on Dublin Core and Metadata Applications (Dc), 2015). Dessa forma, o uso do DC o posiciona estrategicamente como a base interoperável sobre a qual elementos mais especializados, provenientes de outros vocabulários, como Schema.org, e de constructos emergentes como os *Model Cards*, serão integrados para formar um perfil de aplicação de metadados coeso e funcional para LLMs personalizados.

O que observa-se é uma notável relação entre os *Model Cards* articulando os requisitos informacionais necessários para a governança de LLMs personalizando, e a metodologia MAP, oriunda da CI, oferecendo a solução estrutural e semântica para atender a esses requisitos de forma padronizada e interoperável. Enquanto os *Model Cards* propõem o que deve ser documentado, um MAP fornece como essa documentação pode ser estruturada de forma legível por máquina, fundamentada em princípios de organização da informação e conectada a vocabulários semânticos da Web e padrões de metadados como o DC.

5.4 O vocabulário Schema.org

Enquanto padrões como o DC estabeleceram os princípios da descrição de recursos interoperáveis, a paisagem informacional contemporânea, dominada por ecossistemas web dinâmicos e agentes computacionais, exige vocabulários nativos deste ambiente (A; Taj; Nair, 2025). A seleção de um vocabulário de metadados amplamente adotado é uma decisão fundacional na construção de qualquer MAP, neste contexto, a iniciativa Schema.org emerge não como um substituto, mas como uma evolução pragmática dos princípios de metadados, projetada especificamente para a escala e as demandas da Web semântica moderna (International Conference on Dublin Core and Metadata Applications (DC), 2015). A sua escolha como vocabulário base para o MAP proposto nesta tese é, portanto, uma decisão metodológica deliberada, fundamentada em sua origem, arquitetura e comprovada extensibilidade.

Lançado em 2011 por uma colaboração entre os principais motores de busca, Google, Microsoft, Yahoo e Yandex, o Schema.org foi concebido com um propósito eminentemente prático de criação de um vocabulário único e compartilhado que permitisse aos seus algoritmos de rastreamento compreender de forma mais eficaz o significado do conteúdo das páginas web (Patel-Schneider, 2014). O objetivo não era apenas indexar texto, mas interpretar entidades, suas propriedades e relações, a fim de aprimorar a experiência de busca do usuário com resultados mais ricos e contextualmente relevantes (Schema.org, 2025). Esta gênese, impulsionada pela indústria, marca uma distinção estrutural em relação a padrões como o DC, orientando o Schema.org para uma função primariamente computacional, onde os metadados servem como dados para os algoritmos e não apenas como dados sobre dados para a descoberta mediada por humanos.

A arquitetura do Schema.org é caracterizada por um modelo de dados hierárquico e extensível, com o tipo genérico *schema:Thing* no topo da hierarquia (Schema.org, 2025). Tipos mais específicos, como *schema:CreativeWork, schema:Person* e *schema:Service*, herdam

propriedades de seus pais, criando uma ontologia rica e logicamente consistente (Schema.org, 2025). Uma decisão de design fundamental que garante sua flexibilidade é o polimorfismo, que permite que uma propriedade tenha múltiplos tipos esperados em seu domínio e alcance, por exemplo, a propriedade *author* pode ser uma *Person* ou uma *Organization* (Guha; Brickley; Macbeth, 2016). Essa abordagem pragmática, que prioriza a facilidade de implementação em detrimento da rigidez ontológica formal, reduziu significativamente as barreiras à adoção e foi um fator chave para sua utilização em mais de 45 milhões de domínios web (Payne, 2022). Para um cenário emergente e em rápida evolução como o dos LLMs, esta flexibilidade é um atributo indispensável.

A adequação do Schema.org para esta pesquisa é ainda mais evidenciada por sua comprovada capacidade de adaptação a contextos especializados e de alta complexidade, por exemplo, iniciativas como a Bioschemas demonstram como a comunidade das ciências da vida estende e refina o vocabulário do Schema.org para descrever com a granularidade necessária recursos biológicos, como conjuntos de dados e amostras biológicas (Cano *et al*., 2023). A Bioschemas cria perfis sobre tipos existentes do Schema.org, especificando recomendações de uso, cardinalidade e vocabulários controlados, um modelo metodológico diretamente análogo à proposta desta tese. Similarmente, o projeto Science on Schema.org fornece diretrizes para a descrição de conjuntos de dados científicos, alinhando a marcação de metadados aos princípios *Findable, Accessible, Interoperable, and Reusable* (FAIR) e facilitando a descoberta de dados por ferramentas como o Google Dataset Search (Payne, 2022). Esses precedentes ilustram o uso do Schema.org como base consolidada para a criação de perfis de aplicação de metadados em cenários que exigem confiabilidade e transparência.

Como descrito na seção correspondente, um *Model Card* é um documento que promove a transparência do processo de personalização de um LLM (Mitchell *et al*., 2019). Ele define os requisitos informacionais para uma descrição confiável de um LLM personalizado, contudo, um *Model Card* é, em sua essência, uma técnica conceitual, um documento legível por humanos e flexível no seu uso prático, não sendo por si só interoperável ou processável por máquinas em escala web. É precisamente nesta intersecção que a contribuição desta tese se manifesta. O MAP proposto visa traduzir os imperativos éticos e informacionais do *Model Card* em uma especificação técnica, formal e legível por máquina. Ao fazê-lo, a pesquisa transforma o conceito de documentação de LLMs personalizados de um relatório estático para um conjunto de dados dinâmico e interoperável, tornando os objetivos de transparência e responsabilidade computacionalmente acionáveis dentro do ecossistema da web.

A viabilidade desta proposta é sustentada pela adequação do vocabulário do Schema.org para descrever as múltiplas facetas de um LLM personalizado. Um LLM pode ser conceitualizado simultaneamente como diferentes tipos de entidades. Como um artefato de software, pode ser descrito pelo tipo *schema:SoftwareApplication*. Como um serviço acessível via *Application Programming Interface* (API), um conjunto de regras e protocolos que permite que diferentes softwares se comuniquem, troquem dados e compartilhem funcionalidades, como é o caso dos Gemini Gems, os tipos *schema:Service* e seu subtipo *schema:WebAPI* são possíveis aplicações (Schema.org, 2025). Como uma obra intelectual, com autores, versão e licença, o tipo *schema:CreativeWork* oferece as propriedades necessárias (Schema.org, 2025). E, principalmente, para descrever um dos componentes mais importantes para a avaliação de sua confiabilidade, os dados ou documentos usados na personalização do LLM, o tipo *schema:Dataset* pode fornecer um esquema detalhado (Schema.org, 2025).

Esta correspondência permite um mapeamento direto entre os componentes conceituais de um *Model Card* e os elementos existentes no Schema.org. Os detalhes do LLM personalizado podem ser representados por propriedades como *schema:version* e *schema:author* dentro de um tipo como *schema:SoftwareApplication*. O uso pretendido pode ser descrito com *schema:serviceType* e *schema:audience*. Os dados de avaliação podem ser descritos usando o tipo *schema:Dataset*, com a propriedade *schema:distribution* apontando para o conjunto de dados real. As limitações e vieses, embora não possuam uma propriedade dedicada, podem ser articuladas de forma transparente através da propriedade textual *schema:comment*, cumprindo um requisito central dos *Model Cards.*

Desta forma, a decisão de utilizar o Schema.org no MAP para LLMs personalizados não se resume apenas à conveniência técnica, mas representa uma escolha estratégica. Primeiramente, sua natureza nativa da web garante que as descrições produzidas sejam imediatamente úteis no ecossistema de busca e descoberta existente (Payne, 2022). Em segundo lugar, sua ampla adoção promove a interoperabilidade, evitando a criação de mais um silo de dados e, em vez disso, conectando a descrição do LLM personalizado ao grafo de conhecimento global (Wu *et al*., 2023).

Finalmente, o Schema.org é um vocabulário vivo, mantido ativamente e com um processo de extensão comunitária (Schema.org, 2025). À medida que a IA se torna mais integrada à web, é provável que o próprio Schema.org evolua para incluir termos mais específicos para descrever LLMs (Dang *et al*., 2024). Ao construir sobre esta fundação, o MAP proposto nesta tese não apenas se beneficia do padrão atual, mas também se posiciona para incorporar futuros desenvolvimentos, garantindo sua relevância e longevidade. A pesquisa,

portanto, não apenas utiliza o Schema.org, mas também contribui para o seu ecossistema, prototipando um perfil de aplicação de metadados que pode, eventualmente, informar a evolução do próprio padrão para o contexto da IA.

5.5 Perfil de Aplicação de Metadados

Este estudo propõe a implementação de um Perfil de Aplicação de Metadados (*Metadata Application Profile* - MAP) com o intuito de viabilizar a representação e interoperabilidade de LLMs personalizados. Nesta seção, serão apresentados os princípios fundamentais e a abordagem metodológica para o desenvolvimento de um MAP, estabelecendo, assim, a estrutura teórica que subsidiará a aplicação prática a ser detalhada em seções subsequentes desta pesquisa.

Um MAP pode ser entendido como um arranjo de metadados, o qual é construído a partir de elementos de dados provenientes de um ou múltiplos esquemas, ou *namespaces*, previamente existentes. Tais elementos são então combinados e otimizados para atender às demandas de uma aplicação ou comunidade específica (International Conference on Dublin Core and Metadata Applications (DC), 2015; Heery; Patel, 2000). Outro ponto fundamental associado a um MAP é a sua característica de não instituir novos elementos de metadados de forma precipitada. Em vez disso, ele fomenta a reusabilidade, mediante a seleção de propriedades extraídas de vocabulários já consolidados. Adicionalmente, quando a necessidade se impõe, promove o refinamento de suas definições ou das diretrizes de uso, visando à conformidade com os requisitos contextuais (Barker; Campbell, 2010; Malta, 2014).

A consecução da interoperabilidade constitui o objetivo primordial de um MAP e, para isso, necessita explicitar os termos empregados, vocabulário proveniente e as diretrizes para sua aplicação, por exemplo, a obrigatoriedade de um elemento ou a restrição de seus valores a listas controladas. Configurando-se como um instrumento contratual, um MAP viabiliza a partilha e a inteligibilidade consistentes de metadados entre sistemas, bem como entre criadores e consumidores de informação, uma vez que todos se submetem a um conjunto uniforme de regras e definições (Nilsson; Baker; Johnston, 2008). Isso implica que a especificação de um LLM personalizado poderia ser interpretada e processada por um repositório institucional ou por um inventário de modelos de IAs, independentemente da autonomia de desenvolvimento desses LLMs.

O processo de desenvolvimento de um MAP é pautado em uma metodologia que visa assegurar sua robustez estrutural e sua adequação funcional na determinação dos metadados. Nesse contexto, o *Singapore Framework for Dublin Core Application Profiles* emerge como

uma das abordagens metodológicas de referência mais influentes, fornecendo diretrizes essenciais para a condução desse processo (Nilsson; Baker; Johnston, 2008). Embora sua concepção original estivesse diretamente ligada a perfis fundamentados no DC, seus princípios fundamentais demonstram uma ampla aplicabilidade, estendendo-se ao desenvolvimento de qualquer MAP. Entretanto, a ausência de uma metodologia estruturada na criação de um MAP pode levar a resultados de baixa qualidade, como comunicação ambígua, desenhos frágeis e documentação insuficiente, comprometendo o objetivo final da interoperabilidade, por isso, a adoção de metodologias formais oriundas do ciclo de vida do desenvolvimento de softwares, por exemplo, o Me4MAP proposto por Malta (2017), aumenta a previsibilidade, a qualidade e a manutenção de um MAP (Malta; Baptista; Walk, 2017). Esta abordagem sistemática proposta pelo MAP demonstra o amadurecimento do campo da determinação de metadados ao adotar as melhores práticas de disciplinas estabelecidas, como a engenharia de software, para gerir a crescente complexidade do ecossistema de dados (Malta, 2017).

As fases que compõem o processo de desenvolvimento de um MAP, segundo as abordagens do *Singapore Framework for Dublin Core Application Profiles* e Me4MAP podem ser sintetizadas conforme a descrição apresentada no quadro 5, evidenciando a sistematicidade característico de sua execução.

Quadro 5 – Processo de Desenvolvimento de um Perfil de Aplicação.

Fase	Atividades Principais	Entradas (*Inputs*)	Resultados (*Outputs*)
1. Análise	- Identificar entidades, conceitos e terminologia. - Levantamento de Requisitos Funcionais (o que os metadados precisam permitir que os usuários façam).	- Documentação do domínio (p. ex., documentação técnica do Google AI Studio). - Literatura sobre o tema (p. ex., artigos sobre IA Confiável). - Padrões e boas práticas existentes (p. ex., *Model Cards*).	- Glossário de termos do domínio. - Lista de requisitos funcionais priorizados.
2. Modelagem	- Criação de um Modelo Relacional que representa as principais entidades e seus relacionamentos.	- Resultados da Fase 1 (glossário, requisitos). - Modelos conceituais de referência (p. ex., LRM).	- Diagrama do Modelo. - Descrição das entidades e relacionamentos.

3. Especificação	- Seleção de termos de namespaces de metadados existentes (p. ex., DC e Schema.org. - Definição de termos locais (se estritamente necessário, p. ex., *Model Cards*). - Especificação de restrições (obrigatoriedade, cardinalidade, vocabulários controlados).	- Resultados da Fase 2 (Modelo Relacional). - Esquemas de metadados existentes (p. ex., DC, Schema.org e *Model Cards*).	- Esboço do *Description Set Profile* (DSP). - Mapeamento entre o Modelo Relacional e os termos do DSP.
4. Formalização e Documentação	- Codificação do perfil em uma sintaxe legível por máquina (p. ex., JSON). - Criação de diretrizes de uso e documentação para implementadores e usuários.	- Resultados da Fase 3 (esboço do DSP).	- Perfil de Aplicação formalizado. - Documentação e guias de preenchimento.

Fonte: elaboração do autor com base em Nilsson, Baker e Johnston (2008) e Malta (2017).

A Fase 1 - Análise, define os Requisitos Funcionais, portanto, mandatório no processo, pois, é o ponto de partida essencial, visto que o propósito de qualquer metadado é suportar uma atividade (Dublin Core Metadata Initiative, 2009). Esta fase visa responder à pergunta: "O que queremos alcançar com estes metadados?" (Dublin Core Metadata Initiative, 2009, tradução nossa). O processo pode envolver a consulta de todas as partes interessadas, por exemplo, gestores, especialistas, desenvolvedores e utilizadores finais, para definir os objetivos e os limites da aplicação. As questões a serem respondidas incluem (Dublin Core Metadata Initiative, 2009):

- Quais tarefas os utilizadores devem ser capazes de realizar? Por exemplo, encontrar, identificar, selecionar e obter?
- A aplicação necessita de funcionalidades específicas, como ordenação por data ou filtragem por tipo de recurso?
- Quais são as características dos recursos a serem descritos e dos utilizadores a serem servidos?

Por exemplo, os requisitos funcionais do *Scholarly Works Application Profile* (SWAP), desenhado para descrever artigos científicos, incluem "facilitar a identificação de materiais de acesso aberto" e "permitir a identificação do financiador da pesquisa e do código do projeto" (Allinson *et al*., 2007, tradução nossa).

Na Fase 2 - Modelagem, ocorre o desenvolvimento do Modelo Relacional, também considerado mandatório, pois, com os requisitos definidos, o passo seguinte é modelar o cenário informacional. Um Modelo Relacional caracteriza as "coisas" (entidades) que os metadados irão descrever e as relações fundamentais entre elas (Nilsson; Baker; Johnston, 2008; Dublin Core Metadata Initiative, 2009). Este modelo serve como o projeto conceitual para o MAP. A sua complexidade pode variar significativamente. Para uma aplicação simples como o MyBookCase, que descreve livros e autores, o modelo pode consistir apenas em duas entidades: Livro e Pessoa (Dublin Core Metadata Initiative, 2009). Em contraste, o SWAP baseia-se num modelo conceitual da comunidade biblioteconômica, o FRBR, e define um conjunto mais rico de entidades para representar a obra, a expressão, a manifestação e um item (Allinson *et al*., 2007).

