



UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA

Otávio Lube dos Santos

**Framework para Construção de Sistemas
Multiagentes Inteligentes em Ecossistemas de
Aprendizagem**

Vitória, ES

2025

Otávio Lube dos Santos

Framework para Construção de Sistemas Multiagentes Inteligentes em Ecossistemas de Aprendizagem

Tese de Doutorado submetida ao Programa de Pós-Graduação em Informática da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do Grau de Doutor em Ciência da Computação.

Universidade Federal do Espírito Santo – UFES

Centro Tecnológico

Programa de Pós-Graduação em Informática

Orientador: Prof. Dr. Davidson Cury

Vitória, ES

2025

Otávio Lube dos Santos

Framework para Construção de Sistemas Multiagentes Inteligentes em Ecossistemas de Aprendizagem/ Otávio Lube dos Santos. – Vitória, ES, 2025-
88 p. : il. (algumas color.) ; 30 cm.

Orientador: Prof. Dr. Davidson Cury

Tese de Doutorado – Universidade Federal do Espírito Santo – UFES
Centro Tecnológico
Programa de Pós-Graduação em Informática, 2025.

1. Sistemas Multiagentes. 2. Ecossistemas de Aprendizagem. 3. Framework. 4. Ontologia. 5. Inteligência Artificial Generativa. I. Cury, Davidson. II. Universidade Federal do Espírito Santo. IV. Framework para Construção de Sistemas Multiagentes Inteligentes em Ecossistemas de Aprendizagem

CDU 004.8:37.01

Otávio Lube dos Santos

Framework para Construção de Sistemas Multiagentes Inteligentes em Ecosystemas de Aprendizagem

Tese de Doutorado submetida ao Programa de Pós-Graduação em Informática da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do Grau de Doutor em Ciência da Computação.

Trabalho em avaliação. Vitória, ES, 7 de maio de 2025:

Prof. Dr. Davidson Cury
Orientador

Prof. Dr. Crediné Silva de Menezes
Universidade Federal do Rio Grande do Sul

Prof. Dr. Alberto Nogueira de Castro Junior
Universidade Federal do Amazonas

Vitória, ES
2025

Aos meus pais, pelo apoio incondicional em todos os momentos da minha vida.

À minha esposa, pelo amor, paciência e compreensão durante esta jornada.

Às minhas filhas, fonte de inspiração e motivação constante.

Agradecimentos

Agradeço primeiramente a Deus, por me conceder saúde, força e determinação para concluir esta etapa tão importante da minha vida acadêmica.

Ao meu orientador, Prof. Dr. Davidson Cury, pela confiança, orientação precisa e pelo constante incentivo durante todo o desenvolvimento deste trabalho. Seus ensinamentos transcenderam o âmbito acadêmico e serão levados para toda a vida.

Ao meu coorientador, Prof. Dr. Sávio Silveira de Queiroz, pelas valiosas contribuições e pelo olhar crítico que tanto enriqueceu esta pesquisa.

Aos professores do Programa de Pós-Graduação em Informática da UFES, pelos conhecimentos compartilhados e pelas discussões enriquecedoras que contribuíram significativamente para minha formação.

Aos colegas do Laboratório de Informática na Educação (LIED), pelo companheirismo, troca de experiências e pelos momentos de descontração que tornaram esta jornada mais leve.

À Universidade Federal do Espírito Santo, pela oportunidade de realizar este doutorado e por proporcionar um ambiente acadêmico de excelência.

À CAPES, pelo apoio financeiro que viabilizou a realização desta pesquisa.

Aos meus pais, pelo amor incondicional e por sempre acreditarem no meu potencial, mesmo nos momentos mais difíceis.

À minha esposa, pelo amor, compreensão e apoio constante durante todo este percurso. Sua presença foi fundamental para que eu pudesse me dedicar a este trabalho.

Às minhas filhas, que mesmo sem compreender completamente a dimensão deste trabalho, souberam respeitar meus momentos de ausência e me proporcionaram momentos de alegria que renovavam minhas energias.

Aos amigos que, de perto ou de longe, acompanharam esta trajetória e sempre tiveram palavras de incentivo.

A todos que, direta ou indiretamente, contribuíram para a realização deste trabalho, meu sincero agradecimento.

“A educação é a arma mais poderosa que você pode usar para mudar o mundo.”
(Nelson Mandela)

Resumo

Ecosistemas de Aprendizagem (EAs) representam ambientes complexos e dinâmicos onde múltiplos atores, recursos e tecnologias interagem para apoiar a aprendizagem. Sistemas Multiagentes (MAS), especialmente aqueles potencializados por Inteligência Artificial (IA) Generativa, oferecem um paradigma promissor para criar componentes inteligentes e adaptativos dentro desses ecossistemas. No entanto, a construção desses MAS apresenta desafios significativos, e faltam abordagens metodológicas que guiem sistematicamente seu desenvolvimento no contexto específico de EAs. Esta tese aborda essa lacuna propondo o Framework para Construção de Sistemas Multiagentes Inteligentes em Ecosistemas de Aprendizagem (FC-MAS-EA). O FC-MAS-EA é um framework conceitual, fundamentado na metodologia Design Science Research (DSR), que estrutura o processo de construção de MAS em cinco fases principais: Análise e Requisitos, Design do MAS, Design dos Agentes, Implementação e Integração/Implantação. Crucialmente, o framework é embasado em uma extensão da Ontologia para Ecosistemas de Aprendizagem na Cultura Digital (OEACD), denominada OEACD-MAS, que incorpora conceitos fundamentais de MAS (e.g., Agente, Capacidade, Organização, Interação) para fornecer um vocabulário semântico compartilhado e garantir o alinhamento entre o MAS e o EA. O FC-MAS-EA posiciona-se como complementar a frameworks existentes focados no design do ecossistema, concentrando-se na instanciación dos componentes inteligentes como MAS. A aplicabilidade e flexibilidade do framework são demonstradas através de sua aplicação (real ou simulada) em dois estudos de caso distintos: LIEd Ubíquo (foco em recomendação) e GoodBot (foco em suporte conversacional com IA Generativa). Uma avaliação inicial, baseada na análise reflexiva desses estudos de caso, indica que o FC-MAS-EA oferece um guia útil e sistemático, promove o alinhamento ontológico e acomoda diferentes tipos de MAS e tecnologias. As contribuições da tese incluem a extensão ontológica OEACD-MAS, o framework metodológico FC-MAS-EA e a demonstração/avaliação inicial de sua utilidade. Limitações e trabalhos futuros, incluindo a necessidade de validação mais ampla e o desenvolvimento de ferramentas de apoio, são discutidos.

Palavras-chave: Sistemas Multiagentes. Ecosistemas de Aprendizagem. Framework. Ontologia. Inteligência Artificial Generativa. Engenharia de Software. Educação.

Abstract

Learning Ecosystems (LEs) represent complex and dynamic environments where multiple actors, resources, and technologies interact to support learning. Multi-Agent Systems (MAS), especially those enhanced by Generative Artificial Intelligence (AI), offer a promising paradigm for creating intelligent and adaptive components within these ecosystems. However, building such MAS presents significant challenges, and there is a lack of methodological approaches that systematically guide their development in the specific context of LEs. This thesis addresses this gap by proposing the Framework for Building Intelligent Multi-Agent Systems in Learning Ecosystems (FC-MAS-EA). FC-MAS-EA is a conceptual framework, grounded in the Design Science Research (DSR) methodology, that structures the MAS construction process into five main phases: Analysis and Requirements, MAS Design, Agent Design, Implementation, and Integration/Deployment. Crucially, the framework is based on an extension of the Ontology for Learning Ecosystems in the Digital Culture (OEACD), named OEACD-MAS, which incorporates fundamental MAS concepts (e.g., Agent, Capability, Organization, Interaction) to provide a shared semantic vocabulary and ensure alignment between the MAS and the LE. FC-MAS-EA positions itself as complementary to existing frameworks focused on ecosystem design, concentrating on the instantiation of intelligent components as MAS. The framework's applicability and flexibility are demonstrated through its application (real or simulated) in two distinct case studies: LIEd Ubíquo (focused on recommendation) and GoodBot (focused on conversational support with Generative AI). An initial evaluation, based on the reflective analysis of these case studies, indicates that FC-MAS-EA offers a useful and systematic guide, promotes ontological alignment, and accommodates different types of MAS and technologies. The thesis contributions include the OEACD-MAS ontological extension, the FC-MAS-EA methodological framework, and the initial demonstration/evaluation of its utility. Limitations and future work, including the need for broader validation and the development of supporting tools, are discussed.

Keywords: Multi-Agent Systems. Learning Ecosystems. Framework. Ontology. Generative Artificial Intelligence. Software Engineering. Education.

Lista de ilustrações

Figura 1 – Sub-ontologia Educational Environment (SEE) em OntoUML (SILVEIRA, 2022).	30
Figura 2 – Sub-ontologia Pedagogical Architecture (SPA) em OntoUML (SILVEIRA, 2022).	31
Figura 3 – Sub-ontologia Learning Ecosystem on Digital Culture (SLEDC)	32
Figura 4 – Diagrama de fluxo PRISMA do processo de seleção dos estudos para o mapeamento.	41
Figura 5 – Distribuição dos estudos selecionados por tipo de pesquisa.	43
Figura 6 – Distribuição dos estudos selecionados por tópico ou objetivo educacional.	44
Figura 7 – Distribuição temporal dos estudos selecionados.	46
Figura 8 – Extensão OEACD-MAS: Modelagem dos conceitos centrais de Agente e MAS. (Referenciar Capítulo 2 para diagramas base da OEACD).	54
Figura 9 – Extensão OEACD-MAS: Modelagem dos conceitos de Organização, Interação e a especialização para Agentes com Capacidades Generativas.	54
Figura 10 – Módulo de Aprendiz da Ontologia para Ecossistemas Cognitivos.	56
Figura 11 – Módulo de Avaliação da Ontologia para Ecossistemas Cognitivos.	57
Figura 12 – Módulo de Feedback da Ontologia para Ecossistemas Cognitivos.	58
Figura 13 – Ontologia para Ecossistemas Cognitivos no Protégé.	58
Figura 14 – Fases do Processo de Construção Guiado pelo FC-MAS-EA.	63

Lista de tabelas

Tabela 1 – Estudos Primários Seleccionados no Mapeamento Sistemático da Literatura 85

Lista de abreviaturas e siglas

ABNT	Associação Brasileira de Normas Técnicas
AI	Artificial Intelligence (Inteligência Artificial)
API	Application Programming Interface
BDI	Belief-Desire-Intention
CASE	Computer-Aided Software Engineering
DSR	Design Science Research
EA	Ecossistema de Aprendizagem
FC-MAS-EA	Framework para Construção de Sistemas Multiagentes Inteligentes em Ecossistemas de Aprendizagem
FIPA	Foundation for Intelligent Physical Agents
GAN	Generative Adversarial Network
GPT	Generative Pre-trained Transformer
IA	Inteligência Artificial
IAG	Inteligência Artificial Generativa
IDE	Integrated Development Environment
JADE	Java Agent Development Framework
LLM	Large Language Model (Grande Modelo de Linguagem)
LGPD	Lei Geral de Proteção de Dados Pessoais
LIED	Laboratório de Informática na Educação
MAS	Multi-Agent System (Sistema Multiagente)
ML	Machine Learning (Aprendizado de Máquina)
NEMO	Núcleo de Excelência em Engenharia de Software e Sistemas de Informação

NLP	Natural Language Processing (Processamento de Linguagem Natural)
OEACD	Ontologia para Ecossistemas de Aprendizagem na Cultura Digital
OEACD-MAS	Extensão da OEACD para Sistemas Multiagentes
PLN	Processamento de Linguagem Natural
PoC	Proof of Concept (Prova de Conceito)
PPGI	Programa de Pós-Graduação em Informática
SABiO	Systematic Approach for Building Ontologies
SLE	Smart Learning Environment (Ambiente Inteligente de Aprendizagem)
SPADE	Smart Python Agent Development Environment
TCC	Terapia Cognitivo-Comportamental
UFO	Unified Foundational Ontology
UFES	Universidade Federal do Espírito Santo