A fase 2, portanto, representa uma etapa essencial no processo, uma vez que estabelece uma descrição abstrata dos elementos que os metadados se propõem a descrever, bem como das interconexões existentes entre eles. Essa etapa atua como uma base conceitual fundamental para o desenvolvimento subsequente do perfil (Riva; Le Bœuf; Žumer, 2020). A culminância da fase de especificação materializa-se no *Description Set Profile* (DSP), um artefato documental que formaliza todas as deliberações adotadas, pormenorizando cada propriedade, sua procedência, sua definição e os princípios reguladores de sua aplicação (Nilsson; Baker; Johnston, 2008).

Na Fase 3 - Especificação, é possível selecionar e especificar termos de metadados, constituindo-se a fase que foca na seleção de propriedades de vocabulários existentes e bem estabelecidos para descrever as entidades do modelo relacional. A reutilização de termos de vocabulários é fortemente encorajada, pois maximiza a interoperabilidade semântica (Dublin Core Metadata Initiative, 2009; Allinson *et al*., 2007). Para cada propriedade selecionada, é necessário tomar decisões técnicas detalhadas e documentá-las, tais como (Dublin Core Metadata Initiative, 2009):

- Tipo de Valor: O valor da propriedade será um literal (uma cadeia de caracteres) ou um não-literal (um URI que aponta para outra descrição ou conceito)? Por exemplo, dcterms:title geralmente tem um valor literal, enquanto dcterms:creator pode apontar para a descrição de uma pessoa.

- Esquemas de Codificação: O valor literal deve seguir um formato específico (esquema de codificação de sintaxe), como o W3CDTF para datas (YYYY-MM-DD)? O valor deve ser selecionado de uma lista controlada (esquema de codificação de vocabulário), como os códigos de idioma da norma ISO 639-3?

Na Fase 4 - Formalização e Documentação, ocorre o desenho do *Description Set Profile* (DSP), ou Perfil de Conjunto de Descrições, considerado mandatório, pois, é a formalização técnica e processável por máquina do MAP. O DSP traduz as decisões das fases anteriores numa série de restrições que os registos de metadados devem cumprir (Dublin Core Metadata Initiative, 2009; Nilsson; Baker; Johnston, 2008). Para cada entidade do modelo relacional, é definido um template de descrição (*description template*). Dentro de cada template, são especificados os templates de declaração (*statement templates*) para cada propriedade, juntamente com as suas restrições (Dublin Core Metadata Initiative, 2009; Nilsson; Baker; Johnston, 2008):

- Cardinalidade: Define se uma propriedade é obrigatória (ocorrência mínima ≥1) e se é repetível (ocorrência máxima >1). Por exemplo, um livro deve ter exatamente um título (minOccurs=1, maxOccurs=1), mas pode ter múltiplos autores (minOccurs=1, maxOccurs=unbounded).
- Restrições de Valor: Especifica os tipos de valores permitidos, como a obrigação de usar um URI de um vocabulário controlado específico ou de seguir um tipo de dado particular.

O DSP é a espinha dorsal que permite a validação automática dos dados, garantindo a sua consistência e conformidade com o perfil. Por fim, pode ocorrer a elaboração de guias de utilização e de sintaxe, ou seja, enquanto o DSP representa o "o quê" do MAP, as guias de utilização explicam o "como" e o "porquê" para os criadores de metadados humanos (Dublin Core Metadata Initiative, 2009). Estes documentos fornecem instruções em linguagem natural, exemplos de preenchimento, e clarificam regras de descrição para garantir a consistência na criação dos dados. As guias de sintaxe, por sua vez, especificam como os metadados devem ser codificados em formatos de máquina, por exemplo, JSON, para garantir que possam ser processados por softwares (Dublin Core Metadata Initiative, 2009). Embora opcionais segundo o *Singapore Framework*, ambas as guias são altamente recomendadas para a implementação bem-sucedida de um MAP.

A necessidade de um MAP destaca-se pela proliferação de dados no ambiente digital, acentuando a necessidade crítica de interoperabilidade, a capacidade de sistemas distintos trocarem e utilizarem informações de forma eficaz (Cardoso, 2020). Padrões de metadados

genéricos, como o DC, são fundamentais para estabelecer uma base comum de descrição (Dublin Core Metadata Initiative, 2009). No entanto, é raro que um único padrão, em sua configuração nativa ou padronizada, consiga satisfazer todos os requisitos de uma comunidade ou aplicação específica (Baker, 2001). Cenários como a saúde, a preservação digital e a gestão de dados de pesquisa exigem um nível de detalhe e especificidade que excede os vocabulários de propósito geral (Cardoso, 2020).

É neste contexto que um MAP se torna indispensável funcionando como ponte entre diversos ambientes digitais. Ao documentar e formalizar como uma comunidade de prática utiliza, combina e restringe os padrões existentes, um MAP promove a harmonização das práticas de metadados (Baker, 2001). Quando os implementadores declaram os seus perfis de aplicação de metadados, permitem que outros compreendam as suas regras de descrição, facilitando a partilha, a agregação e a reutilização de dados (Heery; Patel, 2000). Esta declaração explícita é o que permite alcançar níveis mais elevados de interoperabilidade, particularmente a interoperabilidade semântica.

A interoperabilidade semântica vai além da simples compatibilidade de formatos de dados, ela exige que diferentes sistemas partilhem uma compreensão comum do significado dos dados (Dublin Core Metadata Initiative, 2008). Isto é alcançado através do uso preciso da semântica formal incorporada em tecnologias como o Schema.org onde as relações entre os termos são formalmente estabelecidas, permitindo que agentes de software façam inferências automáticas (Dublin Core Metadata Initiative, 2008). O MAP é a operacionalização deste conceito, sendo possível, para esta pesquisa, compará-lo a um contrato semântico que é simultaneamente legível por humanos e processável por máquinas.

O MAP possui dois componentes essenciais, sendo a primeira, legível por humanos, por exemplo, as guias de utilização, que explicam as regras, intenções e fornecem exemplos para a descrição do objeto pelos profissionais (Nilsson; Baker; Johnston, 2008; Dublin Core Metadata Initiative, 2009). A segunda, processável por máquinas, é o DSP, que define as restrições formais sobre os dados, permitindo a sua validação automática (Nilsson; Baker; Johnston, 2008). Quando uma comunidade de prática adota um MAP, os seus membros estão, na prática, concordando com os termos de um contrato semântico. Esta concordância é o que permite que os dados publicados sob este perfil sejam "processados automaticamente por agentes de software" (Malta, 2017, tradução nossa), viabilizando a automação e a escala necessárias para a Web de Dados. Sem estes contratos formais, a interoperabilidade permanece num nível superficial, dependente de mapeamentos manuais. Assim, após este estudo sobre

MAP, apresenta-se na próxima seção a aplicação do MAP para o contexto de LLMs personalizados.

6 PROPOSTA DE PERFIL DE APLICAÇÃO DE METADADOS PARA LLMS PERSONALIZADOS

Esta seção dedica-se à concretização da metodologia previamente delineada, aplicando-a especificamente ao processo de personalização de LLMs. O desfecho desta aplicação metodológica é a proposição de um MAP, denominado MAP-CLLM (*Metadata Application Profile for Custom Large Language Models*), cuja estruturação se materializa por meio da definição criteriosa de requisitos funcionais, da elaboração de um modelo relacional apropriado e da construção de um DSP. Tais elementos são determinantes para a organização e interoperabilidade dos metadados no contexto dos LLMs personalizados, assegurando uma gestão informacional padronizada.

A construção do MAP-CLLM adota a arquitetura lógica fornecida pelo *Singapore Framework* para organizar os níveis de abstração do perfil. Contudo, a definição das restrições de valor, cardinalidade e obrigatoriedade apresentadas no DSP é orientada pelo método Me4MAP. Esta articulação metodológica permite que o perfil se estabeleça para além de uma listagem fundamental de elementos, constituindo-se como um instrumento de formalização semântica tecnicamente consistente, apto a subsidiar a interoperabilidade e a auditabilidade de metadados em ecossistemas de IA.

Com base na Análise Documental das interfaces e documentações técnicas das ferramentas Google AI Studio e Gemini Gem, e fundamentado no modelo conceitual LRM, a determinação da lista de metadados deste MAP foi influenciada pelos 15 elementos básicos do DC e pela proposta dos *Model Cards*, refletindo a dualidade denominada nesta pesquisa como técnico-configuracional e semântico-instrucional identificada. O Schema.org foi usado para mapear os elementos do DC e *Model Cards* para seus termos, garantindo que os metadados de um LLM personalizado sejam compreendidos globalmente e referenciados corretamente em ambientes Web. O Schema.org caracteriza-se como um vocabulário nativo deste ambiente, projetado especificamente para a escala e as demandas da Web semântica moderna, por isso, assume uma função primariamente computacional, onde os metadados servem como dados para os algoritmos e não apenas como dados sobre dados para a descoberta mediada por humanos. Deste modo, os principais motores de busca, Google, Microsoft, Yahoo e Yandex, foram projetados para compreender este vocabulário.

Portanto, o DC é a estrutura do MAP-CLLM fundamentada no LRM apresentando um conjunto mínimo de metadados para representar um LLM personalizado como um objeto informacional complexo, garantindo identificação e descoberta mínima; os *Model Cards* e a

documentação das ferramentas Google AI Studio e Gemini Gem contribuíram para a determinação de metadados específico e seus possíveis valores, além das questões éticas; e o Schema.org atua como um vocabulário de publicação legível na Web fornecendo os termos apropriados para este cenário, o que complementa os padrões anteriores.

Como parte da metodologia implementada nesta pesquisa, a revisão de literatura realizada permitiu mapear o que consideram-se sobre determinação de metadados. Deste modo, antes de apresentar o MAP-CLLM completo proposto, é apropriada uma breve recapitulação sobre metadados e determinação de metadados, incluindo uma sintetização das orientações dos autores estudados e a indicação das usadas nesta fase da pesquisa. O propósito é apresentar um conjunto de conceitos, princípios e modelos teóricos que servem como alicerce para esta pesquisa, retirados das pesquisas dos autores citados como referências.

Para determinar uma lista de metadados de um LLM personalizado, esta pesquisa buscou primeiramente alcançar um entendimento geral dos termos usados neste contexto, orientação destacada por Ulrich *et al*. (2020, p. 2). Embora tenha optado por usar o ecossistema Google como exemplo tecnológico no processo de personalização de um LLM, a revisão de literatura permitiu concluir que, embora alguns termos possam ser diferentes, a literatura confirma que se trata da mesma configuração presente em outras ferramentas. Por exemplo, no Google AI Studio o termo “Model” se refere ao mesmo tipo de configuração usado na ferramenta OutSystems AI Agent Builder quando usa o termo “AI Model”, e o termo “System Instructions” no Google AI Studio é apenas “Instructions” no OutSystems AI Agent Builder (Google, 2025b; Outsystems, 2024).

Lembrando que a proposta dos *Model Cards* permite certa flexibilidade ao determinar a lista final de metadados, priorizar a identificação e determinação de um conjunto genérico de metadados é baseado na orientação de mais de um autor. Por exemplo, os autores Liu; Fu; Liu (2023, p. 291) destacam que não é simples fornecer uma descrição detalhada de um objeto de informação devido a vários fatores que precisam ser considerados e equilibrados, por isso, é necessário valorizar a análise humana conhecedora do domínio. Também exemplificando a necessidade de identificar um conjunto genérico de recursos comuns e a importância da simplicidade nessa tarefa, Riley (2017, p. 23) lembra que “os participantes [que trabalharam na definição dos elementos do DC] foram encarregados de identificar um conjunto básico de recursos comuns à maioria dos tipos de informação digital” e que “a simplicidade do DC foi intencional” (Riley, 2017, p. 23, tradução nossa). O exemplo do desenvolvimento do DC também é citado por Baca (2016) para destacar a priorização em identificar um conjunto

genérico de elementos de metadados que poderiam ser usados por qualquer comunidade, especialista ou não especialista.

Sobre a interoperabilidade dos metadados, o MAP proposto reflete a afirmação de Riley (2017, tradução nossa) de que a determinação de um conjunto de metadados realizada por indivíduos ou instituições precisa atender a determinadas necessidades da comunidade envolvida e depois publicados para que as partes interessadas possam consultar, permitindo que diferentes sistemas trabalhem juntos compartilhando informações sem desconsiderar os aspectos semânticos, estruturais e sintáticos (Baca, 2016, tradução nossa).

Todas as orientações dos autores sobre determinação de metadados sintetizados aqui, bem como o estudo do processo de desenvolvimento de um MAP, fazem parte da teoria de base desta tese, formando o conjunto de conceitos, princípios e modelos teóricos que auxiliaram neste estudo. A metodologia fundamentada em revisão de literatura e análise documental situou este estudo em um contexto científico mais amplo, ligando-o a pesquisas e descobertas já realizadas e resultando na proposta de um MAP para LLMs personalizados. A seguir, iniciando pelos requisitos funcionais, o MAP-CLLM é apresentado.

6.1 Requisitos Funcionais

O objetivo deste MAP é padronizar a representação, descoberta e gestão de LLMs personalizados. O perfil integra elementos do DC, *Model Cards* e propriedades do Schema.org, estruturados sob o modelo conceitual LRM.

Os seguintes requisitos funcionais orientaram a determinação dos metadados e a estrutura do MAP-CLLM, visando atender às necessidades de desenvolvedores, curadores de informação e usuários finais de LLMs personalizados:

- R1 (Descoberta): O perfil deve permitir que usuários localizem e selecionem um LLM personalizado utilizando critérios de busca como: propósito da aplicação, identidade do criador, modelo de base utilizado (p. ex.: Gemini 3 Pro) e domínio de conhecimento (p. ex.: Nutrição).
- R2 (Avaliação de Confiança e Risco): O perfil deve fornecer metadados suficientes para que o usuário avalie a adequação ética e técnica do LLM personalizado, incluindo limitações, níveis de segurança, testes realizados e áreas fora de escopo.
- R3 (Compreensão e Reprodutibilidade): O perfil deve registrar de forma detalhada o processo de personalização do LLM, especificamente as instruções de sistema e parâmetros técnicos, permitindo a compreensão do seu comportamento e sua potencial reprodutibilidade.

- R4 (Interoperabilidade e Governança): O perfil deve utilizar vocabulários padronizados e amplamente aceitos na Web Semântica, primariamente Schema.org, para permitir a agregação de metadados em repositórios institucionais e mecanismos de busca globais.

Estes requisitos funcionais estabelecidos para a estruturação do MAP-CLLM encontram-se fundamentados na interseção entre o LRM e os princípios FAIR. Essa abordagem visa superar os limites das documentações puramente técnicas, integrando a descrição de metadados de IAG tanto às tarefas essenciais de informação dos usuários finais quanto à capacidade de processamento semântico automatizado por máquinas (Oliveira; Castro; Jesus, 2021; Riva; Le Bœuf; Žumer, 2020; Vidotti; Torino; Coneglian, 2021). Conforme postulado nas diretrizes do consórcio Go Fair (2026, tradução nossa), "[…] os princípios referem-se a três tipos de entidades: dados (ou qualquer objeto digital), metadados (informações sobre esse objeto digital) e infraestrutura." Essa conceituação embasa a modelagem unificada do MAP-CLLM sob o amparo da CI, na qual os metadados atuam como a camada interpretativa que viabiliza a transparência e confiança.