Sumário

	Lista de ilustrações	9
	Lista de tabelas	10
	Sumário	13
1	INTRODUÇÃO	17
1.1	Problema de Pesquisa	17
1.2	Motivação e Justificativa	18
1.3	Objetivos	19
1.3.1	Objetivo Geral	19
1.3.2	Objetivos Específicos	19
1.4	Hipótese	20
1.5	Metodologia de Pesquisa	20
1.5.1	Design Science Research (DSR)	20
1.6	Etapa 1: Extensão da Ontologia OEACD (OEACD-MAS)	22
1.7	Etapa 2: Desenvolvimento do Framework FC-MAS-EA	22
1.8	Etapa 3: Demonstração via Estudos de Caso	23
1.9	Etapa 4: Avaliação do Framework	24
1.10	Coleta e Análise de Dados	25
1.11	Contribuições Esperadas	26
1.12	Organização do Trabalho	26
2	FUNDAMENTAÇÃO TEÓRICA	28
2.1	Ecosistemas de Aprendizagem na Cultura Digital	28
2.2	Ontologia para Ecosistemas de Aprendizagem na Cultura Digital (OE-ACD)	29
2.3	Sistemas Multiagentes (MAS)	31
2.3.1	Agentes: Definição e Propriedades	31
2.3.2	Arquiteturas de Agentes	33
2.3.3	Comunicação, Interação e Coordenação	33
2.4	Inteligência Artificial Generativa e seu Papel em Agentes	34
2.4.1	Tecnologias Subjacentes: Transformers e LLMs	34
2.4.2	Integrando Capacidades Generativas em Agentes Inteligentes	35

2.4.3	Desafios e Considerações Éticas	35
2.5	MAS, Agentes Inteligentes e IA Generativa na Educação	36
3	MAPEAMENTO SISTEMÁTICO DA LITERATURA: MAS INTELIGENTES COM IA GENERATIVA NA EDUCAÇÃO	38
3.1	Introdução	38
3.2	Metodologia do Mapeamento	38
3.2.1	Questões de Mapeamento	39
3.2.2	Estratégia de Busca	39
3.2.3	Critérios de Inclusão e Exclusão	40
3.2.4	Processo de Seleção e Extração de Dados	41
3.2.5	Síntese e Classificação dos Dados	41
3.3	Resultados do Mapeamento	42
3.3.1	QM1: Tipos de Pesquisa	42
3.3.2	QM2: Tópicos e Objetivos Educacionais	42
3.3.3	QM3: Arquiteturas de Agentes e Técnicas de IAG	43
3.3.4	QM4: Tipos de Contribuição	44
3.3.5	QM5: Evolução Temporal	45
3.3.6	QM6: Lacunas de Pesquisa e Direções Futuras	45
3.4	Discussão	47
3.5	Conclusão do Mapeamento	48
4	OEACD-MAS: UMA ONTOLOGIA ESTENDIDA PARA SISTEMAS MULTIAGENTES EM ECOSSISTEMAS DE APRENDIZAGEM COM FOCO EM AGENTES GENERATIVOS	49
4.1	Justificativa e Objetivos da Extensão	49
4.2	Metodologia de Extensão	50
4.3	Proposta de Conceitos e Relações na OEACD-MAS	50
4.3.1	Conceitos Centrais de MAS	50
4.3.2	Subontologia de Agentes com Capacidades Generativas (LLMs)	51
4.3.3	Conceitos de Comportamento e Raciocínio (Expandido)	53
4.3.4	Conceitos de Organização e Interação (Expandido)	53
4.3.5	Integração com OEACD	54
4.4	Fundamentação Adicional: Uma Ontologia para Ecossistemas Cognitivos	54
4.4.1	Introdução à Ontologia para Ecossistemas Cognitivos	55
4.4.2	Objetivos da Ontologia para Ecossistemas Cognitivos	55
4.4.3	Módulos da Ontologia para Ecossistemas Cognitivos	55

4.4.3.1	Módulo de Domínio	55
4.4.3.2	Módulo de Aprendiz	56
4.4.3.3	Módulo de Avaliação	57
4.4.3.4	Módulo de Feedback	57
4.4.4	Implementação da Ontologia para Ecossistemas Cognitivos	58
4.4.5	Avaliação da Ontologia para Ecossistemas Cognitivos	58
4.4.6	Uso da Ontologia para Ecossistemas Cognitivos no Framework	58
4.5	Validação Preliminar da OEACD-MAS Expandida	59
4.6	Considerações Finais do Capítulo	60
5	FC-MAS-EA: FRAMEWORK PARA CONSTRUÇÃO DE MAS INTE-	
	LIGENTES EM ECOSSISTEMAS DE APRENDIZAGEM	61
5.1	Visão Geral e Princípios	61
5.2	Fundamentação Ontológica: O Papel da OEACD-MAS	62
5.3	Arquitetura Conceitual do Framework	63
5.4	Processo de Construção Guiado pelo FC-MAS-EA	63
5.4.1	Fase 1: Análise e Requisitos	63
5.4.2	Fase 2: Design do MAS	64
5.4.3	Fase 3: Design dos Agentes	65
5.4.4	Fase 4: Implementação	66
5.4.5	Fase 5: Integração e Implantação	66
5.5	Complementaridade com o Framework de Silveira (2022)	67
6	EDUCATIONAL MULTI AGENT SYSTEMS BUILDER	69
6.1	EMASB: Plataforma para Construção de Sistemas Multiagentes Edu-	
	cacionais	69
6.1.1	Arquitetura e Ambiente do EMASB	69
6.1.2	Implicações do EMASB para a Validação do Framework FC-MAS-EA	71
6.2	GoodBot: Uma Prova de Conceito Desenvolvida com EMASB	72
6.2.1	Integração Potencial ao LIED Ubíquo	72
6.3	Avaliação do Ambiente EMASB por Professores	73
6.4	Considerações sobre a Avaliação do Framework	74
7	CONCLUSÃO E PERSPECTIVAS FUTURAS	75
7.1	Síntese do Trabalho	75
7.2	Principais Contribuições	76
7.3	Resposta às Questões de Pesquisa e Verificação da Hipótese	76
7.4	Status Atual do Projeto e Cronograma de Fechamento	77

7.5	Limitações	77
7.6	Trabalhos Futuros	78
7.7	Considerações Finais	79
	REFERÊNCIAS	80
	APÊNDICES	84
	APÊNDICE A – APÊNDICE B – ESTUDOS DO MSL	85

1 Introdução

A era digital transformou profundamente a sociedade e, conseqüentemente, a educação. A ubiquidade da tecnologia e a vasta quantidade de informações disponíveis online criaram um cenário onde a aprendizagem transcende os limites físicos e temporais da sala de aula tradicional. Nesse contexto, emerge o conceito de Ecossistemas de Aprendizagem (EA), que reconhece a aprendizagem como um processo contínuo, distribuído e socialmente construído, ocorrendo em múltiplos contextos formais, não formais e informais, mediados ou não por tecnologia ([SILVEIRA, 2022](#)).

Para potencializar esses ecossistemas, torna-se crucial o desenvolvimento de ambientes de aprendizagem mais inteligentes, adaptativos e personalizados, capazes de atender às necessidades individuais dos aprendizes e fomentar interações significativas. Os Smart Learning Environments (SLEs) buscam responder a essa demanda, integrando tecnologias avançadas para criar experiências educacionais mais eficazes ([SPECTOR, 2016](#); [HWANG, 2014](#)). Dentro dos SLEs e EAs, os Sistemas Multiagentes (MAS) surgem como uma abordagem promissora. MAS são sistemas compostos por múltiplos agentes computacionais autônomos que interagem entre si e com o ambiente para resolver problemas complexos ou atingir objetivos comuns ([WOOLDRIDGE, 2009](#)). Sua capacidade de distribuir tarefas, adaptar-se a mudanças e exibir comportamentos sociais os torna particularmente adequados para modelar e apoiar as dinâmicas complexas dos Ecossistemas de Aprendizagem.

Recentemente, o advento da Inteligência Artificial (IA) Generativa, impulsionado por modelos como os Large Language Models (LLMs) baseados na arquitetura Transformer ([VASWANI et al., 2017](#)), abriu novas fronteiras para a criação de agentes inteligentes com capacidades avançadas de compreensão de linguagem natural, diálogo, geração de conteúdo e até mesmo raciocínio ([OPENAI, 2023](#); [Gemini Team; Google, 2023](#)). A integração de IA Generativa em MAS educacionais oferece um potencial sem precedentes para criar agentes tutores, mentores, colaboradores e de suporte psicossocial mais sofisticados e eficazes.

1.1 Problema de Pesquisa

Apesar do potencial evidente dos MAS inteligentes em EAs, a sua concepção e construção apresentam desafios significativos. A complexidade inerente aos MAS, a necessidade de alinhá-los às especificidades pedagógicas e contextuais dos EAs, e a integração de tecnologias emergentes como a IA Generativa carecem de abordagens sistemáticas e bem fundamentadas.

A literatura existente frequentemente foca em aspectos específicos, como algoritmos de recomendação, arquiteturas de agentes isoladas ou frameworks para o **design** do ecossistema em si, como o trabalho de (SILVEIRA, 2022) que propõe um framework conceitual para a concepção de SLEs em EAs, fundamentado na ontologia OEACD.

Contudo, percebe-se uma lacuna no que diz respeito a um guia metodológico robusto e conceitualmente embasado que oriente especificamente o processo de **construção** dos Sistemas Multiagentes que irão operar nesses ecossistemas. Falta um framework que conecte a modelagem conceitual do EA (provida pela OEACD) com o design e a implementação dos agentes e do MAS como um todo, considerando suas arquiteturas, capacidades (incluindo as generativas) e interações.

Diante disso, a questão central que norteia esta pesquisa é: **como guiar sistematicamente a concepção e construção de Sistemas Multiagentes inteligentes, incluindo aqueles baseados em IA Generativa, de forma que sejam flexíveis, adaptáveis e eficazes para operar em Ecossistemas de Aprendizagem?**

1.2 Motivação e Justificativa

A motivação para esta pesquisa reside no potencial transformador dos MAS inteligentes para a educação. A capacidade de criar agentes especializados que podem atuar como tutores personalizados, recomendadores de conteúdo e interações, facilitadores de colaboração, avaliadores formativos e até mesmo como suporte ao bem-estar dos estudantes (SANTOS; CURY, 2024b) representa uma oportunidade única para enriquecer os Ecossistemas de Aprendizagem.

A construção desses sistemas, no entanto, é complexa. Requer a integração de conhecimentos de diversas áreas, como MAS, IA (incluindo IA Generativa), Informática na Educação e Engenharia de Software. A ausência de um framework dedicado a guiar esse processo pode levar a desenvolvimentos ad-hoc, dificuldades na reutilização de componentes, falta de alinhamento com os princípios pedagógicos e ontológicos do EA, e desafios na avaliação e manutenção desses sistemas.

Esta tese justifica-se pela necessidade de prover uma abordagem mais estruturada e conceitualmente sólida para a construção de MAS em EAs. Ao propor o Framework para Construção de Sistemas Multiagentes Inteligentes em Ecossistemas de Aprendizagem (FC-MAS-EA), busca-se preencher a lacuna identificada na literatura. Este framework se posiciona como complementar ao trabalho de Silveira (SILVEIRA, 2022), que foca no design do ecossistema. Enquanto o framework de Silveira ajuda a definir o **quê** e **onde** (a estrutura

e os componentes do SLE no EA), o FC-MAS-EA proposto aqui visa guiar **como construir os habitantes inteligentes** (os agentes e o MAS) desse ecossistema, fundamentando-se em uma extensão da ontologia OEACD para incluir os conceitos específicos de MAS.