O **R1 (Descoberta)** é sustentado metodologicamente pelo princípio *Findable* (Localizável) do FAIR e pela tarefa do usuário Encontrar do LRM (Riva; Le Bœuf; Žumer, 2020; Vidotti; Torino; Coneglian, 2021). Sob as diretrizes do FAIR, para que um objeto digital seja efetivamente descoberto, ele deve possuir um identificador global persistente, ser documentado por metadados ricos e estar registrado em recursos de busca indexados (Go Fair, 2026; Vidotti; Torino; Coneglian, 2021). Essa premissa de localização em rede é operacionalizada por meio da tarefa Encontrar no LRM, que orienta o sistema de informação a propiciar pesquisas eficazes de recursos de interesse a partir de atributos estruturados e caminhos relacionais (Riva; Le Bœuf; Žumer, 2020). Desse modo, o MAP-CLLM herda essa fundamentação ao associar metadados de identificação da entidade Expressão, como título, criador e assunto, permitindo que o LLM personalizado seja facilmente recuperado em repositórios digitais.

A justificação do **R2 (Avaliação de Confiança e Risco)** apoia-se diretamente no princípio *Reusable* (Reutilizável) do FAIR e nas tarefas Identificar e Selecionar preconizadas pelo LRM (Riva; Le Bœuf; Žumer, 2020; Vidotti; Torino; Coneglian, 2021). Seguindo o Go Fair (2026), a reutilização de dados e modelos de IAG de forma confiável requer metadados descritos de maneira rica e contextualizada, acompanhados de licenças claras de uso e proveniência detalhada (Vidotti; Torino; Coneglian, 2021). Esse objetivo ético-técnico é concretizado pelas tarefas do LRM Identificar e Selecionar, onde a tarefa Identificar assegura

que o usuário compreenda a natureza do recurso encontrado, distinguindo-o de instâncias semelhantes, e a tarefa Selecionar instrumentaliza os julgamentos de relevância, permitindo que o usuário determine a adequação do conteúdo e aceite ou rejeite o recurso com base nas restrições de público-alvo ou licenças documentadas (Riva; Le Bœuf; Žumer, 2020). O MAP-CLLM consolida essa articulação ao propor metadados específicos para documentar as considerações éticas dos *Model Cards*, tais como as áreas fora de escopo, níveis de filtros de segurança e relatórios de testes de segurança, convertendo a explicabilidade em um processo contextual legível por humanos e validável por máquinas.

O **R3 (Compreensão e Reprodutibilidade)** encontra sustentação no princípio *Reusable* (Reutilizável) e na tarefa Explorar estabelecida pelo LRM (Riva; Le Bœuf; Žumer, 2020; Vidotti; Torino; Coneglian, 2021). A reprodutibilidade algorítmica constitui um dos pilares da IA confiável e depende da fidedignidade da proveniência do recurso descrita em metadados. Com efeito, o foco fundamental no processamento por agentes automatizados é destacado por Wilkinson *et al.* (2016, citado por Vidotti; Torino; Coneglian, 2021, p. 211), ao asseverarem que "[...] os Princípios FAIR enfatizam especificamente o aprimoramento da capacidade das máquinas de encontrar e usar os dados automaticamente, além de apoiar sua reutilização por indivíduos." No MAP-CLLM, a tarefa Explorar é empregada metodologicamente para estruturar os relacionamentos hierárquicos e as dependências funcionais entre as entidades Obra, Expressão, Manifestação e Item, permitindo que atores naveguem de forma contextual pela genealogia técnica do modelo para compreender e reproduzir com precisão o comportamento desejado do LLM personalizado (Oliveira; Castro; Jesus, 2021; Riva; Le Bœuf; Žumer, 2020).

Por fim, o **R4 (Interoperabilidade e Governança)** fundamenta-se nos princípios *Interoperable* (Interoperável) e *Accessible* (Acessível) do FAIR, bem como na abordagem conceitual e lógica do LRM (Riva; Le Bœuf; Žumer, 2020; Vidotti; Torino; Coneglian, 2021). Os princípios do FAIR preconizam o emprego de linguagens de representação do conhecimento que sejam formais, compartilhadas e aplicáveis de maneira genérica, utilizando vocabulários controlados que sigam os próprios princípios do FAIR para minimizar silos informacionais (Go Fair, 2026; Vidotti; Torino; Coneglian, 2021). De forma correspondente, o modelo LRM foi projetado a partir de uma modelagem de alto nível compatível com os princípios da Web Semântica, prevendo a concretização de propriedades e a representação de atributos por meio de URIs (Oliveira; Castro; Jesus, 2021; Riva; Le Bœuf; Žumer, 2020). Essa premissa teórica traduz-se no MAP-CLLM por meio do mapeamento e da codificação sistemática de seus metadados para o vocabulário Schema.org, sugerindo a sintaxe JSON-LD, assegurando que o

registro de metadados atue como um contrato semântico de governança de dados passível de ser colhido e interpretado de forma descentralizada e confiável na web.

Prosseguindo com a construção do MAP proposto, após a definição dos requisitos funcionais indicando o que os metadados precisam permitir que os usuários façam, a próxima etapa do processo de desenvolvimento do MAP-CLLM é a definição do modelo relacional representando as entidades e seus relacionamentos.

6.2 Modelo Relacional

Para a modelagem deste MAP adotou-se o modelo conceitual LRM, adaptado para o contexto de IAG, especificamente para LLMs personalizados. Essa abordagem conceitual permite delimitar o escopo de representação do MAP-CLLM, esclarecendo que o MAP proposto não representa o processo opaco de tokenização em si, que pertence à dimensão da computação interna do modelo, mas sim a totalidade do LLM personalizado enquanto objeto informacional complexo. Dessa forma, o MAP-CLLM abrange desde a infraestrutura do modelo fundacional e as regras instrucionais de personalização até a aplicação disponibilizada, contemplando a interação dos usuários e os resultados gerados por meio do registro de identificadores auditáveis. A seguir, apresenta-se a descrição textual das entidades e seus relacionamentos:

- **Obra (LRM-E2):** Representa o modelo de base.
  - *Relacionamento:* Uma única **Obra** é realizada através de uma ou mais **Expressões** (1:N).
  - *Mapeamento Schema.org:* schema:Product
  - *Justificativa:* Um modelo de base, produto comercial tangível, com marca, fabricante, versão e documentação (p. ex: Gemini 3 Pro) pode servir de fundação para dezenas de personalizações diferentes.
- **Expressão (LRM-E3)**: Representa a personalização do LLM.
  - *Relacionamento:* Uma **Expressão** realiza uma única **Obra** (N:1). Uma **Expressão** é materializada em uma ou mais **Manifestações** (1:N).
  - *Mapeamento Schema.org:* schema:SoftwareSourceCode
  - *Justificativa:* A personalização é feita através de *prompts* e configurações. Na era da IA, *prompt* é considerado código. O processo de personalização constitui uma criação intelectual original e autoral do ator responsável (p. ex. Cientista da Informação) que define o comportamento do LLM.

- **Manifestação (LRM-E4):** Representa a instância técnica acessível.
  - *Relacionamento:* Uma **Manifestação** materializa uma única **Expressão** (N:1). Uma **Manifestação** é exemplificada por um ou mais **Itens** (1:N).
  - *Mapeamento Schema.org:* schema:WebApplication
  - *Justificativa:* É o artefato tangível digital com o qual o usuário interage com uma aplicação rodando na Web, seja um Gemini Gem, um site ou uma *Application Programming Interface* (API) Web.
- **Item (LRM-E5):** Representa a sessão única de *Chat* (par *Prompt*/Resposta).
  - *Relacionamento:* O **Item** exemplifica uma única **Manifestação** (N:1).
  - *Mapeamento Schema.org:* schema:Conversation
  - *Justificativa:* Cada sessão de chat é um registro único e irrepetível em um momento específico do tempo, um par de interação contendo o *prompt* de entrada e a resposta, descreve um fragmento de informação enviado de um remetente para um destinatário.

A próxima etapa é realizar o mapeamento entre o modelo relacional e os termos do DSP, constituindo-se a formalização técnica e processável por máquina deste MAP.

6.3 Description Set Profile - DSP

Antes de apresentar o DSP para LLMs personalizados traduzindo as decisões das fases anteriores que os registos de metadados devem cumprir, os quadros a seguir apresentam os metadados analisados e que, portanto, influenciaram na determinação final apresentada no Quadro 9 – *Description Set Profile* (DSP) para LLMs personalizados.

Seguindo a orientação do referencial teórico usado nesta pesquisa sobre os benefícios de apresentar exemplos reais no momento da formalização e documentação do DSP, é necessário esclarecer que o cenário hipotético para a área da nutrição tendo como público uma nutricionista específica e seus pacientes apresentado nos quadros a seguir é usado apenas para atender esta orientação exemplificando a aplicação de cada metadado (Dublin Core Metadata Initiative, 2009; Nilsson; Baker; Johnston, 2008). Contudo, o MAP-CLLM proposto nesta pesquisa foca em LLMs personalizados independente de cenários, portanto, pode ser aplicado em qualquer situação que ferramentas que permitem a personalização de LLMs sem profundos conhecimentos da área da CC foram usadas.

O quadro 6 apresenta os 15 elementos do DC aplicados a um LLM personalizado:

Quadro 6 – Dublin Core aplicado a um LLM personalizado.

Metadado	Descrição Breve	Exemplo hipotético de uso no LLM personalizado
Title (DC.Title)	O nome dado ao recurso.	TiaNutri: o nome do LLM personalizado que será divulgado para o público em geral.
Creator (DC.Creator)	O Ator (pessoa ou organização) primariamente responsável pela criação do conteúdo intelectual.	Karina Siqueira: a nutricionista responsável por todas as orientações da área da nutrição necessárias para a personalização do LLM. Marcos Siqueira: O cientista da informação responsável por personalizar o LLM usando a ferramenta Google AI Studio.
Subject (DC.Subject)	O tópico do recurso, geralmente expresso como palavras-chave, frases ou códigos de classificação.	*Large Language Model* (LLM); Inteligência Artificial (IA); IA Generativa (IAG); Nutrição; Aconselhamento Nutricional; Educação Alimentar; Dieta e Saúde; Hábitos Alimentares.
Description (DC.Description)	Um resumo ou relato do conteúdo do recurso (ex: *abstract*, índice).	Recurso de Inteligência Artificial Generativa (IAG) desenvolvido como um *Large Language Model* (LLM) personalizado para o cenário da Nutrição. O modelo foi construído utilizando a ferramenta Google AI Studio. O conteúdo e a base de conhecimento foram curados e validados por Karina Siqueira (Nutricionista), e a personalização técnica foi executada por Marcos Siqueira (Cientista da Informação), garantindo a precisão do aconselhamento nutricional fornecido.
Publisher (DC.Publisher)	O Ator responsável por disponibilizar o recurso em sua forma atual.	Karina Siqueira (Nutricionista) e Marcos Siqueira (Cientista da Informação).
Contributor (DC.Contributor)	Ator que fez contribuições intelectuais secundárias ao recurso (ex: editor, tradutor,	Maria Eduarda Silva (Consultora de IA Generativa), Enzo Silva (Nutricionista Consultor) e Bárbara

	ilustrador).	Silva (Bibliotecária responsável por reunir o corpus documental).
Date (DC.Date)	Um ponto ou período de tempo associado a um evento no ciclo de vida do recurso (ex: data de publicação).	Com base no formato ISO 8601 (AAAA-MM-DD - Ano-Mês-Dia) a data da publicação e disponibilização ao público desejado, por exemplo, 2026-03-30.
Type (DC.Type)	A natureza ou gênero do recurso (p. ex: software).	Um *Large Language Model* (LLM) personalizado por meio da ferramenta Google AI Studio para orientação nutricional e recomendação personalizada.
Format (DC.Format)	O formato de dados (mídia) do recurso (ex: MIME Type como text/html, application/pdf).	Foco na Interface de Interação com o LLM via uma Interface Web (Chatbot): text/html ou application/x-chatbot
Identifier (DC.Identifier)	Uma referência não ambígua ao recurso dentro de um determinado contexto (ex: URL, DOI, ISBN).	A URL que permite o acesso ao LLM personalizado: https://www.TiaNutri.com/
Source (DC.Source)	Um recurso relacionado de onde o recurso descrito é derivado.	Indica o corpus de conhecimento do LLM personalizado incluindo documentos públicos ou de acesso restrito. Relatório Interno: Diretrizes Dietéticas para LLM (Autora: Karina Siqueira, 2025-11-05). Acesso Restrito - Rel_Diretrizes_Dieteticas_LLM.pdf Artigo: "O Impacto da IA na Nutrição Pública". Souza, L. (2024). DOI: 10.XXXX/jnutr.2023.12345 Tese de Doutorado: "Modelos de Linguagem na Educação Alimentar". Costa, B. (2023). URL: http://repositorio.exemplo.br/handle/2023/54321
Language	O idioma do conteúdo intelectual	Usar o padrão BCP 47 (que engloba o

(DC.Language)	do recurso.	RFC 4646), por exemplo, pt-BR.
Relation (DC.Relation)	Um recurso relacionado. Usado para vincular o recurso a outros recursos relacionados.	Indicar o *Model Card* do LLM Base (Gemini 3 Pro): https://storage.googleapis.com/deepmind-media/Model-Cards/Gemini-3-Pro-Model-Card.pdf O *Model Card* do LLM Personalizado (TiaNutri): http://www.tianutri.com.br/modelcard/tianutri O Perfil de Aplicação de Metadados (MAP) para LLMs personalizados: http://www.tianutri.com.br/metadata/map-cllm-v1.0 Relatório técnico de testes realizados no LLM personalizado.
Coverage (DC.Coverage)	O escopo espacial ou temporal do conteúdo do recurso, ou a jurisdição à qual o recurso se aplica.	Cobertura Espacial: Brasil Cobertura Temporal (ISO 8601): 2025-04/2025-06 (Período de validade da base de conhecimento)
Rights (DC.Rights)	Informações sobre direitos detidos no e sobre o recurso (ex: direitos autorais, declarações de acesso).	Software Proprietário de Uso Comercial. Acesso restrito e sujeito a licença de uso paga. Não substitui o aconselhamento profissional. Consulte Termos Comerciais em: http://www.tianutri.com.br/termos

Fonte: elaboração do autor.

O quadro 7 lista os metadados determinados a partir do estudo da proposta dos *Model Cards* e da aplicação da metodologia de análise documental nas ferramentas Google AI Studio e Gemini Gem. Contudo, quando existir uma relação entre o metadado apresentado no quadro 7 com o apresentado no quadro 6 uma sinalização desta relação é apresentada seguindo a principal orientação para a construção de um MAP sobre a necessidade de fazer um arranjo de metadados a partir de elementos de dados provenientes de um ou mais esquemas ou *namespaces* existentes. Nesta pesquisa, ao identificar que um metadado proposto pelos *Model Cards* pode ser representado pelo DC, a decisão foi manter o metadado do DC no DSP final apresentado no quadro 9 visto que um ponto fundamental sobre um MAP é a sua característica de não instituir novos elementos de metadados de forma precipitada.

Quadro 7 – Metadados determinados a partir dos *Model Cards* e ferramentas Google.