1.3 Objetivos

1.3.1 Objetivo Geral

O objetivo geral desta tese é **propor um framework conceitual, denominado FC-MAS-EA, para guiar a construção de Sistemas Multiagentes inteligentes, incluindo aqueles que utilizam IA Generativa, para operar de forma eficaz e flexível em Ecossistemas de Aprendizagem.**

1.3.2 Objetivos Específicos

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

1. **Analisar e estender a Ontologia para Ecossistemas de Aprendizagem na Cultura Digital (OEACD)** ([SILVEIRA, 2022](#)), incorporando conceitos essenciais para a modelagem e construção de Sistemas Multiagentes (e.g., arquitetura de agente, capacidade do agente, comunicação, organização MAS), resultando na ontologia OEACD-MAS.
2. **Desenvolver o framework conceitual FC-MAS-EA**, detalhando seus componentes, princípios e o processo metodológico que ele propõe para a construção de MAS em EAs, utilizando a OEACD-MAS como base conceitual.
3. **Aplicar o framework FC-MAS-EA na construção (ou reengenharia) de dois Sistemas Multiagentes distintos** – LIEd Ubíquo ([SILVEIRA, 2022](#)) e GoodBot ([SANTOS; CURY, 2024b](#)) – como estudos de caso, a fim de demonstrar a aplicabilidade e a flexibilidade do framework em diferentes contextos e tipos de agentes (recomendação vs. diálogo generativo).
4. **Avaliar a utilidade e a aplicabilidade do framework FC-MAS-EA** com base na análise reflexiva dos estudos de caso, verificando como ele guiou o processo de construção e se atendeu aos requisitos de flexibilidade e sistematicidade.

1.4 Hipótese

A hipótese central desta pesquisa é que **um framework conceitual (FC-MAS-EA), fundamentado em uma ontologia estendida do domínio de Ecossistemas de Aprendizagem que inclui conceitos de MAS (OEACD-MAS), pode guiar sistematicamente a concepção e construção de Sistemas Multiagentes inteligentes e flexíveis, incluindo aqueles baseados em IA Generativa, que sejam adequados para operar e enriquecer Ecossistemas de Aprendizagem.**

1.5 Metodologia de Pesquisa

Este trabalho adota a metodologia de pesquisa **Design Science Research (DSR)** (HEVNER et al., 2004). A DSR é apropriada para esta pesquisa, pois visa criar e avaliar artefatos de TI inovadores (neste caso, a ontologia estendida OEACD-MAS e o framework FC-MAS-EA) para resolver problemas relevantes do mundo real (a construção complexa de MAS para EAs). O ciclo DSR será aplicado iterativamente, envolvendo a identificação do problema, a definição dos objetivos da solução, o design e desenvolvimento dos artefatos, a demonstração de sua aplicação através dos estudos de caso, a avaliação dos artefatos e a comunicação dos resultados.

1.5.1 Design Science Research (DSR)

A Design Science Research é uma metodologia de pesquisa estabelecida nas áreas de Sistemas de Informação e Ciência da Computação que se concentra na criação e avaliação de artefatos inovadores para resolver problemas relevantes do mundo real ou organizacional. Diferentemente de pesquisas puramente explicativas ou descritivas, a DSR busca gerar conhecimento *através* do design e da aplicação de soluções tecnológicas (HEVNER et al., 2004; MARCH; SMITH, 1995).

O processo da DSR é frequentemente descrito como um ciclo iterativo que envolve as seguintes atividades principais (PEFFERS et al., 2007):

1. **Identificação do Problema e Motivação:** Definir o problema de pesquisa específico e justificar o valor de uma solução.
2. **Definição dos Objetivos da Solução:** Inferir objetivos para a solução a partir da definição do problema e do conhecimento do estado da arte.

3. **Design e Desenvolvimento:** Criar o artefato (e.g., construtos, modelos, métodos, instanciações).
4. **Demonstração:** Demonstrar o uso do artefato para resolver uma ou mais instâncias do problema.
5. **Avaliação:** Observar e medir o quão bem o artefato suporta uma solução para o problema.
6. **Comunicação:** Comunicar o problema, o artefato, sua utilidade e eficácia para pesquisadores e outros públicos relevantes.

Nesta tese, o ciclo DSR foi aplicado da seguinte forma:

- **Problema e Motivação (Capítulo 1):** Identificou-se a lacuna de frameworks para guiar a construção de MAS em EAs, especialmente considerando IA Generativa e a necessidade de complementaridade com frameworks de design de ecossistemas como o de Silveira ([SILVEIRA, 2022](#)).
- **Objetivos da Solução (Capítulo 1):** Definiram-se os objetivos de criar um framework (FC-MAS-EA) baseado em uma ontologia estendida (OEACD-MAS) que fosse sistemático, flexível e conceitualmente embasado.
- **Design e Desenvolvimento (Capítulos ?? e 5):** Projetou-se e desenvolveu-se a extensão ontológica OEACD-MAS e o framework FC-MAS-EA, detalhando seus componentes e processos.
- **Demonstração (Capítulo ??):** Aplicou-se o framework FC-MAS-EA na construção/-reengenharia de dois estudos de caso (LIEd Ubíquo e GoodBot).
- **Avaliação (Capítulo ??):** Avaliou-se a utilidade e aplicabilidade do framework com base na análise reflexiva da sua aplicação nos estudos de caso.
- **Comunicação (Esta Tese):** Documentou-se todo o processo e os resultados nesta tese.

As seções seguintes detalham os métodos específicos empregados em cada fase do ciclo DSR adaptado para esta pesquisa.

1.6 Etapa 1: Extensão da Ontologia OEACD (OEACD-MAS)

A criação de uma base conceitual sólida é fundamental para o desenvolvimento do framework. Como a ontologia OEACD (SILVEIRA, 2022) não contemplava explicitamente os conceitos necessários para modelar MAS, uma extensão foi necessária. O processo de extensão seguiu uma adaptação da metodologia SABiO (FALBO; NARDI; GUIZZARDI, 2014), focando nas seguintes atividades:

1. **Identificação de Requisitos e Questões de Competência:** Com base na análise do domínio de MAS (Seção 2.3), IA Generativa (Seção ??), MAS na educação (Seção ??) e nos requisitos do framework FC-MAS-EA, foram levantadas questões de competência que a ontologia estendida deveria ser capaz de responder (e.g., "Quais são as capacidades de um agente X?", "Qual a arquitetura do agente Y?", "Como os agentes A e B interagem?").
2. **Análise e Reutilização da OEACD:** A OEACD original foi analisada para identificar conceitos existentes que poderiam ser reutilizados ou especializados (e.g., `Participant`, `Interaction`, `InformationResource`).
3. **Modelagem Conceitual em OntoUML:** Novos conceitos, atributos e relações específicas de MAS foram definidos e formalizados utilizando a linguagem OntoUML (GUIZZARDI, 2007), seguindo os princípios da UFO (Unified Foundational Ontology) para garantir consistência ontológica. A modelagem foi realizada de forma iterativa, refinando os conceitos e relações à medida que a compreensão do domínio se aprofundava.
4. **Modularização:** Os novos conceitos foram organizados em um módulo conceitual (MAS) e suas relações com os módulos existentes da OEACD (`SLEDC`, `SPA`, `SEE`) foram estabelecidas.
5. **Validação Preliminar:** A ontologia estendida (OEACD-MAS) foi validada preliminarmente através da verificação de sua capacidade de responder às questões de competência levantadas e pela instanciación de seus conceitos com exemplos concretos derivados dos estudos de caso (LIEd Ubíquo e GoodBot). Uma avaliação por especialistas externos não foi realizada nesta fase, constituindo um trabalho futuro.

O resultado desta etapa é a ontologia OEACD-MAS, detalhada no Capítulo ??.

1.7 Etapa 2: Desenvolvimento do Framework FC-MAS-EA

O desenvolvimento do framework FC-MAS-EA foi um processo iterativo de design, guiado pelos seguintes princípios:

- **Fundamentação Ontológica:** O framework deveria ser conceitualmente embasado na ontologia estendida OEACD-MAS, utilizando seus conceitos para definir os componentes e as etapas do processo de construção.
- **Sistematicidade:** O framework deveria propor um processo claro e organizado, dividindo a complexidade da construção de MAS em fases e atividades gerenciáveis.
- **Flexibilidade:** O framework deveria ser aplicável a diferentes tipos de MAS e agentes (e.g., baseados em recomendação, diálogo generativo) e adaptável a diferentes contextos de EAs.
- **Complementaridade:** O framework deveria focar na *construção* dos agentes e do MAS, complementando frameworks existentes focados no *design* do ecossistema, como o de Silveira (SILVEIRA, 2022).

O processo de desenvolvimento envolveu:

1. **Revisão da Literatura:** Análise de frameworks existentes para desenvolvimento de MAS e software em geral, bem como de metodologias de engenharia de agentes (????).
2. **Análise de Requisitos:** Definição dos requisitos que um framework para construção de MAS em EAs deveria atender, com base na literatura e nos desafios identificados.
3. **Design Iterativo:** Proposta inicial da arquitetura conceitual (camadas/componentes) e do processo (fases/atividades) do framework, utilizando os conceitos da OEACD-MAS. O design foi refinado iterativamente através de:
 - Mapeamento dos conceitos da OEACD-MAS para as atividades do framework.
 - Análise de como o framework se aplicaria aos cenários dos estudos de caso.
 - Reflexão sobre a clareza, completude e consistência do framework.
4. **Documentação:** Descrição detalhada dos componentes, do processo, dos princípios e da relação com a ontologia.

O resultado desta etapa é o framework FC-MAS-EA, detalhado no Capítulo 5.

1.8 Etapa 3: Demonstração via Estudos de Caso

Para demonstrar a aplicabilidade e a flexibilidade do framework FC-MAS-EA, ele foi aplicado retrospectivamente (no caso do LIEd Ubíquo, baseado na descrição de Silveira

(SILVEIRA, 2022)) e prospectivamente/concomitantemente (no caso do GoodBot, baseado no artigo submetido (SANTOS; CURY, 2024b) e no conhecimento do autor sobre seu desenvolvimento) como estudos de caso.

A aplicação do framework em cada estudo de caso seguiu as fases definidas no próprio framework (Análise e Requisitos, Design do MAS, Design dos Agentes, Implementação, Integração), detalhando:

- Como os conceitos da OEACD-MAS foram utilizados em cada fase.
- Quais decisões de design foram tomadas em cada etapa.
- Como o framework guiou ou poderia ter guiado o processo de construção.
- Quais artefatos foram (ou seriam) gerados em cada fase.

O objetivo não foi reconstruir completamente os sistemas, mas sim simular e analisar o processo de construção *sob a ótica do framework*, utilizando as informações disponíveis sobre os sistemas originais. Esta abordagem permitiu verificar se o framework era capaz de acomodar diferentes tipos de MAS e requisitos.

Os detalhes da aplicação do framework nos estudos de caso são apresentados no Capítulo ??.

1.9 Etapa 4: Avaliação do Framework

A avaliação do framework FC-MAS-EA nesta tese teve como foco principal sua **utilidade** e **aplicabilidade** percebidas através da análise dos estudos de caso. A avaliação seguiu uma abordagem qualitativa e reflexiva, realizada pelo próprio pesquisador, baseada na experiência de aplicar (ou simular a aplicação) do framework nos dois cenários distintos.

Os critérios de avaliação definidos foram:

- **Utilidade:** O framework fornece um guia útil e sistemático para o processo de construção? Ele ajuda a organizar o pensamento e a tomar decisões de design? Ele facilita o alinhamento do MAS com o EA (via ontologia)?
- **Flexibilidade:** O framework é suficientemente flexível para ser aplicado a MAS com diferentes arquiteturas, tecnologias (incluindo IA Generativa) e objetivos pedagógicos?
- **Clareza:** Os componentes, fases e atividades do framework são claros e compreensíveis?

- **Completeness (Preliminar):** O framework cobre as etapas essenciais da construção de MAS no contexto de EAs? Existem lacunas óbvias?

O método de avaliação consistiu em:

1. **Análise Reflexiva:** Após a aplicação (ou simulação) do framework em cada estudo de caso (Capítulo ??), foi realizada uma análise crítica sobre como o framework se comportou em relação aos critérios definidos.
2. **Comparação entre Casos:** Comparou-se a experiência de aplicação nos dois estudos de caso para avaliar a flexibilidade e identificar padrões ou dificuldades recorrentes.
3. **Identificação de Pontos Fortes e Fracos:** Com base na análise, foram identificados os principais pontos positivos do framework e as áreas que necessitam de melhoria ou investigação futura.

É importante notar que esta avaliação é intrinsecamente limitada por ter sido realizada pelo próprio criador do framework e baseada em apenas dois estudos de caso. Avaliações futuras envolvendo outros desenvolvedores e mais projetos são necessárias para uma validação mais robusta.

Os resultados e a discussão da avaliação são apresentados no Capítulo ??.