Metadado	Descrição Breve	Exemplo hipotético de uso no LLM personalizado
model_name	Nome exclusivo do LLM personalizado.	Ver Quadro 6: DC.Title
model_base	Nome do modelo de base usado.	gemini-3-pro
model_version	Versão do LLM personalizado.	1.0.1
model_type	Arquitetura ou finalidade principal.	Ver Quadro 6: DC.Type
task_type	A tarefa técnica primária que o LLM personalizado executa. A ação da máquina.	Question Answering, Summarization e Text Generation para orientação Nutricional e Recomendação Personalizada.
language	Idioma principal de uso.	Ver Quadro 6: DC.Language
developer_org	Responsável pela personalização do LLM.	Ver Quadro 6: DC.Creator
publisher	Ator responsável por disponibilizar o recurso em sua forma atual.	Ver Quadro 6: DC.Publisher

contributor	Ator que fez contribuições intelectuais secundárias ao recurso (ex: editor, tradutor, ilustrador).	Ver Quadro 6: DC.Contributor
date_published	Data da publicação.	Ver Quadro 6: DC.Date
license	Licença de uso da versão personalizada.	Ver Quadro 6: DC.Rights
frameworks	Conjunto de ferramentas e diretrizes usadas.	Google AI Studio
tags	Palavras-chave para descoberta.	Ver Quadro 6: DC.Subject
description	Um resumo ou relato do conteúdo do recurso (ex: *abstract*, índice).	Ver Quadro 6: DC.Description
format	O formato de dados (mídia) do recurso (ex: MIME Type como text/html, application/pdf).	Ver Quadro 6: DC.Format
api_endpoint	Uma URL que permite acessar o LLM personalizado.	Ver Quadro 6: DC.Identifier
input_prompt_tokens	Limite máximo de palavras/tokens permitido no texto de entrada.	30720
max_output_tokens	O número máximo de palavras/tokens a serem	2048

	gerados no texto da resposta.	
stop_sequences	Uma ou mais sequências de texto que, quando geradas, encerram a geração do texto da resposta.	*** (Três asteriscos); FIM_DESCRICAO; \n\n (Dois saltos de linha consecutivos)
response_type	Indicação do tipo de saída padrão gerada pelo LLM personalizado sendo texto simples ou um formato estruturado de dados, por exemplo, JSON.	"application/json" ou “string”
thinking_mode	Disponível em alguns modelos de base e aplicável em alguns casos, permite orientar o LLM personalizado a "pensar antes de responder" (Sim/Não).	Não.
code_execution	Indica se o LLM personalizado está habilitado a executar código escrito em uma linguagem de programação de computadores diretamente no texto de entrada (Sim/Não).	Não.
function_calling	Indica se o LLM personalizado está habilitado a identificar no texto de entrada fornecido a necessidade de interagir com ferramentas, sistemas ou aplicações externas para calcular algo ou buscar informações em uma base de dados. Apresenta o nome e uma breve descrição da função (ou funções) que o LLM personalizado pode interagir.	consultar_agenda: verifica a disponibilidade da nutricionista para um dia específico.
system_instruction	O conjunto completo de instruções em linguagem natural que define o comportamento do LLM personalizado.	Você é a "TiaNutri", um LLM personalizado para a área da nutrição e bem-estar, projetado para auxiliar nutricionistas em seu trabalho e fornecer suporte informativo e motivacional aos pacientes. Sua prioridade máxima é a segurança. Você nunca deve diagnosticar, prescrever dietas específicas (excluindo exemplos gerais não personalizados) ou substituir o

		conselho de um profissional de saúde. Sempre encoraje o paciente a discutir qualquer mudança importante com seu nutricionista. Use um tom de voz empático, encorajador, e informativo. Mantenha a linguagem acessível, mas baseada em ciência (quando apropriado). Auxilie o nutricionista com a criação de planos alimentares de exemplo, sugestões de receitas com base em restrições, resumo de logs de alimentação de pacientes e informações sobre a ciência por trás de nutrientes específicos (ex: funções da vitamina D). Para pacientes responda a dúvidas sobre alimentos, forneça motivação, auxilie no registro de refeições (logging) e ofereça lembretes suaves para hidratação e refeições. Evite jargões médicos complexos, a menos que solicitado explicitamente pelo nutricionista. Se o paciente expressar sintomas graves ou sinais de transtorno alimentar, você deve interromper a conversa e instruí-lo a procurar ajuda profissional imediatamente.
temperature	Valor da temperatura usada na configuração para controlar a aleatoriedade ou criatividade do LLM personalizado.	1
top_p	O valor do Top P usado para definir o limite de probabilidade cumulativa dos tokens mais prováveis que serão considerados para a amostragem da próxima palavra/token no processo de geração do texto.	0.9
top_k	Valor do Top K usado (Similar ao Top P, porém usando um	30

	valor fixo).	
data_source	Origem do conjunto de dados usados na personalização do LLM.	Ver Quadro 6: DC.Source
safety_settings_level	Nível de filtros de segurança, por exemplo, assédio, discurso de ódio, conteúdo sexual ou perigoso.	Informar a categoria do conteúdo e o nível de limiar de bloqueio, usando um vocabulário controlado sugerido pela documentação do modelo de base, por exemplo : harassment: BLOCK_MEDIUM_AND_ABOVE hateSpeech: BLOCK_LOW_AND_ABOVE
use_case_type	Classificação da categoria do cenário principal de uso, a intenção humana.	Apoio à decisão clínica.
use_case_domain	Setor, área ou domínio de aplicação.	Saúde e Nutrição Clínica.
target_user_role	Função principal do usuário que interage com o LLM personalizado.	Nutricionista ou Paciente.
criticality_level	Nível de risco/impacto das decisões do LLM personalizado (Baixo, Médio, Alto).	Risco médio para a saúde.
out_of_scope_areas	Lista de domínios explicitamente proibidos.	Diagnóstico Médico ou Nutricional e Prescrição Farmacológica ou Dietética.

customization_strategy	Método de personalização do LLM.	Engenharia de *prompt* avançada usada para definir a *System Instruction* do LLM e Geração Aumentada por Recuperação (*Retrieval Augmented Generation* - RAG).
safety_tested	Confirmação (Sim/Não) de teste de segurança (*red-teaming*).	Sim. Uma equipe (*red-teaming*) composta pela nutricionista, seus pacientes, e um cientista da informação realiza diversas interações com o LLM personalizado seguindo um protocolo de testes e documenta todas as interações.
red_team_metrics	Documentação completa dos testes realizados (safety_tested) indicando o protocolo seguido, os resultados e ações de correções.	Ver Quadro 6: (DC.Relation)
coverage	O escopo espacial ou temporal do conteúdo do recurso, ou a jurisdição à qual o recurso se aplica.	Ver Quadro 6: (DC.Coverage)
review_frequency	Frequência de revisão humana (em meses).	3
interaction_id	Um identificador universalmente único para uma interação única e específica na sessão de chat.	*Universal Unique Identifier* (UUID) p. ex. a1b2c3d4-e5f6-7890-a1b2-c3d4e5f67890
timestamp_start	Data e hora do início de uma interação única e específica de sessão de chat.	Usando ISO 8601 p. ex. 2026-03-30T16:00:00Z 30 de março de 2026, 4 horas da tarde (no relógio global de referência).
timestamp_end	Data e hora do fim de uma	Usando ISO 8601 p. ex. 2026-

	interação única e específica de sessão de chat.	03-30T17:00:00Z 30 de março de 2026, 5 horas da tarde (no relógio global de referência).
user_input_hash	Código que permite verificar se o texto digitado pelo usuário foi alterado depois de armazenado para fins de auditoria.	"Minha última consulta foi em 12/09/2025. Qual é o meu plano alimentar?" 7b4c81a2f60e9d4c… (SHA-256)
user_input_enc	Texto criptografado digitado pelo usuário.	"Minha última consulta foi em 12/09/2025. Qual é o meu plano alimentar?" XsD2kL90k+c4H7gWzR6yA8 mB1j2f… (AES-256)
LLM_out_hash	Código que permite verificar se o texto gerado pelo LLM personalizado foi alterado depois de armazenado para fins de auditoria.	"Seu plano alimentar 'Equilíbrio' permanece ativo até o final de 2026. Lembre-se de agendar sua próxima revisão nutricional." 3c8f1e2b0d7a65c94b2a8d1e7f 0c... (SHA-256)
LLM_out_Enc	Texto criptografado gerado pelo LLM personalizado.	"Seu plano alimentar 'Equilíbrio' permanece ativo até o final de 2026. Lembre-se de agendar sua próxima revisão nutricional." R2sP1t5xJ3yA0zB9Q7wX4eU 6vG8h... (AES-256)

Fonte: elaboração do autor.

O quadro 8 apresenta o arranjo de metadados realizado e necessário para a criação de um MAP. A decisão de manter os metadados do DC no DSP final, em detrimento dos elementos nativos propostos pelos *Model Cards*, fundamenta-se nas diretrizes metodológicas para a construção de um MAP. De acordo com a literatura sobre a arquitetura de um MAP, um dos princípios fundamentais desse processo consiste em priorizar a reusabilidade de esquemas consolidados e evitar a instituição precipitada de novos elementos descritivos no ecossistema de dados (Malta, 2014). Desse modo, ao identificar que uma propriedade conceitual sugerida pelo framework dos *Model Cards* pode ser representada de maneira equivalente por um termo do DC, a herança semântica deste último foi mantida. Essa estratégia de harmonização impede a redundância e o encargo operacional desproporcional decorrentes do desenvolvimento de

novos metadados sem necessidade prática (International Conference on Dublin Core and Metadata Applications (DC), 2015).

Sob a perspectiva da padronização e da precisão técnica, a substituição das propriedades nativas dos *Model Cards* pelo DC justifica-se pelas limitações formais da proposta de Mitchell *et al*. (2019). Como indicam as análises documentais, o framework original concebido pela Ciência da Computação não define uma sintaxe formal, um esquema rígido ou chaves de identificadores uniformes (URIs) para seus elementos, caracterizando-se predominantemente como uma estrutura conceitual de linguagem natural. Por outro lado, o DC constitui uma norma internacional estável que oferece uma infraestrutura de identificadores única e chaves de processamento por máquina associadas a rótulos de compreensão humana. Portanto, a transposição dos termos conceituais dos *Model Cards* para a sintaxe estruturada do DC é uma exigência técnica para transmutar um relatório estático legível apenas por humanos em um conjunto de dados semântico, formalmente estruturado e processável de maneira automatizada em escala web (Riley, 2017).

Adicionalmente, a adoção do DC como camada fundamental do MAP-CLLM viabiliza o alcance da interoperabilidade global de metadados, atuando como o menor denominador comum necessário para a busca e recuperação de recursos informacionais complexos na Web (Baptista, 2007). Uma vez que a proposta de Mitchell *et al*. (2019) permite uma representação flexível e expansível para incluir metadados de cenários específicos, a personalização de um *Model Card* para o cenário dos LLMs personalizados requer a definição exata de quais elementos descritivos de fato farão parte do perfil da aplicação (Qin; Yu, 2024). Desse modo, o mapeamento "De/Para" apresentado no quadro 8 confere estabilidade semântica ao vincular os elementos dinâmicos da IAG a propriedades universais do DC. Essa ancoragem assegura que o LLM personalizado não se torne um silo de informação isolado, mas sim um ativo documental amplamente compartilhável, interoperável e auditável em ecossistemas de informação diversos (International Conference on Dublin Core and Metadata Applications (DC), 2015).

Quadro 8 – Mapeamento (De/Para) entre Model Cards e Dublin Core.

Model Cards	Dublin Core	Description Set Profile (DSP)
model_name	DC.Title	Title
model_type	DC.Type	Type
language	DC.Language	Language
developer_org	DC.Creator	Creator
publisher	DC.Publisher	Publisher
contributor	DC.Contributor	Contributor
date_published	DC.Date	Date
license	DC.Rights	Rights

tags	DC.Subject	Subject
description	DC.Description	Description
format	DC.Format	Format
api_endpoint	DC.Identifier	Identifier
data_source	DC.Source	Source
red_team_metrics	DC.Relation	Relation
coverage	DC.Coverage	Coverage_Temporal e Coverage_Spatial

Fonte: elaboração do autor.

Depois desta visão de todos os metadados determinados para um LLM personalizado organizada com base em seus padrões de referência, o DC e os *Model Cards*, e exemplos da aplicação de cada metadado em cenário real, embora fictício, segue o DSP do MAP proposto nesta pesquisa, o MAP-CLLM, resultante da análise desta visão, que define os templates de descrição para cada entidade do modelo LRM.

Quadro 9 – *Description Set Profile* (DSP) para LLMs personalizados.

Entidade Obra (LRM-E2): Foco no Modelo de Base, a origem do LLM personalizado.			
Elemento do MAP	**Definição**	**Cardinalidade**	**Restrição de Valor**
Model_Base	Nome do modelo de base usado, p. ex., gemini-3-pro	1..1	Lista Controlada (p. ex.: Google Models)
Model_Provider	Fornecedor que desenvolveu e mantém o modelo de base (p. ex: Google, OpenAI, Anthropic).	1..1	Texto Livre OU URI (para o site oficial do fornecedor)
Model_Docs	Documentação técnica oficial disponibilizada pelo fornecedor do modelo de base.	1..1	URI (para o site oficial da documentação)
Entidade Expressão (LRM-E3): Foco na materialização da personalização do LLM.			
Elemento do MAP	**Definição**	**Cardinalidade**	**Restrição de**

			Valor
Work_ID	Identificador único da Obra (Modelo de Base) que esta expressão realiza.	1..1	Universal Unique Identifier (UUID)
Title	Nome dado ao LLM personalizado (p. ex.: TiaNutri).	1..1	Texto Livre. DC.Title
Creator	Responsável pela personalização do LLM.	1..N	Texto Livre. DC.Creator
Publisher	Responsável por disponibilizar o recurso em sua forma atual.	1..N	Texto Livre / URI DC.Publisher
Contributor	Ator que fez contribuições intelectuais secundárias (p. ex.: curadoria de corpus e consultores).	0..N	Texto Livre. DC.Contributor
Description	Resumo do propósito e funcionalidades da personalização.	1..1	Texto Livre. DC.Description
Subject	Palavras-chave para descoberta.	1..N	Texto Livre. DC.Subject
Rights	Licença de uso, direitos autorais e intelectuais sobre a lógica da personalização.	1..1	Texto Livre / URI de Licença. DC.Rights
Type	A natureza ou gênero do recurso (p. ex: software).	1..1	Texto Livre. DC.Type

Relation	Recursos relacionados (p. ex: Documentos de testes realizados, *Model Cards* e MAP relacionados).	1..N	Texto Livre / URI. DC.Relation
Model_Version	Versão do LLM personalizado (p. ex: 1.0.1).	1..1	Texto (Semântico)
Date	Data de publicação ou disponibilização da versão.	1..1	ISO 8601 AAAA-MM-DD DC.Date
Customization_Strategy	Método de personalização do LLM usado (p. ex.: *Prompt Engineering*, RAG).	1..N	Texto Livre
Frameworks	Conjunto de ferramentas usadas no processo de personalização do LLM (p. ex: Google AI Studio, Gemini Gems).	1..N	Texto Livre
Response_Type	Indicação do tipo de saída padrão gerada pelo LLM personalizado (p. ex: JSON, Texto).	1..1	MIME Type
System_Instruction	O conjunto completo de instruções em linguagem natural que define o comportamento do LLM personalizado.	1..1	Texto Livre (Pode ser extenso)
Temperature	Valor de configuração da "criatividade" do LLM personalizado (0.0 a 2.0).	0..1	Decimal

Top_P	Define o limite de probabilidade cumulativa dos tokens mais prováveis que serão considerados para a amostragem da próxima palavra/token no processo de geração do texto.	0..1	Decimal
Top_K	Similar ao Top P, porém usando um valor fixo.	0..1	Inteiro
Stop_Sequences	Sequência de textos que forçam a parada da geração da resposta do LLM personalizado.	0..N	Texto Livre
Source	Origem do conjunto de dados usados na personalização do LLM.	0..N	URI / Referência Bibliográfica. DC.Source
Thinking_Mode	Capacidade nativa de "pensar antes de responder".	0..1	Booleano (Sim/Não)
Code_Execution	Capacidade nativa de executar código de programação de computadores informado no texto de entrada pelo usuário final.	0..1	Booleano (Sim/Não)
Function_Calling	Capacidade nativa de chamar funções externas.	0..N	Texto Livre (Descrição da função)
Safety_Settings_Level	Níveis padrão de filtros de segurança.	0..N	Vocabulário Controlado fornecido pelo fornecedor do modelo de base: BLOCK_NONE