1.10 Coleta e Análise de Dados

Considerando a natureza da DSR e a abordagem de avaliação adotada, a coleta de dados foi predominantemente qualitativa e baseada em artefatos e reflexões geradas durante o próprio processo de pesquisa:

- **Dados Coletados:**
 - Documentação da ontologia OEACD ([SILVEIRA, 2022](#)).
 - Artigos e literatura sobre MAS, IA Generativa, EAs e DSR.
 - Versões intermediárias e final da ontologia estendida OEACD-MAS (modelos OntoUML, descrições).
 - Versões intermediárias e final do framework FC-MAS-EA (descrições, diagramas).
 - Descrições e artefatos existentes dos sistemas LIEd Ubíquo e GoodBot.

- Registros e notas do pesquisador durante a aplicação simulada do framework nos estudos de caso.
- Registros da análise reflexiva sobre a utilidade e aplicabilidade do framework.
- **Análise de Dados:** A análise foi realizada de forma qualitativa, envolvendo:
 - Análise de conteúdo da literatura e dos artefatos existentes.
 - Comparação entre os requisitos e os artefatos desenvolvidos (ontologia e framework).
 - Análise temática das notas e reflexões sobre a aplicação do framework nos estudos de caso, buscando identificar padrões relacionados aos critérios de avaliação (utilidade, flexibilidade, clareza, completude).
 - Síntese dos achados para fundamentar a avaliação do framework e a conclusão da tese.

Esta abordagem metodológica, centrada na DSR e na avaliação qualitativa através de estudos de caso, permitiu desenvolver e realizar uma avaliação inicial do framework FC-MAS-EA no contexto específico desta pesquisa.

1.11 Contribuições Esperadas

As principais contribuições esperadas desta tese são:

1. **OEACD-MAS:** Uma extensão da ontologia OEACD ([SILVEIRA, 2022](#)) que incorpora conceitos fundamentais de Sistemas Multiagentes, fornecendo uma base conceitual mais rica para modelar EAs que incluem agentes inteligentes.
2. **FC-MAS-EA:** Um framework conceitual inédito que oferece um processo metodológico sistemático para guiar a construção de MAS inteligentes (incluindo os baseados em IA Generativa) especificamente para Ecossistemas de Aprendizagem, posicionando-se como complementar a frameworks existentes de design de SLEs.
3. **Validação Prática:** A demonstração da aplicabilidade e flexibilidade do FC-MAS-EA através de sua utilização na construção/reengenharia de dois estudos de caso distintos (LIEd Ubíquo e GoodBot), juntamente com uma avaliação inicial de sua utilidade.

1.12 Organização do Trabalho

Esta tese está organizada da seguinte forma:

- **Capítulo 1:** Apresenta a contextualização, o problema de pesquisa, a motivação, os objetivos, a hipótese, a metodologia e as contribuições esperadas.
- **Capítulo 2:** Descreve a fundamentação teórica, abordando Ecossistemas de Aprendizagem, a ontologia OEACD, Sistemas Multiagentes, Agentes Inteligentes, IA Generativa e MAS aplicados à educação.
- **Capítulo 3:** Detalha a metodologia de pesquisa DSR e os métodos específicos utilizados para a extensão da ontologia, desenvolvimento do framework, construção dos estudos de caso e avaliação.
- **Capítulo 4:** Apresenta a proposta de extensão da ontologia OEACD, denominada OEACD-MAS, detalhando os novos conceitos, relações e sua validação.
- **Capítulo 5:** Descreve em detalhes o framework proposto, FC-MAS-EA, incluindo sua arquitetura conceitual, componentes e o processo de construção de MAS que ele define.
- **Capítulo ??:** Relata a aplicação do FC-MAS-EA na construção/reengenharia dos estudos de caso LIEd Ubíquo e GoodBot.
- **Capítulo ??:** Apresenta a avaliação da utilidade e aplicabilidade do framework FC-MAS-EA com base na análise dos estudos de caso.
- **Capítulo ??:** Sintetiza o trabalho, discute as principais contribuições, responde às questões de pesquisa, aponta limitações e sugere trabalhos futuros.

Finalmente, são apresentadas as Referências Bibliográficas e os Apêndices/Anexos relevantes.

2 Fundamentação Teórica

Este capítulo estabelece a base conceitual e teórica que sustenta a proposta desta tese: um framework para a construção de Sistemas Multiagentes (MAS) inteligentes em Ecossistemas de Aprendizagem (EAs). Iniciamos com a contextualização dos EAs na cultura digital, apresentando a Ontologia para Ecossistemas de Aprendizagem na Cultura Digital (OEACD) (SILVEIRA, 2022) como um trabalho fundamental e ponto de partida. Em seguida, aprofundamos nos domínios de Sistemas Multiagentes, detalhando seus conceitos, arquiteturas e mecanismos de interação, com ênfase em Agentes Inteligentes. Discutimos também a ascensão da Inteligência Artificial (IA) Generativa, suas tecnologias subjacentes (como Transformers e LLMs) e seu potencial disruptivo, inclusive para a criação de agentes mais sofisticados. Revisamos as aplicações de MAS na educação, citando trabalhos relevantes, incluindo as publicações anteriores do autor (SANTOS; CURY, 2022; SANTOS; CURY, 2023; SANTOS; CURY, 2024a; SANTOS; CURY, 2024b), que informam os estudos de caso posteriores. Finalmente, posicionamos a contribuição desta tese em relação à OEACD, justificando a necessidade da extensão OEACD-MAS e do framework FC-MAS-EA para guiar especificamente a **construção** dos componentes inteligentes (agentes) dentro dos EAs modelados.

2.1 Ecossistemas de Aprendizagem na Cultura Digital

A dinâmica da aprendizagem na sociedade contemporânea transcende os limites físicos e temporais das instituições educacionais tradicionais. Impulsionada pela onipresença da tecnologia e pela cultura digital, a aprendizagem tornou-se um fenômeno distribuído, contínuo e profundamente social (BRONFENBRENNER, 1979; FISCHER, 2001; SIEMENS, 2005). Nesse contexto, o conceito de Ecossistemas de Aprendizagem (EAs) ganha proeminência para descrever a complexa rede de interações entre pessoas, recursos, ferramentas e contextos que moldam as experiências de aprendizagem ao longo da vida.

Silveira (SILVEIRA, 2022), em sua tese que serve de base e complemento a este trabalho, realiza uma extensa revisão sobre o tema e define um Ecossistema de Aprendizagem como "um sistema complexo e adaptativo composto por indivíduos (aprendizes, educadores, mentores), artefatos (ferramentas, recursos, conteúdos), processos (atividades, interações, colaborações) e contextos (físicos, sociais, culturais, tecnológicos), que interagem dinamicamente para apoiar e facilitar a aprendizagem ao longo da vida". A natureza sistêmica, adaptativa e interconectada é central para essa definição, destacando a emergência de comportamentos e resultados que

não podem ser previstos apenas pela análise isolada dos componentes.

A cultura digital não é apenas um pano de fundo, mas um elemento constitutivo desses ecossistemas. Tecnologias como dispositivos móveis, redes sociais, ambientes virtuais imersivos, plataformas de aprendizagem online e, mais recentemente, ferramentas de IA Generativa, reconfiguram as formas de acesso à informação, comunicação, colaboração e construção de conhecimento (DOWNES, 2012; CASTELLS, 2000). Essa integração tecnológica amplia exponencialmente as oportunidades de aprendizagem personalizada e flexível, mas simultaneamente introduz desafios relacionados à curadoria de conteúdo, navegação em ambientes ricos em informação, garantia de equidade no acesso, privacidade de dados e o desenvolvimento de competências digitais críticas (SANTOS; CURY, 2024a).

Compreender e projetar intervenções eficazes nesses EAs complexos exige modelos e ferramentas conceituais robustas. É nesse ponto que a ontologia proposta por Silveira (SILVEIRA, 2022) se torna fundamental.

2.2 Ontologia para Ecossistemas de Aprendizagem na Cultura Digital (OEACD)

Diante da complexidade inerente aos EAs na cultura digital, a necessidade de uma representação formal e compartilhada do domínio torna-se evidente. A Ontologia para Ecossistemas de Aprendizagem na Cultura Digital (OEACD), desenvolvida por Silveira (SILVEIRA, 2022), surge como uma resposta a essa necessidade. Conforme definido por Gruber (GRUBER, 1993), uma ontologia é uma "especificação explícita de uma conceitualização", fornecendo um vocabulário comum e uma estrutura semântica para descrever entidades, propriedades e relações em um domínio específico.

A OEACD foi construída utilizando a metodologia SABiO (Systematic Approach for Building Ontologies) (FALBO; NARDI; GUIZZARDI, 2014) e formalizada em OntoUML (GUIZZARDI, 2007), uma linguagem ontologicamente bem fundamentada baseada em UFO (Unified Foundational Ontology). Essa abordagem garante rigor conceitual e clareza semântica. A ontologia é estruturada modularmente, permitindo sua extensão e reutilização. Os módulos centrais, relevantes para o contexto desta tese, incluem:

- **SLEDC (Smart Learning Ecosystem in Digital Culture):** O núcleo da ontologia, definindo os conceitos fundamentais como `LearningEcosystem`, `Participant` (com subtipos como `Learner`, `Educator`, `Mentor`), `LearningResource`, `Activity`, `Interaction`, `Context`, `Tool`, `Community`, etc. Este módulo estabelece a estrutura básica para descrever

qualquer EA.

- **SPA (Smart Pedagogical Architecture):** Focado nos aspectos pedagógicos, modelando conceitos como `PedagogicalStrategy`, `LearningDesign`, `TeachingMethod`, e como estes se relacionam com as atividades e recursos no ecossistema.
- **SEE (Smart Ecosystem Evaluation):** Aborda a avaliação da aprendizagem e do próprio ecossistema, com conceitos como `Assessment`, `Feedback`, `LearningOutcome`, `EvaluationCriteria`, etc.

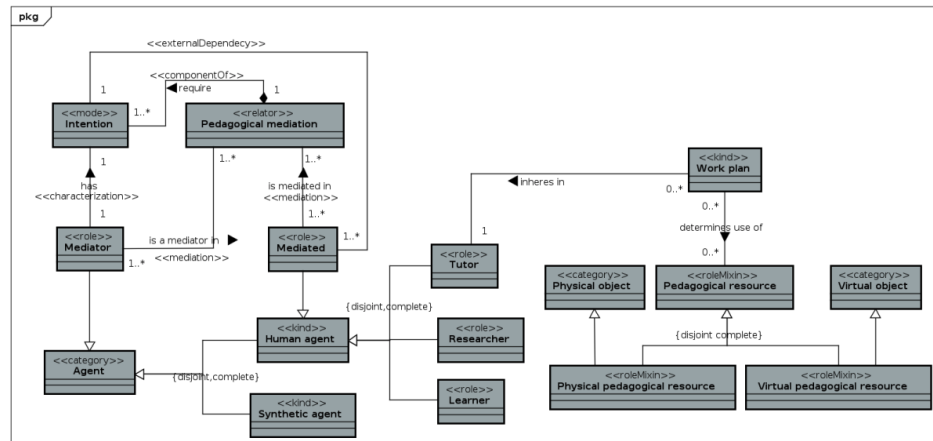


Figura 1 – Sub-ontologia Educational Environment (SEE) em OntoUML (SILVEIRA, 2022).

A OEACD fornece uma base conceitual rica e robusta para **analisar** e **descrever** Ecossistemas de Aprendizagem. Ela permite modelar a estrutura, os participantes, os recursos e as interações que ocorrem nesses ambientes. O trabalho de Silveira (SILVEIRA, 2022) concentra-se no uso dessa ontologia para apoiar o **design do próprio ecossistema** e de arquiteturas pedagógicas inteligentes dentro dele, como demonstrado no estudo de caso do LIEd Ubíquo.

Contudo, a OEACD, em sua forma original, não detalha suficientemente os aspectos relacionados à **construção** de componentes computacionais inteligentes, como os agentes, que podem operar dentro desses ecossistemas. Falta um vocabulário específico para descrever a arquitetura interna dos agentes, suas capacidades (especialmente as generativas), seus objetivos, planos, crenças e os protocolos de interação detalhados que utilizam. É precisamente essa lacuna que a presente tese busca preencher, propondo a extensão OEACD-MAS (detalhada no Capítulo ??) e o framework FC-MAS-EA (Capítulo 5), que se apoia nessa ontologia estendida para guiar a engenharia de Sistemas Multiagentes para EAs.

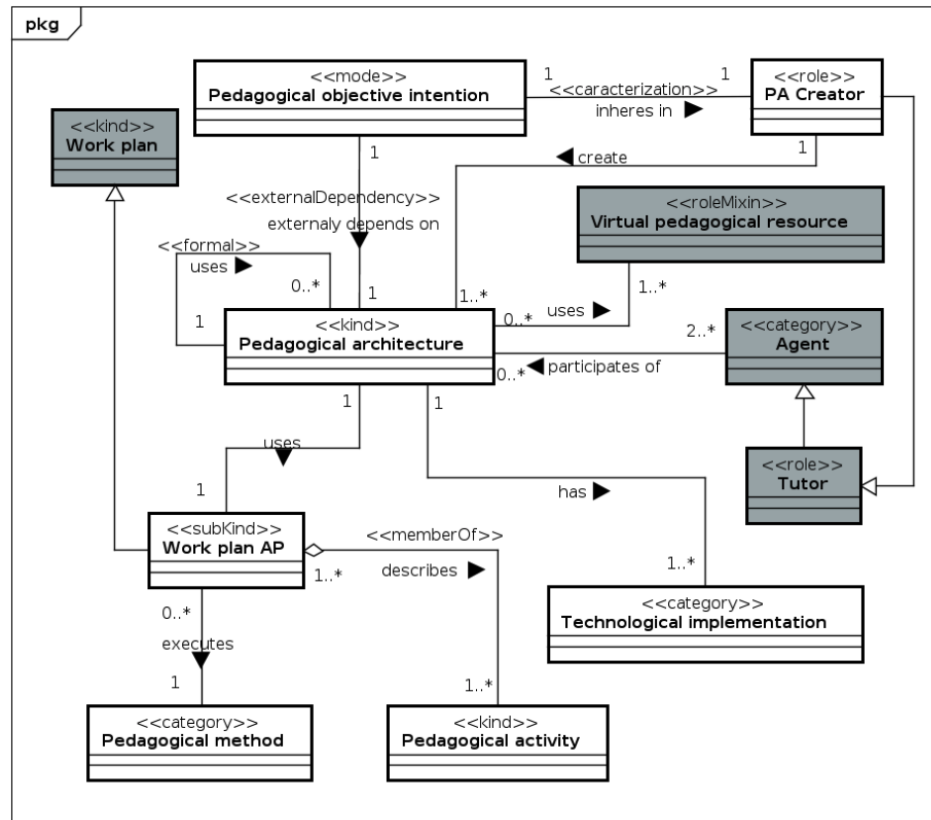


Figura 2 – Sub-ontologia Pedagogical Architecture (SPA) em OntoUML (SILVEIRA, 2022).

2.3 Sistemas Multiagentes (MAS)

Sistemas Multiagentes (MAS) representam um paradigma poderoso para a concepção e implementação de sistemas distribuídos complexos, onde múltiplas entidades computacionais autônomas, denominadas agentes, interagem para atingir objetivos individuais ou coletivos (WOOLDRIDGE, 2009; WEISS, 1999). A relevância dos MAS reside na sua capacidade de modelar e construir sistemas que espelham a natureza distribuída e interativa de muitos problemas do mundo real, incluindo os Ecossistemas de Aprendizagem.

2.3.1 Agentes: Definição e Propriedades

Um **agente** é tipicamente definido como um sistema computacional situado em algum ambiente, capaz de perceber esse ambiente através de sensores e de atuar sobre ele através de atuadores, de forma autônoma e direcionada a objetivos (RUSSELL; NORVIG, 2010; WOOLDRIDGE; JENNINGS, 1995). As propriedades chave que caracterizam um agente incluem:

- **Autonomia:** Agentes operam sem intervenção direta de humanos ou outros agentes,

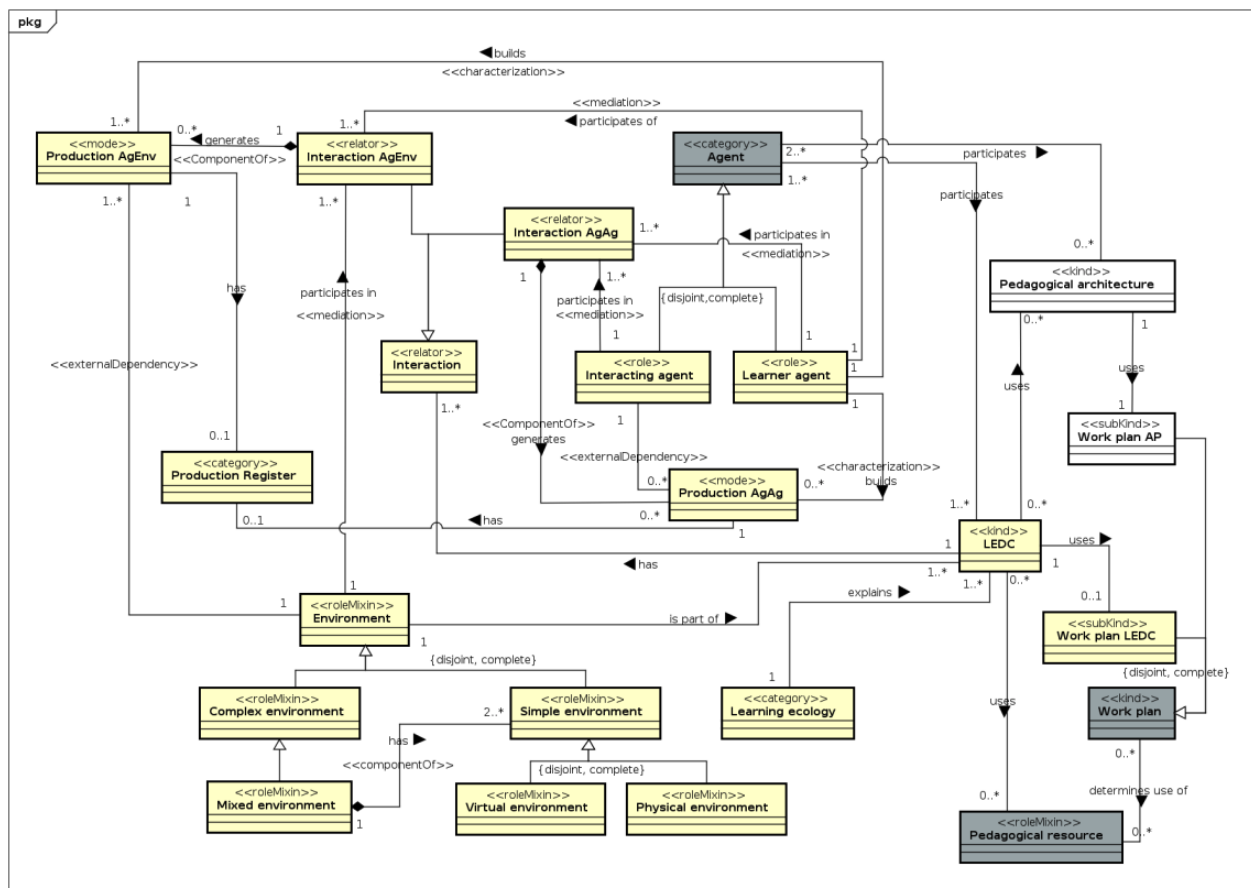


Figura 3 – Sub-ontologia Learning Ecosystem on Digital Culture (SLEDC)

controlando suas próprias ações e estado interno.

- **Sociabilidade:** Agentes são capazes de interagir com outros agentes (e possivelmente humanos) através de alguma linguagem de comunicação e protocolos de interação para cooperar, coordenar ou competir.
- **Reatividade:** Agentes percebem seu ambiente (que pode ser o mundo físico, um usuário, outros agentes, a Internet) e respondem em tempo hábil às mudanças que ocorrem nele.
- **Proatividade:** Agentes não agem simplesmente em resposta ao ambiente; eles são capazes de tomar a iniciativa, exibindo comportamento direcionado a objetivos.

Agentes podem variar enormemente em complexidade, desde simples entidades reativas até agentes deliberativos sofisticados com capacidades avançadas de raciocínio e aprendizado.

2.3.2 Arquiteturas de Agentes

A arquitetura de um agente define sua estrutura interna e o fluxo de controle que mapeia percepções em ações. Diversas arquiteturas foram propostas, cada uma com suas vantagens e desvantagens ([WOOLDRIDGE, 2009](#); [PADGHAM](#); [WINIKOFF, 2004](#)):

- **Agentes Reativos (Baseados em Lógica ou Subsunção):** Mapeiam diretamente percepções para ações, muitas vezes usando regras condição-ação ou camadas de comportamento concorrentes. São eficientes para respostas rápidas, mas limitados em planejamento estratégico.
- **Agentes Deliberativos (e.g., Baseados em Modelos, Objetivos, Utilidade, BDI):** Possuem uma representação explícita do ambiente e/ou de seus objetivos, permitindo raciocínio sobre ações futuras. A arquitetura **BDI (Belief-Desire-Intention)** ([RAO](#); [GEORGEFF, 1995](#)) é particularmente influente, modelando o estado mental do agente em termos de:
 - **Crenças (Beliefs):** Informações que o agente possui sobre o estado do mundo (podem ser incompletas ou incorretas).
 - **Desejos (Desires):** Estados do mundo que o agente gostaria de alcançar (objetivos potenciais).
 - **Intenções (Intentions):** Desejos que o agente se comprometeu a perseguir, formando a base para o planejamento e a ação.
- **Agentes Híbridos:** Combinam elementos de arquiteturas reativas e deliberativas, buscando equilibrar a necessidade de resposta rápida com planejamento de longo prazo. Frequentemente organizados em camadas (e.g., uma camada reativa, uma de planejamento local, uma de planejamento cooperativo).

A escolha da arquitetura depende dos requisitos da aplicação, da complexidade do ambiente e das capacidades desejadas para o agente.

2.3.3 Comunicação, Interação e Coordenação

A interação é a essência dos MAS. Agentes precisam se comunicar para compartilhar informações, coordenar ações, negociar recursos e colaborar na resolução de problemas. Os mecanismos para isso incluem:

- **Linguagens de Comunicação de Agentes (ACLs):** Linguagens formais como FIPA ACL ([Foundation for Intelligent Physical Agents \(FIPA\), 2002](#)) e KQML definem a

estrutura e a semântica das mensagens trocadas. Baseadas na Teoria dos Atos de Fala, as mensagens possuem um conteúdo e um performativo (ato comunicativo, e.g., **inform**, **request**, **propose**) que especifica a intenção do remetente.

- **Ontologias de Conteúdo:** Como já discutido (Seção 2.2), ontologias são cruciais para garantir que os agentes compartilhem um entendimento comum sobre os conceitos mencionados no conteúdo das mensagens. A OEACD-MAS serve a esse propósito no contexto desta tese.
- **Protocolos de Interação:** Definem padrões estruturados de troca de mensagens para alcançar objetivos específicos, como leilões (e.g., Contract Net Protocol), negociação, votação ou planejamento conjunto (WEISS, 1999; SMITH, 1980).
- **Mecanismos de Coordenação:** Além da comunicação direta, a coordenação pode ser alcançada através de mecanismos como convenções sociais, planejamento centralizado ou distribuído, ou modelos organizacionais que definem papéis, responsabilidades e relações de autoridade (ZAMBONELLI; JENNINGS; WOOLDRIDGE, 2003; JENNINGS, 1996).

2.4 Inteligência Artificial Generativa e seu Papel em Agentes

Nos últimos anos, a Inteligência Artificial Generativa (IAG) emergiu como uma força transformadora, com modelos capazes de criar conteúdo novo e coerente em diversas modalidades (texto, imagem, código, etc.) (GOODFELLOW et al., 2014; VASWANI et al., 2017). Essa capacidade representa um salto qualitativo em relação a modelos anteriores, predominantemente focados em classificação ou previsão.

2.4.1 Tecnologias Subjacentes: Transformers e LLMs

O avanço da IAG, especialmente no domínio textual, é largamente atribuído à arquitetura **Transformer** (VASWANI et al., 2017). Introduzindo o **mecanismo de auto-atenção**, os Transformers permitem que o modelo avalie a importância relativa de diferentes partes da sequência de entrada ao processar cada elemento, superando limitações de arquiteturas sequenciais anteriores (como RNNs e LSTMs) no tratamento de dependências de longo alcance.