			BLOCK_SOME
Entidade Manifestação (LRM-E4): Foco na instância técnica acessível do LLM personalizado.			
Elemento do MAP	Definição	Cardinalidade	Restrição de Valor
Expression_ID	Identificador único da Expressão (Personalização) que esta manifestação corporifica.	1..1	Universal Unique Identifier (UUID)
Identifier	URL de acesso ao LLM personalizado.	1..1	URI/URL válido. DC.Identifier
Language	Idioma principal da interação (BCP 47).	1..N	Padrão (p. ex.: pt-BR). DC.Language
Format	Formato de interação (MIME type ou descrição).	1..1	Texto (p. ex: text/html, application/json) DC.Format
Input_Prompt_Tokens	Limite máximo de tokens permitido no texto de entrada.	0..1	Inteiro
Max_Output_Tokens	O número máximo de tokens a serem gerados no texto da resposta.	0..1	Inteiro
Use_Case_Domain	Setor, área ou domínio de aplicação (p. ex.: Nutrição Clínica).	1..N	Texto Livre
Target_User_Role	Função principal do usuário que interage com o LLM personalizado (p.	1..N	Texto Livre

	ex., Nutricionista ou Paciente).		
Out_Of_Scope_Areas	Tópicos proibidos ou não suportados pela personalização.	1..N	Texto Livre
Safety_Tested	Indicador de realização de testes de segurança (*Red Teaming*).	1..1	Booleano
Criticality_Level	Nível de risco da aplicação.	1..1	Lista Controlada (Baixo, Médio, Alto).
Review_Frequency	Frequência de revisão humana (em meses).	1..1	Inteiro
Coverage_Temporal	A janela de validade da base de conhecimento do LLM personalizado, ou o período de tempo coberto pelo conteúdo.	1..1	Padrão ISO 8601 (Intervalo). DC.Coverage
Coverage_Spatial	A área geográfica ou jurisdição principal para a qual o conteúdo ou serviço se aplica.	1..1	Texto Livre (Nome) OU URI (Vocabulário Controlado, p. ex: ISO 3166) DC.Coverage
Task_Type	A tarefa técnica primária que o LLM personalizado executa. A ação da máquina (p. ex: Question Answering, Summarization, Text Generation).	1..N	Lista Controlada (Sugestão: *Hugging Face Tasks* ou *Model Card Schema* - ex: *Question Answering, Summarization, Text Generation*).
Use_Case_Type	Classificação da categoria do cenário principal de uso	1..1	Texto Livre (ex: Apoio à decisão clínica) OU

	(Intenção humana, p. ex: Apoio à decisão clínica.).		Vocabulário Controlado
Entidade Item (LRM-E5): Foco na interação única (*prompt* e resposta) com o LLM personalizado.			
Elemento do MAP	Definição	Cardinalidade	Restrição de Valor
Manifestation_ID	Identificador único da Manifestação que gerou este registro/log do Item.	1..1	Universal Unique Identifier (UUID)
Interaction_ID	Um identificador universalmente único para uma interação única e específica na sessão de chat.	1..1	Universal Unique Identifier (UUID)
Timestamp_Start	Data e hora do início de uma interação única e específica de sessão de chat.	1..1	ISO 8601 (Timestamp)
Timestamp_End	Data e hora do fim de uma interação única e específica de sessão de chat.	1..1	ISO 8601 (Timestamp)
User_Input_Hash	Código que permite verificar se o texto digitado pelo usuário foi alterado após armazenado para fins de auditoria.	0..1	Hash String (SHA-256)

User_Input_Enc	Texto criptografado digitado pelo usuário.	0..1	String Criptografia (AES-256)
LLM_Out_Hash	Código que permite verificar se o texto gerado pelo LLM personalizado foi alterado após armazenado para fins de auditoria.	0..1	Hash String (SHA-256)
LLM_Out_Enc	Texto criptografado gerado pelo LLM personalizado.	0..1	String Criptografia (AES-256)

Fonte: elaboração do autor.

Embora o DSP permita a validação automática dos dados, adicionalmente pode ser útil fornecer diretrizes de uso com instruções em linguagem natural, exemplos de preenchimento e esclarecimentos de regras para garantir a consistência na criação dos dados.

6.4 Diretrizes de Uso

Para garantir a qualidade e a consistência dos metadados determinados para este MAP, os profissionais envolvidos com a descrição devem seguir as seguintes orientações:

1. **Preenchimento da System_Instruction (Expressão):** Este é o elemento mais crítico para a reprodutibilidade (R3). Deve-se incluir o texto literalmente, com as mesmas palavras *(ipsis litteris),* usado na personalização do LLM.

2. **Identificadores e URLs (Manifestação):** O campo Identifier deve levar, preferencialmente, à interface pública do Gem ou aplicação web.

3. **Segurança e Ética (Avaliação - R2):** Os elementos Safety_Tested, Relation e Out_Of_Scope_Areas são obrigatórios para aplicações em cenários sensíveis (como Saúde e Finanças). Seja explícito sobre o que o modelo não deve fazer (ex: "Não realiza diagnósticos médicos").

4. **Relacionamentos (Relation):** Utilize este elemento para criar a linhagem do LLM personalizado. Sempre vincule a versão personalizada a documentos de suporte (MAP relacionados, manuais, documentos de testes realizados e *Model Cards* do modelo de base e da versão personalizada).

5. **Vínculo Hierárquico (1:N):** Os elementos Work_ID, Expression_ID e Manifestation_ID não são opcionais e devem sempre ser preenchidos para garantir a rastreabilidade da Obra ao Item.

6. **Classificação de Uso (Task_Type / Use_Case_Type):** Existe uma política para a diferenciação desses elementos, por isso, o Use_Case_Type deve ser o principal critério para determinar o Criticality_Level.

7. **Cobertura Temporal:** O elemento Coverage_Temporal deve ser revisado sempre que houver atualização da base de conhecimento (Source) do LLM personalizado.

Enquanto as diretrizes de uso fornecem instruções para garantir a consistência na criação dos dados, a definição da sintaxe e esquema de codificação especificam como os metadados devem ser codificados em formatos de máquina para garantir o processamento.

6.5 Definição da Sintaxe e Esquema de Codificação

O quadro 10 a seguir apresenta o mapeamento dos elementos do MAP apresentados no DSP para propriedades do vocabulário Schema.org. Dada a ausência de propriedades específicas para parâmetros de IA no vocabulário base, utiliza-se additionalProperty para assegurar a preservação da especificidade técnica do dado. Recomenda-se a utilização da sintaxe JSON-LD para a implementação em páginas web.

Quadro 10 – Mapeamento (De/Para) entre MAP e Schema.org.

Elemento do MAP **Obra (LRM-E2)**	**Schema.org** schema:Product schema.org/Product
Model_Base	schema:name schema.org/name
Model_Provider	schema:manufacturer schema.org/manufacturer
Model_Docs	schema:url schema.org/url
Elemento do MAP **Expressão (LRM-E3)**	**Schema.org**

	schema:SoftwareSourceCode schema.org/SoftwareSourceCode
Work_ID	schema:isBasedOn schema.org/isBasedOn
Title	schema:name schema.org/name
Creator	schema:author schema.org/author
Publisher	schema:publisher schema.org/publisher
Contributor	schema:contributor schema.org/contributor
Description	schema:description schema.org/description
Subject	schema:keywords schema.org/keywords
Rights	schema:license schema.org/license
Type	schema:genre schema.org/genre

Relation	schema:citation schema.org/citation
Model_Version	schema:version schema.org/version
Date	schema:datePublished schema.org/datePublished
Customization_Strategy	schema:additionalProperty schema.org/additionalProperty
Frameworks	schema:runtimePlatform schema.org/runtimePlatform
Response_Type	schema:additionalProperty schema.org/additionalProperty
System_Instruction	schema:additionalProperty schema.org/additionalProperty
Temperature	schema:additionalProperty schema.org/additionalProperty
Top_P	schema:additionalProperty schema.org/additionalProperty
Top_K	schema:additionalProperty schema.org/additionalProperty
Stop_Sequences	schema:additionalProperty

	schema.org/additionalProperty
Source	schema:additionalProperty schema.org/additionalProperty
Thinking_Mode	schema:additionalProperty schema.org/additionalProperty
Code_Execution	schema:additionalProperty schema.org/additionalProperty
Function_Calling	schema:additionalProperty schema.org/additionalProperty
Safety_Settings_Level	schema:additionalProperty schema.org/additionalProperty
Elemento do MAP Manifestação (LRM-E4)	**Schema.org** schema:WebApplication schema.org/WebApplication
Expression_ID	schema:isBasedOn schema.org/isBasedOn
Identifier	schema:url schema.org/url
Language	schema:inLanguage schema.org/inLanguage
Format	schema:encodingFormat schema.org/encodingFormat
Input_Prompt_Tokens	schema:additionalProperty

	schema.org/additionalProperty
Max_Output_Tokens	schema:additionalProperty schema.org/additionalProperty
Use_Case_Domain	schema:applicationCategory schema.org/applicationCategory
Target_User_Role	schema:audience schema.org/audience
Out_Of_Scope_Areas	schema:additionalProperty schema.org/additionalProperty
Safety_Tested	schema:additionalProperty schema.org/additionalProperty
Criticality_Level	schema:additionalProperty schema.org/additionalProperty
Review_Frequency	schema:additionalProperty schema.org/additionalProperty
Coverage_Temporal	schema:temporalCoverage schema.org/temporalCoverage
Coverage_Spatial	schema:spatialCoverage schema.org/spatialCoverage
Task_Type	schema:additionalProperty schema.org/additionalProperty
Use_Case_Type	schema:additionalProperty schema.org/additionalProperty
Elemento do MAP Item (LRM-E5)	**Schema.org** schema:Conversation schema.org/Conversation

Manifestation_ID	schema:isBasedOn schema.org/isBasedOn
Interaction_ID	schema:identifier schema.org/identifier
Timestamp_Start	schema:dateCreated schema.org/dateCreated
Timestamp_End	schema:dateModified schema.org/dateModified
User_Input_Hash	schema:additionalProperty schema.org/additionalProperty
User_Input_Enc	schema:additionalProperty schema.org/additionalProperty
LLM_Out_Hash	schema:additionalProperty schema.org/additionalProperty
LLM_Out_Enc	schema:additionalProperty schema.org/additionalProperty

Fonte: elaboração do autor.

Uma análise de conformidade com os requisitos funcionais definidos indica que o MAP-CLLM atende ao R1 (Descoberta) através do uso de Subject, Title e Description. O R2 (Avaliação) é coberto pelos metadados de Safety_Tested, Safety_Settings_Level e Criticality_Level. O R3 (Reprodutibilidade) é garantido pelo registro granular de parâmetros técnicos na entidade Expressão (p. ex., Temperature, System_Instruction). Finalmente, o R4 (Interoperabilidade) é assegurado pelo mapeamento com o Schema.org. Diante disso, a justificativa do uso do MAP-CLLM, após ser devidamente alimentado, manifesta-se em sua utilidade prática e operacional ao longo de todo o ciclo de vida do objeto informacional: 1) na descoberta e recuperação automatizada, permitindo que motores de busca e repositórios

indexem o modelo por área e aplicação; 2) na governança e conformidade regulatória, servindo como passaporte de auditoria técnica e ética perante normativas; 3) na tomada de decisão pelos usuários, que podem avaliar previamente o escopo e a segurança antes da adoção; 4) na reprodutibilidade e manutenção, viabilizando que curadores e desenvolvedores reconstituam a lógica de personalização; e 5) na rastreabilidade e citação, garantindo a auditoria de interações e resultados gerados sem violar a privacidade. Portanto, a implementação do MAP-CLLM subsidia os processos de governança de LLMs personalizados, caracterizando-os como ativos de informação documentados, auditáveis e recuperáveis, essenciais para a confiabilidade deste tipo de IA.

7 CONSIDERAÇÕES FINAIS

Esta tese buscou enfrentar a opacidade informacional dos LLMs personalizados partindo do problema de que a ausência de uma estrutura formal adequada para a representação desses objetos informacionais complexos compromete a sua transparência e auditabilidade. Ao concluir esta pesquisa, confirma-se a tese de que o aporte metodológico da CI, materializado em instrumentos de representação, é capaz de minimizar dificuldades ao explicar o comportamento da IAG, fornecendo uma estrutura de governança informacional necessária e confiável pautada no MAP-CLLM, especificamente no DSP apresentado.

O objetivo geral de propor um MAP para LLMs personalizados foi atingido com a consolidação do MAP-CLLM. Este MAP não se limita a uma lista de campos descritivos, mas constitui uma resposta técnica ao desafio de identificar, recuperar e gerenciar LLMs personalizados que operam em cenários de conhecimento especializados. A pesquisa demonstrou que a sistematização de requisitos, fundamentada em um processo metodológico pautado na CI, combinando a revisão de literatura como abordagem teórica e a Análise Documental como técnica de coleta e análise de dados, é o caminho para contribuir para a explicabilidade a sistemas de IAG tornando-os acessíveis ao exame público e regulatório.

Mediante o percurso metodológico adotado foi possível delinear os alicerces e as compreensões para a concepção de um MAP para LLMs personalizados. Este MAP é especificamente projetado para a caracterização e organização desses objetos informacionais complexos oriundos da IAG. Deste modo, uma das contribuições deste trabalho reside na construção de uma ponte metodológica entre a CC, responsável pela criação e desenvolvimento da IAG, e a CI, que oferece os métodos, técnicas e ferramentas para sua descrição, representação e organização, consequentemente, para a promoção de sua integração social de forma confiável, ética e responsável.

A construção do MAP-CLLM validou a aplicabilidade do referencial teórico sobre MAP discutido nesta tese. O processo de desenvolvimento seguiu as etapas preconizadas pela literatura especializada da área, desde a definição de requisitos funcionais até a seleção e refinamento de vocabulários. Essa conformidade metodológica atesta que os protocolos tradicionais da CI permanecem vigentes e eficazes para a organização desses objetos informacionais, contribuindo para a semântica necessária e para a interoperabilidade.

O uso do modelo conceitual LRM permitiu uma desconstrução sistemática do objeto de estudo, um LLM personalizado, permitindo a identificação das entidades Obra, Expressão, Manifestação e Item, e informando a estrutura do perfil de aplicação de metadados proposto. O

resultado é a determinação de um conjunto de metadados que busca capturar tanto os aspectos técnico-configuracionais quanto os semântico-instrucionais identificados nas ferramentas de personalização de um LLM disponíveis, e que definem a singularidade deste recurso informacional. A decomposição do objeto de estudo em entidades de Obra, Expressão, Manifestação e Item revelou-se uma estratégia analítica fundamental. Ao tratar o modelo de base como Obra e a configuração específica do sistema como Manifestação, esta pesquisa conseguiu organizar a complexidade técnica sob uma estrutura hierárquica clara, facilitando a compreensão das derivações de um LLM personalizado.

A harmonização entre o padrão DC, o *framework* de *Model Cards* e o vocabulário Schema.org no âmbito do MAP-CLLM permitiu uma representação abrangente. Enquanto o DC garantiu a interoperabilidade básica e a proveniência, o conceito de *Model Cards* trouxe para a CI os parâmetros técnicos e éticos essenciais da CC. O mapeamento final para o Schema.org assegurou que esses metadados técnicos sejam indexáveis e compreensíveis por motores de busca globais.

Do ponto de vista prático, o MAP-CLLM propõe um instrumento para a organização, descrição, representação, recuperação e gerenciamento de LLMs personalizados em repositórios institucionais, plataformas de compartilhamento ou sistemas de gerenciamento de conhecimento. A sua adoção pode promover a interoperabilidade entre diferentes sistemas, facilitar estudos comparativos sobre o comportamento de LLMs personalizados e garantir a preservação do contexto de criação desses recursos. Teoricamente, esta pesquisa indica a aplicabilidade de modelos e métodos clássicos da CI para a compreensão e organização de novos objetos informacionais, por exemplo, a pertinência do modelo LRM para além do contexto estritamente bibliográfico.