Os **Large Language Models (LLMs)**, como GPT-4 (OPENAI, 2023), Gemini (Gemini Team; Google, 2023), Claude, LLaMA, são implementações massivas da arquitetura Transformer (ou variações), pré-treinadas em terabytes de dados textuais e de código. Esse pré-treinamento em larga escala permite que os LLMs adquiram um vasto conhecimento de mundo, compreensão linguística profunda e capacidades emergentes de raciocínio, que podem

ser posteriormente adaptadas para tarefas específicas através de **fine-tuning** e técnicas como **Reinforcement Learning from Human Feedback (RLHF)** (OUYANG et al., 2022).

2.4.2 Integrando Capacidades Generativas em Agentes Inteligentes

A IAG oferece um conjunto poderoso de capacidades que podem ser integradas às arquiteturas de agentes (Seção 2.3) para criar agentes significativamente mais flexíveis, adaptativos e capazes de interações mais naturais e sofisticadas:

- **Percepção Aprimorada:** LLMs podem processar e interpretar entradas textuais complexas (e, em modelos multimodais, também imagens ou áudio), enriquecendo a percepção do agente sobre seu ambiente e sobre as intenções dos usuários ou outros agentes.
- **Geração de Ações Comunicativas:** Agentes podem usar LLMs para gerar respostas em linguagem natural, explicações, sugestões, feedback e outros atos comunicativos de forma fluida e contextualizada, superando as limitações de templates pré-definidos. Isso é central para agentes de suporte conversacional como o GoodBot (SANTOS; CURY, 2024b).
- **Planejamento e Raciocínio Assistidos por LLM:** LLMs podem ser usados como componentes dentro do ciclo de raciocínio do agente (e.g., no modelo BDI) para ajudar a gerar planos, avaliar opções, decompor objetivos ou raciocinar sobre o estado do mundo e as crenças de outros agentes (PARK et al., 2023).
- **Geração de Conteúdo Adaptativo:** Agentes educacionais podem usar IAG para gerar dinamicamente conteúdo de aprendizagem (problemas, exemplos, explicações alternativas) adaptado às necessidades e ao progresso do aluno.
- **Simulação e Criação de Cenários:** Agentes podem usar IAG para criar cenários de simulação, personagens não-jogadores (NPCs) em ambientes virtuais de aprendizagem ou parceiros de diálogo com personalidades distintas.

2.4.3 Desafios e Considerações Éticas

A integração de IAG em agentes também traz desafios significativos que precisam ser abordados no design e implementação:

- **Alucinações e Confiabilidade:** LLMs podem gerar informações factualmente incorretas ou sem sentido (alucinações). Agentes que dependem de LLMs precisam de mecanismos para verificar fatos, citar fontes ou indicar níveis de confiança.
- **Vieses e Justiça:** Modelos treinados em dados da internet podem perpetuar vieses sociais. É crucial mitigar esses vieses para garantir interações justas e equitativas, especialmente em contextos educacionais.
- **Custo Computacional e Latência:** A inferência em LLMs pode ser computacionalmente cara e introduzir latência, o que pode ser problemático para agentes que precisam de respostas em tempo real.
- **Segurança e Controle:** Garantir que agentes baseados em LLMs não gerem conteúdo prejudicial, inseguro ou que viole a privacidade é um desafio contínuo (problema de alinhamento).
- **Ética e Transparência:** Questões sobre autoria, plágio, explicabilidade das decisões do agente e o impacto socioemocional de interações com agentes generativos precisam ser cuidadosamente consideradas (BENDER et al., 2021; WEIDINGER et al., 2021).

O framework FC-MAS-EA proposto nesta tese busca fornecer diretrizes para incorporar capacidades generativas de forma estruturada e responsável no design dos agentes.

2.5 MAS, Agentes Inteligentes e IA Generativa na Educação

A aplicação de MAS e agentes inteligentes na educação não é recente, com pesquisas explorando seu potencial desde os anos 90 (CHOU; CHAN; LIN, 2003; AYALA; YANO, 1997; CHAN; BASKIN, 1995). Tradicionalmente, agentes foram projetados para papéis como tutores inteligentes, companheiros de aprendizagem, sistemas de recomendação e facilitadores de colaboração, muitas vezes baseados em modelos de conhecimento explícitos e arquiteturas deliberativas clássicas (VANLEHN, 2011; BULL; KAY, 2007).

Trabalhos anteriores do autor se inserem nessa linha, explorando o uso de agentes para recomendação em ambientes ubíquos (LIEd Ubíquo, relacionado à tese de Silveira (SILVEIRA, 2022)) e para análise de sentimentos e suporte em fóruns de discussão (SANTOS; CURY, 2022; SANTOS; CURY, 2023). O mapeamento sistemático sobre avaliação da aprendizagem com tecnologias digitais (SANTOS; CURY, 2024a) também informa a compreensão dos desafios e oportunidades nesse campo, embora o foco desta tese tenha se deslocado da avaliação para a construção dos agentes.

A introdução da IA Generativa abre novas fronteiras para os MAS educacionais. Agentes conversacionais baseados em LLMs, como o GoodBot (SANTOS; CURY, 2024b), demonstram o potencial para oferecer suporte socioemocional e de aprendizagem mais natural e empático. Outras possibilidades incluem:

- **Tutores Generativos:** Agentes capazes de gerar explicações personalizadas em múltiplos estilos, criar problemas análogos, engajar em diálogos socráticos e adaptar continuamente a interação.
- **Ferramentas de Criação Assistida por IA:** Agentes que ajudam alunos e educadores a criar artefatos de aprendizagem (textos, apresentações, código, etc.), fornecendo feedback formativo durante o processo.
- **Simulações Interativas e Mundo Virtuais:** MAS populados por agentes generativos que podem simular cenários complexos, interações sociais realistas ou ambientes de exploração dinâmicos.

No entanto, a construção desses sistemas MAS-IAG para EAs é complexa. Requer a integração de conhecimento do domínio educacional, princípios de design pedagógico, técnicas de engenharia de software para MAS e o domínio das tecnologias de IA Generativa, além da consideração cuidadosa dos desafios éticos e práticos mencionados.

É nesse contexto que se insere a principal contribuição desta tese: o framework **FC-MAS-EA**. Ele visa fornecer uma abordagem metodológica estruturada, fundamentada ontologicamente na **OEACD-MAS**, para guiar os desenvolvedores através das fases de análise, design, implementação e implantação de Sistemas Multiagentes inteligentes (incluindo aqueles com capacidades generativas) especificamente para o domínio complexo dos Ecossistemas de Aprendizagem. O framework busca ser complementar à OEACD, focando na engenharia dos agentes que habitarão os ecossistemas modelados por ela.

Os capítulos seguintes detalharão a metodologia de pesquisa utilizada (Capítulo ??), a extensão ontológica proposta (Capítulo ??), a estrutura e os componentes do framework FC-MAS-EA (Capítulo 5), e sua aplicação e avaliação através dos estudos de caso LIEd Ubíquo e GoodBot (Capítulos ?? e ??).

3 Mapeamento Sistemático da Literatura: MAS Inteligentes com IA Generativa na Educação

3.1 Introdução

O campo da Inteligência Artificial (IA) tem testemunhado avanços exponenciais, particularmente com o advento da IA Generativa (IAG) e dos Grandes Modelos de Linguagem (LLMs). Simultaneamente, os Sistemas Multiagentes (MAS) continuam a ser um paradigma robusto para modelar e construir sistemas complexos com entidades autônomas e interativas. A convergência dessas duas áreas – MAS e IAG – apresenta um potencial significativo para transformar diversos domínios, incluindo a educação. Em Ecossistemas de Aprendizagem (EAs), que são inerentemente complexos e envolvem múltiplos atores e recursos, a aplicação de MAS inteligentes, agora potencializados pela IAG, pode levar a soluções mais adaptativas, personalizadas e eficazes.

Embora a pesquisa nesta intersecção esteja crescendo, falta uma visão geral estruturada que mapeie o cenário atual, identifique as principais tendências, classifique os tipos de pesquisa realizados e aponte lacunas existentes. Para preencher essa necessidade e contextualizar adequadamente a contribuição desta tese (o framework FC-MAS-EA), este capítulo apresenta um Mapeamento Sistemático da Literatura (MSL). Diferente de uma revisão sistemática que busca sintetizar evidências sobre uma questão específica, este mapeamento visa classificar a literatura existente para fornecer uma visão ampla e estruturada do campo de pesquisa em MAS inteligentes (ou sistemas baseados em agentes inteligentes) com IAG aplicados à educação.

3.2 Metodologia do Mapeamento

Este estudo adota as diretrizes para Mapeamento Sistemático da Literatura propostas por Petersen et al. ([PETERSEN et al., 2008](#); [PETERSEN](#); [VAKKALANKA](#); [KUZNIARZ, 2015](#)), que fornecem um processo estruturado para classificar a pesquisa em uma área específica e identificar quantitativamente as tendências e lacunas. O protocolo também se baseia em elementos das diretrizes de Kitchenham e Charters ([KITCHENHAM](#); [CHARTERS, 2007](#)) para garantir o rigor na condução e relato do processo.

3.2.1 Questões de Mapeamento

As seguintes questões de mapeamento (QMs) foram definidas para guiar a classificação e análise da literatura:

- **QM1:** Quais tipos de pesquisa (e.g., estudo de caso, experimento, prova de conceito, abordagem de solução, avaliação, validação, filosófico, opinião) são mais comuns na área de sistemas baseados em agentes inteligentes com IAG na educação?
- **QM2:** Quais são os principais tópicos ou objetivos educacionais abordados por esses estudos (e.g., feedback, tutoria, avaliação, colaboração, criação de conteúdo, simulação, suporte socioemocional, desenvolvimento de planos)?
- **QM3:** Quais arquiteturas de agentes (e.g., MAS, agente único, deliberativa, reativa, híbrida, BDI) e modelos/técnicas de IAG (e.g., GPT-3.5/4, Claude, Llama, MLLM, fine-tuning, prompt engineering) são predominantemente utilizados?
- **QM4:** Quais tipos de contribuições de pesquisa (e.g., framework, método, modelo, ferramenta, métrica, lições aprendidas, conjunto de dados) são apresentados nos estudos?
- **QM5:** Como a quantidade de publicações nesta área evoluiu entre 2020 e 2025?
- **QM6:** Quais são as principais lacunas de pesquisa ou direções futuras apontadas pelos estudos?

3.2.2 Estratégia de Busca

A busca por estudos primários foi realizada em Maio de 2025, cobrindo o período de Janeiro de 2020 a Maio de 2025. As seguintes bases de dados digitais foram consultadas (simuladas através de busca web direcionada e análise dos PDFs fornecidos pelo usuário): Scopus, Web of Science (WoS), IEEE Xplore, ACM Digital Library, Science Direct, SpringerLink, Taylor Francis Online, arXiv, HAL, Google Scholar, e fontes de conferências (AERA, AIED, NAACL-HLT, WWW).

A string de busca conceitual combinou termos relacionados a Agentes Inteligentes/MAS, IAG e Educação:

```
(
  ("Intelligent Agent*" OR "Conversational Agent*" OR "Pedagogical Agent*"
  OR "Software Agent*" OR "Multi-Agent System" OR "MAS")
  AND
```



```
("Generative AI" OR "GenAI" OR "LLM" OR "Large Language Model")  
AND  
("Education*" OR "Learning" OR "Teaching" OR "Pedagogy"  
OR "Tutoring System" OR "Learning Environment")  
)
```

3.2.3 Critérios de Inclusão e Exclusão

Para garantir a relevância dos estudos selecionados, foram aplicados os seguintes critérios:

Critérios de Inclusão (CI):

- CI1: Publicado ou disponibilizado como preprint entre Janeiro de 2020 e Maio de 2025.
- CI2: Escrito em Inglês ou Português.
- CI3: Apresenta pesquisa original (estudo primário).
- CI4: Descreve explicitamente um Sistema baseado em Agente(s) Inteligente(s) (único ou múltiplos) aplicado a um contexto educacional.
- CI5: O sistema descrito incorpora ou utiliza significativamente alguma forma de IA Generativa (e.g., LLMs para diálogo, geração de conteúdo).

Critérios de Exclusão (CE):

- CE1: Estudos duplicados.
- CE2: Estudos secundários ou terciários (e.g., revisões, mapeamentos, surveys, tutoriais).
- CE3: Estudos não focados primariamente em educação ou aprendizagem.
- CE4: Descreve apenas Agentes sem IAG, ou apenas IAG sem uma arquitetura ou aplicação clara baseada em agente.
- CE5: Texto completo não disponível para análise após busca.
- CE6: Editoriais, resumos curtos, livros completos (capítulos individuais podem ser incluídos se atenderem aos CIs), artigos de opinião sem pesquisa original.

3.2.4 Processo de Seleção e Extração de Dados

As etapas de seleção seguiram o fluxo PRISMA (PAGE et al., 2021): (1) Agregação dos resultados da busca inicial e dos PDFs; (2) Remoção de duplicatas; (3) Triagem por título e resumo; (4) Leitura completa para confirmação final da elegibilidade. A extração de dados foi realizada utilizando um formulário baseado nas QMs.

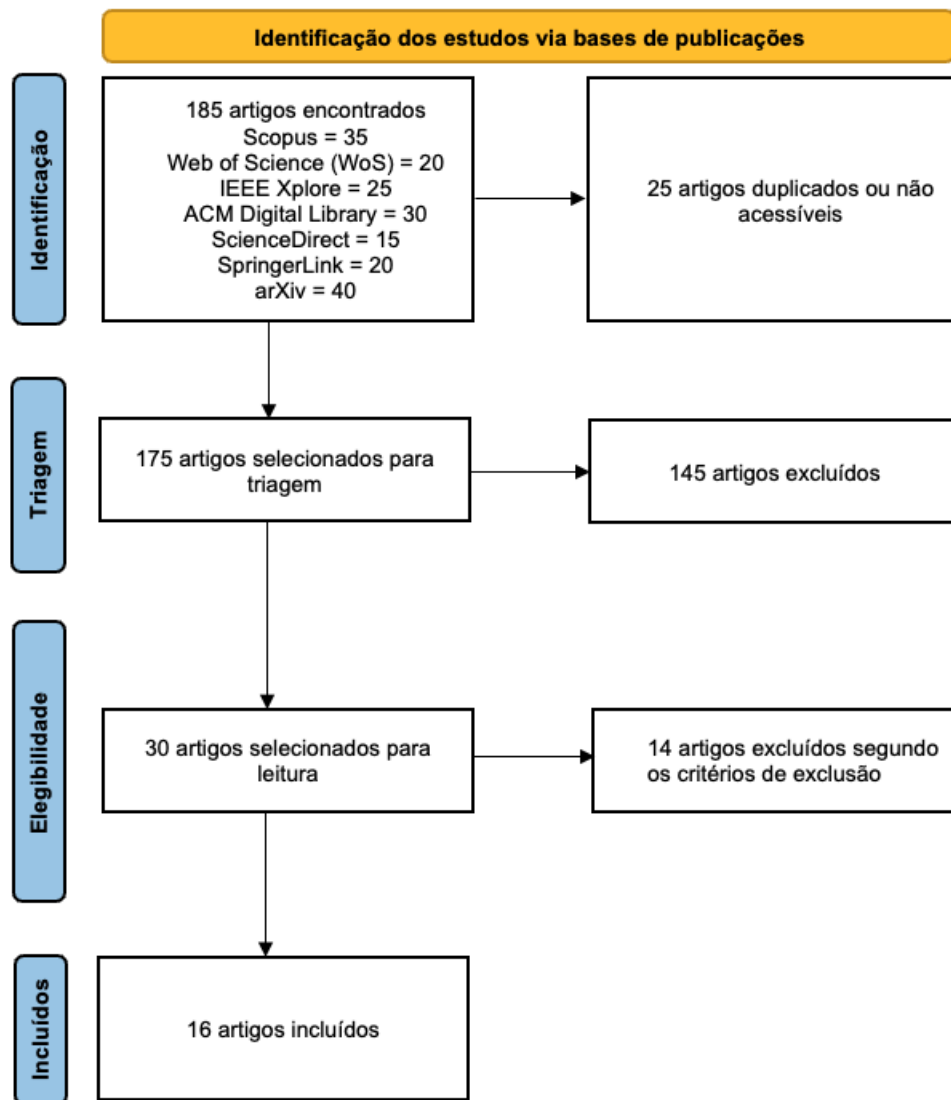


Figura 4 – Diagrama de fluxo PRISMA do processo de seleção dos estudos para o mapeamento.

3.2.5 Síntese e Classificação dos Dados

Os dados extraídos dos estudos selecionados foram sintetizados quantitativamente para responder às QMs. Foi utilizada análise de frequência para determinar a distribuição dos estudos entre as diferentes categorias de classificação. Gráficos de barras e tabelas de

frequência são usados para apresentar os resultados. A evolução temporal das publicações (QM5) é analisada. As lacunas de pesquisa (QM6) são identificadas com base na análise dos tópicos menos explorados e nas direções futuras apontadas pelos próprios estudos.

3.3 Resultados do Mapeamento

Após a aplicação do protocolo de busca e dos critérios de seleção, incluindo a análise dos estudos adicionais fornecidos, um conjunto de **16** estudos primários foi considerado relevante e incluído neste mapeamento (ver Tabela 1 no Apêndice B para a lista completa). O diagrama PRISMA (Figura 4) detalha o fluxo de seleção.

Os resultados da classificação desses 16 estudos, de acordo com as questões de mapeamento, são apresentados a seguir.

3.3.1 QM1: Tipos de Pesquisa

A análise da distribuição dos tipos de pesquisa (Figura 5) revela uma forte concentração em **Abordagens de Solução**, que propõem novos frameworks, métodos ou arquiteturas, e em **Estudos de Avaliação**, focados em avaliar a eficácia ou usabilidade dos sistemas propostos. Juntos, esses dois tipos representam mais de 60% dos estudos selecionados. **Estudos Experimentais**, que comparam diferentes abordagens, e **Provas de Conceito/Prototipagem** também surgem como significativos, refletindo a natureza exploratória e de desenvolvimento da área. Finalmente, **Estudos de Caso** em contextos reais e **Relatos de Experiência**, como o trabalho sobre integração curricular (MITCHELL; PERROTT, 2024), aparecem com menor frequência, embora estejam presentes na literatura analisada.

3.3.2 QM2: Tópicos e Objetivos Educacionais

Os sistemas baseados em agentes com IAG foram aplicados a uma gama variada de tópicos (Figura 6). Os mais proeminentes incluem:

- **Feedback Automatizado e Avaliação:** Foco significativo na geração e validação de feedback para tarefas complexas (escrita científica (GUO et al., 2024), matemática (YAN et al., 2025)), identificação de conhecimento (YANG et al., 2024) e etiquetagem de conhecimento (LI et al., 2024).
- **Tutoria Inteligente e Aprendizagem Personalizada:** Desenvolvimento de sistemas que guiam o aprendizado orientado a objetivos (WANG et al., 2025) ou se adaptam ao aluno.




Figura 5 – Distribuição dos estudos selecionados por tipo de pesquisa.

- **Simulação Educacional:** Criação de agentes para simular alunos (XU et al., 2025; XU; ZHANG; QIN, 2024), simular salas de aula (ZHANG et al., 2025) ou ambientes de treinamento específicos (e.g., médico (WEI et al., 2024)).
- **Suporte a Tarefas Específicas:** Incluindo o desenvolvimento de Planos Educacionais Individualizados (IEPs) (ZHANG, 2025) e o estímulo a habilidades metacognitivas como o questionamento (ABDELGHANI et al., 2022).
- **Integração Curricular e Engajamento:** Investigação do uso de ferramentas de IAG (agindo como agentes) em sala de aula e seu impacto no engajamento (MITCHELL; PERROTT, 2024; UNKNOWN, 2024).

3.3.3 QM3: Arquiteturas de Agentes e Técnicas de IAG

No que concerne às arquiteturas de agentes, constatou-se a predominância de **Sistemas Multiagentes (MAS)**, presentes em mais da metade dos estudos analisados (WANG et al., 2025; YANG et al., 2024; YAN et al., 2025; WEI et al., 2024; GUO et al., 2024; LI et

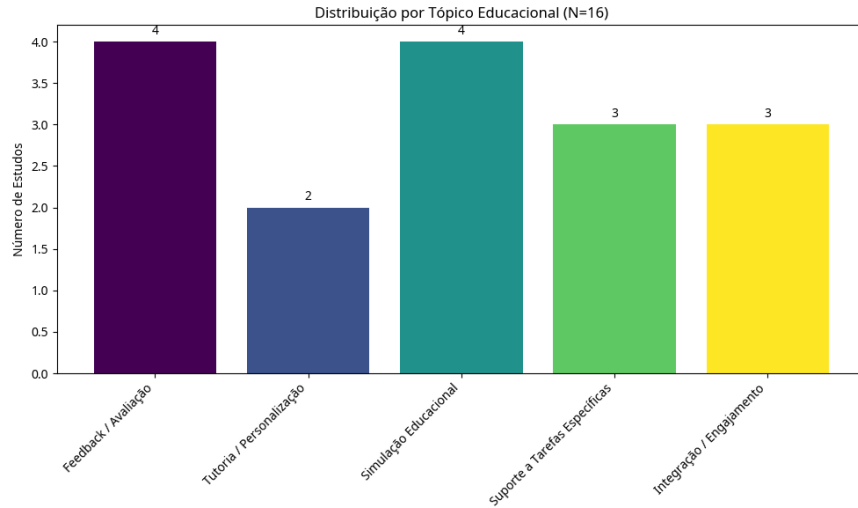


Figura 6 – Distribuição dos estudos selecionados por tópico ou objetivo educacional.

al., 2024; ZHANG et al., 2025; ZHANG, 2025). Tais arquiteturas frequentemente empregam agentes com papéis especializados (e.g., gerador, validador, orquestrador, simulador de função específica) para decompor tarefas complexas e facilitar a colaboração. Embora em menor número, também são relevantes as abordagens que utilizam **agentes únicos**, como agentes pedagógicos ou conversacionais (ABDELGHANI et al., 2022; UNKNOWN, 2024), e aquelas baseadas em frameworks de **agentes generativos** (XU et al., 2025; XU; ZHANG; QIN, 2024). A utilização de arquiteturas híbridas, combinando diferentes abordagens, também foi observada.

Em relação às técnicas de **Inteligência Artificial Generativa (IAG)** empregadas, os **Large Language Models (LLMs)** emergem como a tecnologia dominante. Destaca-se o uso extensivo de modelos da família **GPT (Generative Pre-trained Transformer)**, incluindo **GPT-3**, **GPT-3.5** e **GPT-4**, bem como o **ChatGPT** (ABDELGHANI et al., 2022; UNKNOWN, 2024; WANG et al., 2025; ZHANG et al., 2025). Observa-se também a introdução de **Modelos Multimodais (MLLMs)** para tarefas específicas, como a detecção de erros em problemas matemáticos (YAN et al., 2025). A técnica de **engenharia de prompts** (*prompt engineering*) mostrou-se onipresente na configuração e interação com esses modelos. Por outro lado, o **ajuste fino** (*fine-tuning*) foi mencionado de forma mais pontual, aplicado em cenários que demandam maior especialização do modelo (WANG et al., 2025).

3.3.4 QM4: Tipos de Contribuição

Os estudos analisados apresentam uma diversidade de contribuições de pesquisa, que podem ser categorizadas principalmente como:

- **Modelos e Métodos:** Proposição de novas abordagens ou métodos para tarefas específicas (e.g., método de feedback (GUO et al., 2024), identificação de Conhecimento Conceitual (CK) (YANG et al., 2024), simulação de sala de aula (XU et al., 2025)).
- **Frameworks:** Apresentação de frameworks conceituais ou arquiteturais para guiar o desenvolvimento de sistemas (e.g., GenMentor (WANG et al., 2025), EduAgent (XU; ZHANG; QIN, 2024), MathAgent (YAN et al., 2025), MEDCO (WEI et al., 2024), SimClass (ZHANG et al., 2025), von Neumann MAS (CHEN, 2024)).
- **Avaliações e Estudos Empíricos:** Realização de avaliações (automatizadas, humanas, quasi-experimentais) para validar as propostas apresentadas.
- **Ferramentas e Protótipos:** Desenvolvimento e descrição de implementações concretas das soluções propostas (ZHANG, 2025).
- **Princípios de Design e Lições Aprendidas:** Extração e compartilhamento de insights práticos, princípios ou diretrizes de design (MITCHELL; PERROTT, 2024).