A proposta do DSP apresentada no quadro 9 materializa a contribuição técnica desta pesquisa ao estabelecer restrições de valor e obrigatoriedade para os metadados de um LLM personalizado. Este nível de detalhamento é o que permite a transição de uma descrição documental simples para uma representação estruturada passível de automação. Conclui-se que a formalização do MAP-CLLM oferece aos desenvolvedores e gestores de informação um protocolo de transparência que equilibra a precisão técnica necessária com a acessibilidade informacional exigida pela sociedade. O DSP proposto também apresenta implicações para o contexto da IA Confiável (*Trustworthy AI*) visto que a presença de um registro de metadados estruturado contribui para a transparência. O preenchimento dos campos sugeridos não se restringe a um simples ato de descrição, mais que isso, configura-se como um exercício que exige daquele que decide personalizar um LLM uma reflexão explícita acerca do propósito, das

limitações e dos riscos da criação de um LLM personalizado. Desse modo, o MAP-CLLM proposto ultrapassa seu papel descritivo para subsidiar os processos relacionados à governança de informação. Em um cenário institucional, a obrigatoriedade de criar um registro de metadados para cada LLM personalizado publicado pode operar como um ponto de controle de qualidade e uma política de informação, fomentando um desenvolvimento de IA minuciosamente documentada e confiável.

É importante estabelecer a distinção entre a contribuição deste MAP para a explicabilidade em IA e as abordagens pesquisadas pela CC (*Explainable AI - XAI*). Enquanto as metodologias de XAI, tais como LIME e SHAP, concentram-se primordialmente em elucidar as razões internas a uma decisão específica do modelo de IA durante a fase de execução, ou seja, na explicabilidade da inferência, o MAP-CLLM apresenta uma perspectiva baseada em metadados que pode ser conceituada como "explicabilidade fundamentada em metadados" ou "explicabilidade contextual". A relevância desta abordagem reside no fato de que, em vez de responder a questionamentos como "Por que o LLM gerou esta frase específica?", ela aborda variáveis determinantes para a construção da confiança por parte do usuário, questões como "Qual o propósito original da concepção deste LLM personalizado?", "Quem detém a responsabilidade pela sua criação e manutenção?", e "Quais são as diretrizes de seu comportamento e as limitações previamente identificadas?". Essa camada de explicação, que não limita-se a justificação de saídas pontuais, é requisito para a tomada de decisão informada sobre o momento oportuno, a forma adequada e a própria pertinência de depositar confiança em um determinado LLM personalizado para contexto específico.

No âmbito do ensino na CI, as contribuições desta tese materializam-se na provisão de um instrumental teórico-metodológico para a formação de futuros profissionais, munindo-os com o aparato conceitual e técnico necessário para atuar no ecossistema da IAG. Ao adaptar os modelos clássicos de representação da CI, como o LRM e o DC, à modelagem de LLMs personalizados, o trabalho expande os horizontes didáticos e curriculares da área, demonstrando de forma prática que as competências tradicionais em catalogação e metadados ultrapassam o universo dos acervos bibliográficos tradicionais para abranger os ecossistemas algorítmicos. A pesquisa também fornece a docentes e discentes um quadro estruturado de metadados para avaliar a explicabilidade contextual, os limites de conhecimento e as restrições éticas de LLMs personalizados para contextos educativos. Desta forma, a tese contribui com uma ponte didática interdisciplinar entre a CI e a CC, capacitando os estudantes a posicionarem-se de forma crítica e ativa como arquitetos de metadados e gestores da governança de sistemas de IA confiáveis.

De um modo mais amplo, a pesquisa contribuiu para reafirmar o papel do profissional da informação como necessário no desenvolvimento de sistemas de inteligência artificial éticos e confiáveis. A competência na representação de conhecimento especializado, demonstrada ao longo deste estudo, posiciona o cientista da informação não apenas como curadores de acervos, mas como arquitetos de metadados em ecossistemas algorítmicos. A pesquisa contribui para o entendimento de que a curadoria de dados e a governança de LLMs são faces da mesma moeda no contexto da economia da informação atual.

Sobre limitações, a pesquisa reconhece a volatilidade do campo da IAG onde a rápida sucessão de versões de modelos de base e a natureza proprietária de ferramentas de personalização de LLMs impõem desafios à durabilidade de descritores específicos. Embora o estudo resida no escopo restrito do ecossistema de ferramentas da Google, o Google AI Studio e Gemini Gem, sendo um ecossistema representativo, do ponto de vista científico, é necessário informar que a generalização dos resultados para outras plataformas requer validação. Entre outros fatores já citados, a enorme quantidade de ferramentas e fornecedores de LLMs justificou a escolha do ecossistema Google, entretanto, o MAP-CLLM proposto, amparado pelas orientações da CI e baseado nos aspectos técnicos sobre LLMs, o alicerce que qualquer fornecedor deve contemplar em seus modelos, buscou selecionar um conjunto de metadados que poderiam ser replicados em qualquer outro ecossistema. De qualquer forma, o cenário atual exige que o MAP seja um instrumento dinâmico e sujeito a revisões periódicas.

Como sugestão para trabalhos futuros, seria pertinente testar a aplicabilidade, a adequação e a extensibilidade deste MAP a LLMs personalizados em outras plataformas de personalização ou modelos de código aberto. Recomenda-se o desenvolvimento de mecanismos de extração automatizada de metadados baseados no MAP-CLLM. A utilização de agentes de IA para gerar seus próprios registros de transparência, validados por um perfil de aplicação de metadados, poderia acelerar a adoção de padrões de explicabilidade. Sugere-se também a aplicação do MAP-CLLM em cenários específicos para testar a flexibilidade dos elementos descritivos frente a requisitos de conformidade. Neste mesmo caminho, um estudo focado nos usuários de LLMs personalizados para avaliar se os registros de metadados gerados a partir do MAP-CLLM proposto nesta pesquisa efetivamente contribuem para a confiança, a compreensão e a capacidade dos usuários de selecionar e utilizar LLMs personalizados de forma mais segura seria relevante. Por fim, outra via de pesquisa consiste na validação deste MAP por meio de estudos com desenvolvedores de LLMs personalizados, permitindo refinar os elementos propostos garantindo sua praticidade.

Esta tese entrega à comunidade científica um modelo de representação que destaca a tradição da CI ao mesmo tempo que dialoga com as inovações da fronteira tecnológica. O MAP-CLLM não é um ponto final, mas uma proposta de base para que a representação de LLMs personalizados seja integrada aos sistemas de informação globais de forma confiável, padronizada e interoperável. Espera-se que novas pontes sejam construídas entre a organização do conhecimento e a inteligência artificial.

Em conclusão, assegurar que o desenvolvimento da IA se processe de maneira benéfica e confiável constitui um desafio complexo. Neste contexto, este estudo contribuiu para demonstrar que a CI, por meio de seus métodos, técnicas e práticas voltados à representação e organização do conhecimento, assume um papel necessário na determinação de metadados para LLMs personalizados. Essa pesquisa pode contribuir para traduzir os preceitos éticos da IA em práticas de identificação e determinação de metadados documentadas, interoperáveis e passíveis de auditoria.

REFERÊNCIAS

A, S.; TAJ, A.; NAIR, A. R. Advancing Open Science: A Bibliometric Study of Scholarly Metadata Research (1995–2024). **Science & Technology Libraries**, [*S. l.*], p. 1–30, 2025. DOI: 10.1080/0194262X.2025.2517089. Disponível em: https://www.tandfonline.com/doi/full/10.1080/0194262X.2025.2517089. Acesso em: 20 out. 2025.

ALLINSON, J. *et al*. The Scholarly Works Application Profile. **Ariadne**, n. 50, 30 jan. 2007. Disponível em: http://www.ariadne.ac.uk/issue/50/allinson-et-al/. Acesso em: 12 set. 2025.

ALVES, L. H. *et al*. Análise documental e sua contribuição no desenvolvimento da pesquisa científica. **Cadernos da Fucamp**, Monte Carmelo, v. 20, n. 43, p. 51-63, 2021. Disponível em: https://www.revistas.fucamp.edu.br/index.php/cadernos/article/view/2335/1440. Acesso em: 3 out. 2025.

ALVES, R. C. V. **Metadados como elementos do processo de catalogação.** 2010. Tese (Doutorado em Ciência da Informação) – Faculdade de Filosofia e Ciências, Universidade Estadual Paulista, Marília, 2010. Disponível em: https://repositorio.unesp.br/handle/11449/103361. Acesso em: 8 jul. 2022.

ARAKAKI, F. A. **Metadados administrativos e a proveniência dos dados:** modelo baseado na família PROV. 2019. Tese (Doutorado em Ciência da Informação) – Faculdade de Filosofia e Ciências, Universidade Estadual Paulista (UNESP), Marília, 2019. Disponível em: http://hdl.handle.net/11449/180490. Acesso em: 30 jul. 2026.

BACA, M. (ed). **Introduction to Metadata**. 3rd ed. Los Angeles: Getty Publications, 2016. Disponívem em: http://www.getty.edu/publications/intrometadata. Acesso em: 10 maio. 2024.

BAKER, T. What Terms Does Your Metadata Use? Application Profiles as Machine-Understandable Narratives. **Journal of Digital Information**, v. 2, n. 2, 2001. Disponível em: https://dcpapers.dublincore.org/files/articles/952106543/dcmi-952106543.pdf. Acesso em: 12 set. 2025.

BAPTISTA, D. M. O impacto dos metadados na representação descritiva. **Revista ACB: Biblioteconomia em Santa Catarina**, Florianópolis, SC, v. 12, n. 2, p. 177-190, jul./dez. 2007. Disponível em: https://dialnet.unirioja.es/descarga/articulo/5026073.pdf. Acesso em: 23 out. 2025.

BARKER, P. A.; CAMPBELL, L. M. Metadata for learning materials: an overview of existing standards and current developments. **Technology, Instruction, Cognition and Learning**, [*S. l.*], v. 7, n. 3-4, p. 225-243, 2010. Disponível em: https://researchportal.hw.ac.uk/en/publications/metadata-for-learning-materials-an-overview-of-existing-standards. Acesso em: 29 set. 2025.

BROWN, T. *et al*. Language models are few-shot learners. **Advances in neural information processing systems**, v. 33, p. 1877-1901, 2020. Disponível em: https://arxiv.org/pdf/2005.14165.pdf. Acesso em: 25 mar. 2024.

CANO, M. A. *et al*. Schema Playground: a tool for authoring, extending, and using metadata schemas to improve FAIRness of biomedical data. **BMC Bioinformatics**, [*S. l.*], v. 24, n. 1, 20 abr. 2023. DOI: 10.1186/s12859-023-05258-4. Disponível em: https://doi.org/10.1186/s12859-023-05258-4. Acesso em: 20 out. 2025.

CARDOSO, I. P. **Dados científicos e metadados:** estudo sobre o uso dos padrões de metadados no fluxo da informação científica sobre biodiversidade. 2020. 135 f. Dissertação (Mestrado em Ciência da Informação) – Faculdade de Ciência da Informação, Universidade de Brasília, Brasília, 2020. Disponível em: https://repositorio.unb.br/handle/10482/46034. Acesso em: 12 set. 2025.

CHOWDHERY, A. *et al* (ed.). **Palm: Scaling language modeling with pathways.** [*S. l.*]: arXiv:2204.02311 [cs. CL], 2022. Disponível em: https://arxiv.org/pdf/2204.02311.pdf. Acesso em: 25 abr. 2024.

COSTA, M. A. F. da; COSTA, M. de F. B. da. **Metodologia da pesquisa:** conceitos e técnicas. Rio de Janeiro: Interciência, 2001.

COX, A.; MAZUMDAR, S. Defining artificial intelligence for librarians. J**ournal of Librarianship and Information Science**. v. 56, n.2, p. 330-340, 2022. Disponível em: https://doi.org/10.1177/09610006221142029. Acesso em: 13 jul. 2024.

DANG, M.-H. *et al*. LLM4Schema.org: Generating Schema.org Markups with Large Language Models. **Semantic Web Journal**, v.16, n. 6, 2025. Disponível em: https://semantic-web-journal.net/system/files/swj3793.pdf. Acesso em: 22 out. 2025.

DAS, R.; ISLAM, M (ed.) **Application of Artificial Intelligence and Machine Learning in Libraries:** A Systematic Review. [*S. l.*]: ArXiv, abs/2112.04573, 2021. Disponível em: https://arxiv.org/pdf/2112.04573. Acesso em: 13 ago. 2024.

DATA SCIENCE ACADEMY. **Deep Learning Book.** [*S. l.*]: DSA, 2022. Disponível em <https://www.deeplearningbook.com.br/. Acesso em: 22 mar. 2024.

DUBLIN CORE METADATA INITIATIVE. **DCMI Metadata Terms**. 2020. Disponível em: https://www.dublincore.org/specifications/dublin-core/dcmi-terms/. Acesso em: 20 jul. 2026.

DUBLIN CORE METADATA INITIATIVE. **Glossary**. 2026. Disponível em: https://www.dublincore.org/resources/glossary/. Acesso em: 20 jul. 2026.

DUBLIN CORE METADATA INITIATIVE. **Guidelines for Dublin Core™ Application Profiles**. 2009. Disponível em: https://www.dublincore.org/specifications/dublin-core/profile-guidelines/. Acesso em: 12 set. 2025.

DUBLIN CORE METADATA INITIATIVE. **Interoperability Levels for Dublin Core™ Metadata**. 2008. Disponível em: https://www.dublincore.org/specifications/dublin-core/interoperability-levels/. Acesso em: 12 set. 2025.

ELECHKO, A. **How Consensus Works.** [*S. l.*]: Consensus Help Center, 2026. Disponível em: https://help.consensus.app/en/articles/9922673-how-consensus-works. Acesso em: 28 fev. 2026.

FERREIRA, N. S. de A. As Pesquisas Denominadas "Estado Da Arte". **Educação & Sociedade**, v. 23, n. 79, ago. 2002. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0101-73302002000300013&lng=pt&nrm=iso&tlng=pt. Acesso em: 26 jun. 2024.

FORMENTON, D. *et al*. Os padrões de metadados como recursos tecnológicos para a garantia da preservação digital. **Biblios**, Pittsburgh, n. 68, p. 82-95, jul. 2017. DOI: 10.5195/biblios.2017.414. Disponível em: http://www.scielo.org.pe/scielo.php?script=sci_arttext&pid=S1562-47302017000300006&lng=es&nrm=iso. Acesso em: 29 set. 2025.

FORMENTON, D.; GRACIOSO, L. de S. P. Padrões de metadados no arquivamento da web: recursos tecnológicos para a garantia da preservação digital de websites arquivados. **Revista Digital de Biblioteconomia e Ciência da Informação**, Campinas, SP, v. 20, e022001, 2022. DOI: 10.20396/rdbci.v20i00.8666263. Disponível em: https://doi.org/10.20396/rdbci.v20i00.8666263. Acesso em: 23 out. 2025.

FREITAG, R. Linguística para uma inteligência artificial (IA) brasileira. **Scielo em Perspectiva**, 2025. Disponível em: https://blog.scielo.org/blog/2025/07/18/linguistica-para-uma-inteligencia-artificial-ia-brasileira/. Acesso em: 29 set.2025.

FRICKÉ, Martin. **Artificial Intelligence and Librarianship.** 3. ed. [*S. l.*]: SoftOption, 2023. Disponível em: https://softoption.us/sites/default/files/AiinLibrariesNotesForTeaching.pdf. Acesso em: 26 abr. 2024.

GEMINI. **Deep Research do Gemini.** [*S. l.*]: Google, 2026. Disponível em: https://gemini.google/overview/deep-research/. Acesso em: 28 fev. 2026.

GIL, A. C. **Como elaborar projetos de pesquisa.** 4. ed. São Paulo: Atlas, 2002. Disponível em: https://files.cercomp.ufg.br/weby/up/150/o/Anexo_C1_como_elaborar_projeto_de_pesquisa_-_antonio_carlos_gil.pdf. Acesso em: 26 abr. 2024.

GILLILAND, A. J. Setting the stage. *In*: BACA, Murtha (ed.). **Introduction to Metadata**. 3. ed. Los Angeles: Getty Publications, 2016. Disponível em: http://www.getty.edu/publications/intrometadata/setting-the-stage/. Acesso em: 22 jul. 2026.

GO FAIR. **FAIR Principles**. 2026. Disponível em: https://www.go-fair.org/fair-principles/. Acesso em: 7 jul. 2026.

GOOGLE. **Comece a usar os Gems nas Apps Gemini**. 2025c. Disponível em: https://support.google.com/gemini/answer/15236321?hl=pt. Acesso em: 29 set. 2025.

GOOGLE. **Guia de início rápido do Google AI Studio.** 2025b. Disponível em: https://ai.google.dev/gemini-api/docs/ai-studio-quickstart?hl=pt-br. Acesso em: 29 set. 2025.

GOOGLE. **Guia para iniciantes sobre IA generativa.** 2025a. Disponível em: https://cloud.google.com/vertex-ai/generative-ai/docs/learn/overview?hl=pt-br. Acesso em: 29 set. 2025.

GOOGLE. **Model Cards Explained:** Simple, structured model information. Google, 2025d. Disponível em: https://modelcards.withgoogle.com/. Acesso em: 20 out. 2025.

GOOGLE. **Responsible AI Progress Report**. [*S. l.*]: Google, 2025e. Disponível em: https://ai.google/static/documents/ai-responsibility-update-published-february-2025.pdf. Acesso em: 24 out. 2025.

GREENBERG, J.; WU, M.; LIU, W.; LIU, F. Metadata as Data Intelligence. **Data Intelligence**, v. 5, n. 1, p. 1-5, 2023. Disponível em: https://doi.org/10.1162/dint_e_00212. Acesso em: 26 abr. 2024.

GUHA, R. V.; BRICKLEY, D.; MACBETH, S. **Schema.org: Evolution of Structured Data on the Web**. [*S. l.*]: ACM, 2016. Disponível em: https://cacm.acm.org/practice/schema-org/. Acesso em: 20 out. 2025.

HAYNES, D. **Metadata for Information Management and Retrieval**: understanding metadata and its use. 2. ed. London: Facet Publishing, 2018. Disponível em: https://www.facetpublishing.co.uk/page/detail/metadata-for-information-management-and-retrieval/?k=9781783302161. Acesso em: 22 jul. 2026.

HEERY, R.; PATEL, M. Application profiles: mixing and matching metadata schemas. **Ariadne**, n. 25, 2000. Disponível em: http://www.ariadne.ac.uk/issue/25/app-profiles/. Acesso em: 12 set. 2025.

HUGGING FACE. **Model Cards**. 2025. Disponível em: https://huggingface.co/docs/hub/model-cards. Acesso em: 24 out. 2025.

INTERNATIONAL CONFERENCE ON DUBLIN CORE AND METADATA APPLICATIONS (DC). **Metadata and ubiquitous access to Culture, Science, and Digital Humanities**. São Paulo: Dublin Core Metadata Initiative, 2015. Disponível em: https://dcevents.dublincore.org/public/dc-docs/2015-Master.pdf. Acesso em: 29 set. 2025.

JORDAN, M. I.; MITCHELL, T. M. Machine learning: Trends, perspectives, and prospects. **Science**, v. 349, n. 6245, p. 255-260, 2015. Disponível em: https://www.cs.cmu.edu/~tom/pubs/Science-ML-2015.pdf. Acesso em: 19 ago. 2024.

LEWIS, Patrick *et al.* (ed.). **Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks.** [*S. l.*]: arXiv:2005.11401, 2020. Disponível em: https://arxiv.org/pdf/2005.11401.pdf. Acesso em: 22 mar. 2024.

LIANG, W. *et al*. What's documented in AI? Systematic Analysis of 32K AI Model Cards. **arXiv:2402.05160v1 [cs.SE]** 7 Feb 2024, 2024. Disponível em: https://arxiv.org/pdf/2402.05160v1. Acesso em: 24 out. 2025.

LIU, W.; FU, Y.; LIU, Q. Metadata as a Methodological Commons: From Aboutness Description to Cognitive Modeling. **Data Intelligence**, v. 5, p. 289-302. 2023. Disponível em: https://doi.org/10.1162/dint_a_00189. Acesso em: 6 maio. 2024.

LONGPRE, S. *et al*. Data Authenticity, Consent, & Provenance for AI are all broken: what will it take to fix them? **arXiv:2404.12691v2 [cs.AI]** 30 Aug 2024, 2024. Disponível em: https://arxiv.org/pdf/2404.12691. Acesso em: 29 set. 2025.

MALTA, M. C. **Contributo metodológico para o desenvolvimento de perfis de aplicação de metadados no contexto da Web Semântica**. 2014. Tese (Doutorado em Tecnologias e Sistemas de Informação) – Escola de Engenharia, Universidade do Minho, Guimarães, 2014. Disponível em: https://repositorium.uminho.pt/entities/publication/fb31b1e6-4506-4f8b-887d-8d59077c96b4. Acesso em: 1 out. 2025.

MALTA, M. C.; BAPTISTA, A. A.; WALK, P. (ed.). **Developing Metadata Application Profiles**. Hershey, PA: IGI Global, 2017. Disponível em: https://www.igi-global.com/book/developing-metadata-application-profiles/172961. Acesso em: 12 set. 2025.

MALTA, M. C. **Me4MAP: A method for the development of metadata application profiles**. [*S. l.*]: Dublin Core Metadata Initiative, 2017. Disponível em: https://www.dublincore.org/webinars/2017/me4map_-_a_method_for_the_development_of_metadata_application_profiles/. Acesso em: 12 set. 2025.

MAYERNIK, M. S. Metadata. **KO Knowledge Organization**, v. 47, n. 8, p. 696-713, 2021. Disponível em: https://www.isko.org/cyclo/metadata. Acesso em: 26 abr. 2024.

MITCHELL, M. *et al*. Model Cards for Model Reporting. **arXiv:1810.03993v2 [cs.LG]** 14 Jan 2019, 2019. Disponível em: https://arxiv.org/pdf/1810.03993. Acesso em: 29 set. 2025.

NILSSON, M.; BAKER, T.; JOHNSTON, P. **The Singapore Framework for Dublin Core Application Profiles**. [*S. l.*]: DCMI Recommended Resource, 2008. Disponível em: http://dublincore.org/documents/singapore-framework/. Acesso em: 12 set. 2025.

NHACUONGUE, J. A.; FERNEDA, E. O campo da ciência da informação: contribuições, desafios e perspectivas. **Perspectivas em Ciência da Informação**, v. 20, n.2, p. 3–18. 2015. Disponível em: https://doi.org/10.1590/1981-5344/1932. Acesso em: 26 abr. 2024.

NÓBREGA-THERRIEN, S. M.; THERRIEN, J. Trabalhos científicos e o estado da questão. **Estudos em Avaliação Educacional**, v. 15, n. 30, p. 5, 30 dez. 2004. Disponível em: http://publicacoes.fcc.org.br/ojs/index.php/eae/article/view/2148. Acesso em: 26 jun. 2024.

OLIVEIRA, R. H. A. de; CASTRO, F. F. de; JESUS, A. F. de. O impacto do modelo IFLA Library Reference Model na prática catalográfica: casos de uso, vantagens e desvantagens. **Em Questão**, Porto Alegre, v. 27, n. 4, p. 359-386, out./dez. 2021. DOI: https://doi.org/10.19132/1808-5245274.359-386. Disponível em: O impacto do modelo IFLA Library Reference Model na prática catalográfica: casos de uso, vantagens e desvantagens | Em Questão. Acesso em: 26 jun. 2024.

OPENAI. **OpenAI developer platform documentantion**. 2024. Disponível em: https://platform.openai.com/docs/overview. Acesso em: 30 set. 2024.

OUTSYSTEMS. **About AI Agent Builder.** Disponível em: https://success.outsystems.com/documentation/outsystems_developer_cloud/building_apps/about_ai_agent_builder/. Acesso em: 25 out. 2024.

PATEL-SCHNEIDER, P. F. Analyzing Schema.org. In: MIKA, P. *et al*. **The Semantic Web – ISWC 2014.** [*S. l.*]: Springer Nature, 2014. DOI: 10.1007/978-3-319-11964-9_17. Disponível em: https://link.springer.com/chapter/10.1007/978-3-319-11964-9_17. Acesso em: 20 out. 2024.

PAYNE, K. Schema.org for research data managers: a primer. **Int. J. Big Data Management**, Vol. 2, No. 2, 2022. DOI: 10.1504/IJBDM.2022.128449. Disponível em: https://www.inderscienceonline.com/doi/abs/10.1504/IJBDM.2022.128449. Acesso em: 20 out. 2024.

PHILLIPS, P. J. *et al*. **Four Principles of Explainable Artificial Intelligence**. Gaithersburg, MD: National Institute of Standards and Technology, 2021. Disponível em: https://nvlpubs.nist.gov/nistpubs/ir/2021/nist.ir.8312.pdf. Acesso em: 1 out. 2025.

PINHEIRO, G. T. **Análise do funcionamento dos grandes modelos de linguagem e a produção de textos semelhantes aos humanos**. 2024. 12 f. Trabalho de Conclusão de Curso (Tecnólogo em Análise e Desenvolvimento de Sistemas) - Faculdade de Tecnologia de Presidente Prudente, Presidente Prudente, SP, 2024. Disponível em: https://ric.cps.sp.gov.br/bitstream/123456789/28860/1/ads_2024_2_guilhermetpinheiro_analisedofuncionamentodosgrandesmodelosdelinguagem.pdf. Acesso em: 29 set. 2025.

POMERANTZ, J. **Metadata**. Cambridge: The MIT Press, 2015. Disponível em: https://mitpress.mit.edu/9780262528511/metadata/. Acesso em: 22 jul. 2026.

PPGCI. **Linhas de Pesquisa PPGCI - Unesp Campus de Marília.** Disponível em: https://www.marilia.unesp.br/#!/pos-graduacao/mestrado-e-doutorado/ciencia-da-informacao/programa/linhas-de-pesquisa/. Acesso em: 26 jun. 2024.

QIN, J.; YU, B. Metadata in Trustworthy AI: from data quality to ML modeling. **Proc. Int'l Conf. on Dublin Core and Metadata Applications**, 2024. Disponível em: https://dcpapers.dublincore.org/files/articles/953354037/dcmi-953354037.pdf. Acesso em: 29 set. 2025.

RAO, P. S. B. *et al*. RiskRAG: A Data-Driven Solution for Improved AI Model Risk Reporting. *In*: CHI CONFERENCE ON HUMAN FACTORS IN COMPUTING SYSTEMS, 25., 2025, Nova Iorque. **Proceedings […]**. Nova Iorque: Association for Computing Machinery (ACM), 2025. Disponível em: https://dl.acm.org/doi/10.1145/3706598.3713979. Acesso em: 27 out. 2025.

RIDLEY, M. Explainable Artificial Intelligence (XAI). **Information Technology and Libraries**, [*S. l.*], v. 41, n. 2, jun. 2022. DOI: 10.6017/ital.v41i2.14683. Disponível em: https://www.researchgate.net/publication/361475613_Explainable_Artificial_Intelligence_XAI. Acesso em: 1 out. 2025.

RILEY, J. **Understanding metadata:** what is metadata, and what is it for? Baltimore: Niso Press, 2017. Diposnível em: https://www.niso.org/publications/understanding-metadata-2017. Acesso em: 6 maio. 2024.

RIVA, P.; LE BŒUF, P.; ŽUMER, M. **IFLA Library Reference Model:** um modelo conceitual para a informação bibliográfica. [*S. l.*]: IFLA, 2020. Disponível em: content. Acesso em: 5 out. 2025.

SÁ-SILVA, J. R.; ALMEIDA, C. D. de; GUINDANI, J. F. Pesquisa documental: pistas teóricas e metodológicas. **Revista Brasileira de História & Ciências Sociais**, v. 1, n. 1, p. 1-15, 2009. Disponível em: https://periodicos.furg.br/rbhcs/article/view/10351. Acesso em: 3 out. 2025.

SANT'ANA, R. C. G. Diagrama estrutural para teses e dissertações: uma proposta didática. *In*: MOREIRA, F. M.; *et al.* (org.). **Acesso a Dados e a Ciência da Informação:** aplicação, tendências e reflexões. Tupã: Faculdade de Ciências e Engenharia UNESP – Campus de Tupã, 2022. p. 330-345.

SCHEMA.ORG. **Documentation Schema.org**. 2025. Disponível em: https://schema.org/docs/documents.html. Acesso em: 20 out. 2025.

SHARIR, O; PELEG, B.; SHOHAM, Y. The cost of training nlp models: a concise overview. **arXiv:2004.08900v1 [cs.CL]** 19 Apr 2020, 2020. Disponível em: https://arxiv.org/pdf/2004.08900.pdf. Acesso em: 25 mar. 2024.

SILVA, G. C. da; CAZELLA, S. C. Large language model para geração de prontuários eletrônicos sintéticos. **Journal of Health Informatics**, [São Paulo], v. 16, n. Especial, 2024. Disponível em: https://jhi.sbis.org.br/index.php/jhi-sbis/article/download/1275/600. Acesso em: 29 set. 2025.

SIQUEIRA, M.; MOREIRA, F.; ALVES, R.; SANT'ANA, R. Transduções informacionais, Machine Learning e a inciência dos atores envolvidos. **Technological Innovations Journal**, [*S. l.*], v. 5, n. 2, p. 7–24, 2026. DOI: 10.35622/j.ti.2026.02.001. Disponível em: https://tijournal.science/index.php/tij/article/view/74. Acesso em: 14 abr. 2026.

SMITH, S. *et al*. Using deepspeed and Megatron to train Megatron-Turing NLG 530B, A Large-Scale Generative Language Model. **arXiv:2201.11990v3 [cs.CL]** 4 Feb 2022, 2022. Disponível em: https://arxiv.org/pdf/2201.11990.pdf. Acesso em: 28 mar. 2024.

SOUZA, M. I. F.; VENDRUSCULO, L. G.; MELO, G. C. Metadados para a descrição de recursos de informação eletrônica: utilização do padrão Dublin Core. **Ciência da Informação**, Brasília, DF, v. 29, n. 1, p. 93-102, jan./abr. 2000. DOI: 10.1590/S0100-19652000000100010. Disponível em: https://www.scielo.br/j/ci/a/tcW3q4WvNBQNTqTyLK8qfFF/?format=html&lang=pt. Acesso em: 1 out. 2025.

TENSORFLOW. **Model Card Toolkit**. 2025. Disponível em: https://www.tensorflow.org/responsible_ai/model_card_toolkit/guide?hl=pt-br. Acesso em: 27 out. 2025.

ULRICH, H. **Understanding the nature of metadata:** Systematic Review. **Journal of Medical Internet Research**, v. 24, n. 1, 2020. Disponível em: https://www.jmir.org/2022/1/e25440/PDF. Acesso em: 2 maio. 2024.

UNIÃO EUROPEIA. **Regulamento (UE) 2024/1689 do Parlamento Europeu e do Conselho, de 13 de junho de 2024**, que estabelece regras harmonizadas em matéria de inteligência artificial (Regulamento Inteligência Artificial) e que altera os Regulamentos (CE) n.º 300/2008, (UE) n.º 167/2013, (UE) n.º 168/2013, (UE) 2018/858, (UE) 2018/1139 e (UE) 2019/2144 e as Diretivas 2014/90/UE, (UE) 2016/797 e (UE) 2020/1828. **Jornal Oficial da União Europeia**: série L, Luxemburgo, 12 jul. 2024. Disponível em: http://data.europa.eu/eli/reg/2024/1689/oj. Acesso em: 6 maio. 2026.

VASWANI, A. *et al*. **Attention is all you need. arXiv:1706.03762v7 [cs.CL]** 2 Jun 2017, 2017. Disponível em: https://arxiv.org/pdf/1706.03762.pdf. Acesso em: 25 mar. 2024.

VENTURINI, F. C. Desafios epistemológicos, políticos e tecnológicos no uso de Inteligência Artificial em Humanidades e Ciências Sociais Aplicadas. **SciELO Preprints**, 2025. DOI: 10.1590/SciELOPreprints.12530. Disponível em: https://preprints.scielo.org/index.php/scielo/preprint/view/12530. Acesso em: 19 out. 2026.

VIDOTTI, S. A. B. G.; TORINO, E.; CONEGLIAN, C. S. #SejaJUSTOeCUIDADOSO: princípios FAIR e CARE na gestão de dados de pesquisa. *In*: SALES, L. F.; VEIGA, V. dos S.; HENNING, P.; SAYÃO, L. F. (org.). **Princípios FAIR aplicados à gestão de dados de pesquisa**. Rio de Janeiro: Ibict, 2021. p. 201 - 214. DOI: 10.22477/9786589167242. Disponível em: https://repositorio.utfpr.edu.br/jspui/bitstream/1/26914/10/principiosfairdadospesquisa.pdf. Acesso em: 27 jul. 2026.

WEI, J. *et al*. **Finetuned language models are zero-shot learners. arXiv:2109.01652v5 [cs.CL]** 8 Feb 2022, 2022. Disponível em: https://arxiv.org/pdf/2109.01652.pdf. Acesso em: 25 mar. 2024.

WU, M. *et al*. An Analysis of Crosswalks from Research Data Schemas to Schema.org. **Data Intelligence**, v. 5, n. 1, p. 100–121, 2023. DOI: 10.1162/dint_a_00186. Disponível em: https://direct.mit.edu/dint/article/5/1/100/113281/An-Analysis-of-Crosswalks-from-Research-Data. Acesso em: 20 out. 2025.

ZENG, M. L.; QIN, J. **Metadata**. 2. ed. Chicago: Neal-Schuman, 2016. Disponível em: https://www.alastore.ala.org/content/metadata-second-edition. Acesso em: 22 jul. 2026.

APÊNDICE A – APLICAÇÃO PRÁTICA E EXEMPLIFICAÇÃO DO MAP-CLLM EM UM CENÁRIO HIPOTÉTICO DA ÁREA DA NUTRIÇÃO

Este apêndice apresenta um exemplo prático de aplicação do *Metadata Application Profile for Custom Large Language Models* (MAP-CLLM). O propósito desta demonstração reside em ilustrar como a arquitetura conceitual e os instrumentos de representação da Ciência da Informação (CI) operacionalizam, no plano empírico, a descrição, a governança e a rastreabilidade de um *Large Language Model* (LLM) personalizado.

Salienta-se expressamente que o cenário, os dados, as instruções e os valores apresentados neste apêndice possuem caráter estritamente hipotético e simulado, desenhados para fins didáticos, analíticos e de apresentação do MAP proposto nesta pesquisa. Para esta simulação, considerou-se a concepção do "TiaNutri", um LLM personalizado hipotético concebido no domínio da nutrição clínica. O modelo foi projetado para atuar como um assistente de aconselhamento nutricional e suporte ao acompanhamento de pacientes, operando sob supervisão profissional e sem a prerrogativa de emitir diagnósticos clínicos ou prescrições dietéticas autônomas.

Para a construção do quadro 11, tomaram-se como diretrizes estruturais e semânticas os parâmetros definidos no quadro 9, *Description Set Profile* (DSP) para LLMs personalizados, desta tese. Os conteúdos, restrições e valores hipotéticos atribuídos às colunas foram alimentados a partir dos mapeamentos e exemplos apresentados no quadro 6, Dublin Core aplicado a um LLM personalizado e no quadro 7, Metadados determinados a partir dos *Model Cards* e ferramentas Google, mantendo-se fidelidade ao DSP proposto.

Quadro 11 – DSP de um LLM personalizado para a área de Nutrição (TiaNutri).

Elemento do MAP	Valor Preenchido (Instância)	Cardinalidade	Restrição de Valor
Entidade Obra (LRM-E2): Foco no Modelo de Base			
Model_Base	gemini-3-pro	1..1	Lista Controlada
Model_Provider	Google	1..1	Texto Livre; URI
Model_Docs	https:// storage.googleapis.co	1..1	URI

	m/deepmind-media/ Model-Cards/ Gemini-3-Pro-Model-Card.pdf		
Entidade Expressão (LRM-E3): Foco na Personalização do LLM			
Elemento do MAP	Valor Preenchido (Instância)	Cardinalidade	Restrição de Valor
Work_ID	a1b2c3d4-e5f6-7890-a1b2-c3d4e5f67890	1..1	UUID
Title	TiaNutri: Assistente de Aconselhamento Nutricional	1..1	Texto Livre DC.Title
Creator	Karina Siqueira; Marcos Siqueira	1..N	Texto Livre DC.Creator
Publisher	Karina Siqueira; Marcos Siqueira	1..N	Texto Livre; URI DC.Publisher
Contributor	Bárbara Silva; Maria Eduarda Silva	0..N	Texto Livre DC.Contributor
Description	LLM personalizado para apoio ao aconselhamento nutricional, suporte a planos alimentares e motivação de pacientes.	1..1	Texto Livre DC.Description
Subject	Nutrição Clínica; Aconselhamento Nutricional; IA Generativa; Educação Alimentar	1..N	Texto Livre; Vocabulário Controlado DC.Subject
Rights	http:// www.tianutri.com.br/	1..1	Texto Livre; URI

	termos		DC.Rights
Type	Large Language Model Personalizado	1..1	Texto Livre; Vocabulário Controlado DC.Type
Relation	http:// www.tianutri.com.br/ testes-v1; MAP-CLLM v1.0	1..N	Texto Livre; URI DC.Relation
Model_Version	1.0.1	1..1	Texto Semântico
Date	2026-07-27	1..1	ISO 8601 DC.Date
Customization_Strategy	Engenharia de Prompt Avançada (System Instruction); Geração Aumentada por Recuperação (RAG)	1..N	Texto Livre
Frameworks	Google AI Studio	1..N	Texto Livre
Response_Type	application/Texto	1..1	MIME Type
System_Instruction	Você é a TiaNutri, um LLM personalizado para a área de nutrição e bem-estar. Sua prioridade máxima é a segurança. Nunca diagnosticar ou prescrever dietas restritivas sem acompanhamento. Embase suas respostas em ciência e mantenha um tom empático.	1..1	Texto Livre
Temperature	0.3	0..1	Decimal

Top_P	0.85	0..1	Decimal
Top_K	30	0..1	Inteiro
Stop_Sequences	***; FIM_RESPOSTA; \n\n	0..N	Texto Livre
Source	Diretrizes Dietéticas SBAN 2025; DOI: 10.XXXX/jnutr.2023.12345; Acervo Clínico Interno	0..N	URI Referência Bibliográfica DC.Source
Thinking_Mode	Não	0..1	Booleano
Code_Execution	Não	0..1	Booleano
Function_Calling	consultar_agenda(data_solicitada)	0..N	Texto Livre
Safety_Settings_Level	harassment: BLOCK_MEDIUM_AND_ABOVE; hateSpeech: BLOCK_LOW_AND_ABOVE; dangerousContent: BLOCK_LOW_AND_ABOVE	0..N	Vocabulário Controlado
Entidade Manifestação (LRM-E4): Foco na Instância Técnica Acessível			
Elemento do MAP	Valor Preenchido (Instância)	Cardinalidade	Restrição de Valor
Expression_ID	b2c3d4e5-f6a7-8901-b2c3-d4e5f6a78901	1..1	UUID
Identifier	https://	1..1	URI/URL

	www.tianutri.com.br		DC.Identifier
Language	pt-BR	1..N	Padrão BCP 47 DC.Language
Format	text/html	1..1	Texto; MIME Type DC.Format
Input_Prompt_Tokens	30720	0..1	Inteiro
Max_Output_Tokens	2048	0..1	Inteiro
Use_Case_Domain	Saúde e Nutrição Clínica	1..N	Texto Livre
Target_User_Role	Nutricionista Clínico; Paciente em Acompanhamento	1..N	Texto Livre
Out_Of_Scope_Areas	Diagnóstico Médico ou Nutricional; Prescrição Farmacológica; Dietas de Emergência	1..N	Texto Livre
Safety_Tested	Sim	1..1	Booleano
Criticality_Level	Médio	1..1	Lista Controlada
Review_Frequency	3	1..1	Inteiro
Coverage_Temporal	2025-07-27/2026-10-27	1..1	ISO 8601 DC.Coverage
Coverage_Spatial	Brasil	1..1	Texto Livre; ISO 3166 DC.Coverage
Task_Type	Question Answering; Summarization; Text Generation	1..N	Lista Controlada

Use_Case_Type	Apoio ao Acompanhamento Nutricional e Educação Alimentar	1..1	Texto Livre
Entidade Item (LRM-E5): Foco na Interação Única (Prompt e Resposta)			
Elemento do MAP	Valor Preenchido (Instância)	Cardinalidade	Restrição de Valor
Manifestation_ID	c3d4e5f6-a7b8-9012-c3d4-e5f6a7b89012	1..1	UUID
Interaction_ID	d4e5f6a7-b8c9-0123-d4e5-f6a7b8c90123	1..1	UUID
Timestamp_Start	2026-07-27T14:30:00Z	1..1	ISO 8601
Timestamp_End	2026-07-27T14:30:05Z	1..1	ISO 8601
User_Input_Hash	e3b0c44298fc1c149afbf4c8996fb92427ae41e4649b934ca495991b7852b855	0..1	Hash String (SHA-256)
User_Input_Enc	U2FsdGVkX1+vGz8X1...	0..1	String Criptografada (AES-256)
LLM_Out_Hash	f4c8996fb92427ae41e4649b934ca495991b7852b855e3b0c44298fc1c149afb	0..1	Hash String (SHA-256)
LLM_Out_Enc	K8mB1j2fXsD2kL90k...	0..1	String Criptografada (AES-256)

Fonte: elaboração do autor com base nas especificações do MAP-CLLM.

Um análise detalhada do funcionamento prático, estrutura e utilidade do MAP-CLLM a partir da observação do quadro 11 permite demonstrar detalhadamente como o perfil de aplicação de metadados funciona na prática, explicitando a coerência interna de sua estrutura, o entrelaçamento de suas relações e sua utilidade direta frente ao problema da opacidade e da falta de padronização em LLMs personalizados.

A articulação estrutural e encadeamento hierárquico do *Library Reference Model* (LRM) desconstruiu a complexidade técnica do LLM personalizado "TiaNutri" em quatro camadas complementares, assegurando uma rastreabilidade semântica contínua:

1. **Camada de Obra (LRM-E2):** Mapeia a infraestrutura computacional de base. Ao registrar o Model_Base (gemini-3-pro), o Model_Provider (Google) e a documentação oficial (Model_Docs), o MAP-CLLM fixa a proveniência original do algoritmo, permitindo que auditores identifiquem instantaneamente as capacidades e vieses nativos do modelo primário.

2. **Camada de Expressão (LRM-E3):** Representa o núcleo do esforço intelectual de personalização. É nesta camada que os atores responsáveis (Creator e Publisher) registram as decisões que moldam o comportamento da máquina. O elemento System_Instruction explicita as regras de conduta da persona "TiaNutri", enquanto o parâmetro Temperature configurado em 0.3 reduz intencionalmente a aleatoriedade e o risco de alucinações, adequando a máquina ao rigor clínico necessário no ambiente de saúde. A inclusão das fontes documentais no elemento Source garante a explicabilidade da base informacional utilizada pela técnica RAG.

3. **Camada de Manifestação (LRM-E4):** Descreve a aplicação web comercialmente implantada com um Identifier (https://www.tianutri.com.br). Esta camada explicita aos usuários e aos órgãos reguladores as condições operacionais do serviço. A presença obrigatória dos elementos Out_Of_Scope_Areas, Criticality_Level (Médio) e Coverage_Spatial (Jurisdição do Conselho Federal de Nutricionistas) estabelece limites éticos e jurídicos claros, prevenindo o uso inadequado do sistema.

4. **Camada de Item (LRM-E5):** Captura a transação conversacional atômica e irrepetível. Para equacionar a exigência de governança com o respeito à privacidade dos dados de saúde dos pacientes, o MAP-CLLM utiliza hashes criptográficos (SHA-256) e cifragem (AES-256) nos elementos de entrada e saída (User_Input_Hash e LLM_Out_Enc). Essa estrutura permite auditar a integridade das interações em processos de investigação sem expor o conteúdo sigiloso das consultas.

Quanto a relações e integração de padrões, o quadro 11 demonstra visualmente a eficácia da abordagem híbrida do MAP-CLLM. A interoperabilidade básica com repositórios e motores de busca globais é viabilizada pela presença dos 15 elementos universais do *Dublin Core*. Paralelamente, os parâmetros específicos da Inteligência Artificial Generativa, derivados do framework *Model Cards* e do resultado da análise documental de ferramentas de personalização de LLMs, como System_Instruction, Temperature e Safety_Settings_Level, conferem a densidade descritiva que a Ciência da Computação exige. Por fim, ao associar a cada elemento o seu mapeamento equivalente no vocabulário Schema.org, conforme sistematizado no Quadro 10, o perfil viabiliza a geração automatizada de anotações JSON-LD, transformando o registro de metadados em um artefato acionável por máquina.

Sobre a utilidade do MAP-CLLM frente ao problema investigado, a falta de padronização documental e a opacidade funcional dos LLMs personalizados, a instanciação do quadro 11, permite uma análise em em três dimensões pragmáticas:

1. **Explicabilidade Contextual:** Diferente de soluções puramente algorítmicas de *Explainable AI* (XAI), que tentam explicar matematicamente pesos de rede neural inacessíveis ao usuário leigo, o MAP-CLLM oferece uma explicabilidade baseada em metadados. O nutricionista ou paciente que interage com o "TiaNutri" pode compreender exatamente quem concebeu o modelo, quais diretrizes éticas foram impostas e quais fontes científicas fundamentam suas respostas.

2. **Governança e Mitigação de Riscos:** A obrigatoriedade de registrar campos como Out_Of_Scope_Areas, Safety_Tested e Review_Frequency força o personalizador a refletir e formalizar as limitações de sua criação antes de disponibilizá-la ao público, atuando como um mecanismo de controle de qualidade informacional.

3. **Reprodutibilidade e Auditabilidade:** A preservação literal da System_Instruction, acompanhada dos parâmetros numéricos exatos como Temperature, Top_P e Top_K, fornece os subsídios necessários para que outros pesquisadores ou curadores de informação possam reconstituir a lógica de personalização, avaliar sua consistência ou realizar auditorias éticas.

A elaboração e análise do quadro 11 confirmam a hipótese defendida nesta tese. A demonstração prática evidencia que os conceitos, modelos e métodos consolidados pela Ciência da Informação, historicamente aplicados ao tratamento de recursos bibliográficos e documentais, possuem aderência e eficácia para a representação de objetos informacionais complexos, como os modelos de Inteligência Artificial Generativa personalizados.

A conversão da estrutura conceitual do MAP-CLLM presente no *Description Set Profile* (DSP) para o LLM personalizado "TiaNutri" confere aplicabilidade, verificabilidade e clareza operacional à tese. Demonstra-se que a estruturação padronizada de metadados não representa um simples encargo burocrático, mas constitui uma infraestrutura que contribui para a transparência, interoperabilidade e governança confiável dos LLMs personalizados.

Este exemplo prático de aplicação do *Metadata Application Profile for Custom Large Language Models* (MAP-CLLM) materializado no quadro 11, ratifica o papel estratégico do profissional e do cientista da informação como arquitetos de metadados em ecossistemas tecnológicos complexos. Ao prover uma ponte metodológica entre as especificações computacionais e os requisitos sociais de transparência e confiabilidade, o MAP-CLLM oferece uma contribuição teórico-prática relevante para a Ciência da Informação e para a promoção de uma Inteligência Artificial confiável e orientada ao bem comum.