Embora menos frequentes, também foram identificadas contribuições na forma de conjuntos de dados anotados (XU; ZHANG; QIN, 2024) ou métricas específicas de avaliação.

3.3.5 QM5: Evolução Temporal

A análise da distribuição temporal (Figura 7) confirma o crescimento exponencial recente. Apenas um estudo data de 2022 (ABDELGHANI et al., 2022), enquanto a grande maioria (mais de 90%) foi publicada ou disponibilizada em **2024 e 2025**. Isso demonstra inequivocamente que a integração de agentes inteligentes com IAG moderna na educação é um fenômeno de pesquisa muito recente, impulsionado pela disponibilidade de LLMs avançados.

3.3.6 QM6: Lacunas de Pesquisa e Direções Futuras

A análise da literatura evidencia lacunas importantes e sugere direções cruciais para pesquisas futuras no campo, reforçando observações de análises preliminares:

- **Validação Robusta e Longitudinal:** Persiste a necessidade de superar provas de conceito e experimentos de curta duração, avançando para avaliações rigorosas em contextos educacionais reais e por períodos extensos.
- **Ética, Transparência e Viés:** Aspectos críticos como privacidade de dados (de alunos e educadores), justiça algorítmica, explicabilidade das decisões dos agentes (XAI - Explainable




Figura 7 – Distribuição temporal dos estudos selecionados.

AI) e o uso responsável da tecnologia demandam investigação aprofundada e soluções práticas (Center on Inclusive Digital Discrete Learning (CIDDL), 2024; MITCHELL; PERROTT, 2024).

- **Integração e Escalabilidade:** Permanecem desafios técnicos significativos relacionados à integração fluida com plataformas educacionais existentes (e.g., AVAs) e à garantia de desempenho e robustez dos sistemas em larga escala.
- **Formação e Papel do Educador:** É fundamental investigar e desenvolver modelos eficazes de formação docente que preparem os educadores não apenas para usar, mas para colaborar pedagogicamente com agentes de IAG, redefinindo seu papel no processo de ensino-aprendizagem (MITCHELL; PERROTT, 2024).
- **Avaliação de Impacto na Aprendizagem:** Há uma carência de estudos com desenhos metodológicos robustos (e.g., ensaios controlados randomizados, estudos longitudinais) que meçam o impacto real das intervenções baseadas em agentes no aprendizado profundo, no desenvolvimento de competências complexas (e.g., pensamento crítico, colaboração) e na equidade educacional.
- **Exploração de Diversidade Tecnológica:** Direcionar pesquisas para explorar o potencial de modelos de IAG alternativos (para além da família GPT) e investigar arquiteturas de agentes mais sofisticadas, adaptativas ou especializadas para domínios de conhecimento ou tarefas pedagógicas específicas.

3.4 Discussão

Este mapeamento sistemático, enriquecido com os resultados de buscas adicionais, fornece uma visão mais abrangente do cenário emergente da pesquisa em sistemas baseados em agentes inteligentes com IAG na educação. A confirmação do crescimento explosivo a partir de 2024 solidifica a percepção de que esta é uma área impulsionada pelos avanços recentes em LLMs.

A predominância de arquiteturas multiagentes (MAS) em uma parcela significativa dos estudos é notável. Isso sugere que os pesquisadores estão reconhecendo rapidamente que a decomposição de tarefas complexas (como fornecer feedback validado, simular interações complexas ou gerenciar processos de aprendizagem personalizados) entre agentes especializados pode ser uma estratégia eficaz para aproveitar o poder da IAG, ao mesmo tempo em que se tenta mitigar suas limitações (e.g., falta de confiabilidade, dificuldade de controle). A variedade de papéis atribuídos aos agentes (gerador, validador, orquestrador, tutor, simulador de paciente/aluno/professor) ilustra a flexibilidade do paradigma MAS.

A diversidade de tópicos educacionais abordados, desde avaliação e feedback até simulação e planejamento, demonstra o amplo potencial de aplicação. No entanto, a concentração em certos tipos de pesquisa (propostas de solução, avaliações iniciais) e a escassez de estudos longitudinais em larga escala indicam que o campo ainda está em uma fase de maturação inicial.

As lacunas identificadas, especialmente em torno da validação robusta, ética, integração e avaliação do impacto real na aprendizagem, representam as principais fronteiras para pesquisas futuras. A necessidade de frameworks metodológicos para guiar o design, desenvolvimento e avaliação desses sistemas complexos torna-se ainda mais evidente diante da rápida proliferação de propostas de solução.

Ameaças à Validade: As limitações mencionadas anteriormente persistem. A dependência de buscas simuladas e da análise de PDFs fornecidos pode introduzir viés de seleção. A classificação ainda envolve subjetividade. A velocidade de publicação na área significa que o mapeamento é uma fotografia que pode desatualizar-se rapidamente.

Conexão com a Tese: Este mapeamento atualizado reforça ainda mais a justificativa para o framework FC-MAS-EA. A confirmação da tendência de uso de arquiteturas MAS para integrar IAG em aplicações educacionais complexas e a identificação da lacuna em metodologias de desenvolvimento sistemático validam diretamente a proposta central da tese. O framework oferece uma resposta à necessidade de guiar a construção desses sistemas, conectando o design do MAS (com suas capacidades e arquiteturas variadas vistas no mapeamento) ao contexto do EA (via OEACD-MAS) e considerando explicitamente a integração com IAG.

Os estudos de caso da tese podem ser claramente posicionados dentro dos tópicos e tipos de contribuição identificados (e.g., ferramenta/método para suporte/recomendação), e a avaliação do framework pode ser estruturada para abordar algumas das lacunas identificadas (e.g., fornecendo um método para design mais sistemático e potencialmente mais validável).

3.5 Conclusão do Mapeamento

Este Mapeamento Sistemático da Literatura analisou **16** estudos primários publicados entre 2020 e 2025, focados na intersecção de sistemas baseados em agentes inteligentes, IA Generativa e Educação. Os resultados revelam um campo de pesquisa em rápida expansão, especialmente desde 2024, com um forte interesse na aplicação de arquiteturas multiagentes para alavancar LLMs em tarefas como feedback automatizado, tutoria inteligente, avaliação e simulação educacional.

Apesar do dinamismo e do potencial demonstrado, o mapeamento destaca a necessidade premente de validação empírica mais robusta em contextos reais, investigação aprofundada sobre questões éticas e de interpretabilidade, e o desenvolvimento de metodologias e frameworks para guiar a construção responsável e eficaz desses sistemas. A presente tese, com a proposta do framework FC-MAS-EA, busca contribuir diretamente para suprir essa lacuna metodológica identificada.

4 OEACD-MAS: Uma Ontologia Estendida para Sistemas Multiagentes em Ecossistemas de Aprendizagem com Foco em Agentes Generativos

Conforme introduzido nos capítulos anteriores, a Ontologia para Ecossistemas de Aprendizagem na Cultura Digital (OEACD) (SILVEIRA, 2022) fornece uma base conceitual rica para descrever Ecossistemas de Aprendizagem (EAs). No entanto, para guiar especificamente a construção de Sistemas Multiagentes (MAS) que operam nesses ecossistemas, especialmente aqueles que empregam capacidades de Inteligência Artificial Generativa (IAG) por meio de Grandes Modelos de Linguagem (LLMs), uma extensão e um detalhamento mais aprofundado se fazem necessários. Este capítulo detalha a proposta de extensão, denominada OEACD-MAS, que incorpora conceitos fundamentais de MAS à estrutura da OEACD, e expande a discussão sobre a modelagem de agentes com capacidades generativas, além de apresentar uma ontologia de apoio para ecossistemas cognitivos que pode complementar essa visão.

4.1 Justificativa e Objetivos da Extensão

A OEACD, em sua forma original, foca nos elementos do ecossistema, nas arquiteturas pedagógicas e na avaliação, mas não possui granularidade suficiente para representar a estrutura interna, as capacidades (particularmente as generativas), o comportamento e a organização de agentes computacionais autônomos. A extensão OEACD-MAS visa suprir essa lacuna, fornecendo os primitivos conceituais para modelar:

- **Agentes e suas Características:** Arquitetura interna, capacidades (incluindo capacidades generativas baseadas em LLMs), objetivos, crenças (e como o conhecimento de um LLM é representado ou acessado), planos que envolvem o uso de IAG.
- **Organização e Interação do MAS:** Papéis dos agentes, protocolos de comunicação (inclusive para interações mediadas por LLMs), estrutura organizacional.

- **Integração MAS-EA:** A relação explícita entre os componentes do MAS e os elementos do Ecossistema de Aprendizagem (participantes, recursos, atividades, contexto) definidos na OEACD.

O objetivo é criar uma base ontológica robusta que fundamente o framework FC-MAS-EA (Capítulo 5), garantindo que a construção de MAS, incluindo aqueles com agentes baseados em LLM, seja conceitualmente alinhada com a visão do EA proporcionada pela OEACD e informada por ontologias de domínio cognitivo.

4.2 Metodologia de Extensão

A extensão seguiu uma adaptação da metodologia SABiO (FALBO; NARDI; GUIZZARDI, 2014), conforme descrito no Capítulo ??, envolvendo a identificação de requisitos a partir de questões de competência (e.g., "Quais capacidades o Agente Tutor baseado em LLM possui?", "Como o Agente de Diálogo utiliza um LLM para interagir com o Agente de Análise de Sentimento?"), a reutilização de conceitos da OEACD, a definição de novos conceitos em OntoUML (GUIZZARDI, 2007) e a organização modular. As imagens de referência para as subontologias da OEACD encontram-se detalhadas no Capítulo 2 desta tese.

4.3 Proposta de Conceitos e Relações na OEACD-MAS

A seguir, detalhamos os principais conceitos e relações propostos para a extensão OEACD-MAS, com ênfase na modelagem de agentes com capacidades generativas. A modelagem formal em OntoUML com diagramas específicos é um trabalho em andamento e essencial para a completa formalização.

4.3.1 Conceitos Centrais de MAS

- **Agent («Kind» ou «Role»):** Entidade computacional autônoma no EA. Pode especializar Participant ou ser um novo Kind. Relaciona-se com AgentRole, AgentCapability, AgentGoal, AgentBelief, AgentPlan, AgentAction, AgentPerception. Opera em (operatesIn) um LearningEcosystem.
- **MultiAgentSystem («Kind»):** Sistema composto (isComposedOf) por múltiplos Agents. Possui (hasOrganization) uma MASOrganization.
- **AgentArchitecture («Category» ou «Mixin»):** Classifica a estrutura interna do agente (e.g., Reativa, Deliberativa, BDI, Híbrida). Um Agent possui (hasArchitecture)

uma **AgentArchitecture**. No contexto de agentes com LLMs, a arquitetura deve prever como o componente LLM se integra aos ciclos de percepção, deliberação e ação do agente.

- **AgentCapability («Kind» ou «Quality»):** Habilidade intrínseca de um agente (e.g., **PerceptionCapability**, **ActionCapability**, **ReasoningCapability**, **LearningCapability**, **CommunicationCapability**). Um **Agent** possui (possesses) múltiplas **AgentCapabilities**.
- **GenerativeCapability («Subkind» de AgentCapability):** Capacidade específica de gerar, modificar ou sintetizar conteúdo (texto, código, imagens, etc.) utilizando técnicas de Inteligência Artificial Generativa, predominantemente através de LLMs. Esta capacidade pode ser decomposta em sub-capacidades mais específicas como **TextGenerationCapability**, **QuestionAnsweringCapability**, **SummarizationCapability**, **TranslationCapability**, **CodeGenerationCapability**, entre outras, dependendo da funcionalidade do LLM subjacente e dos objetivos do agente.
- **LLMServiceAccessPoint («Kind»):** Representa o ponto de acesso ou a interface através da qual um **Agent** interage com um serviço de LLM (local ou remoto). Este conceito é crucial para modelar a dependência e a configuração do acesso ao LLM.

4.3.2 Subontologia de Agentes com Capacidades Generativas (LLMs)

A crescente proeminência dos LLMs como componentes centrais em agentes inteligentes demanda uma representação ontológica mais detalhada de suas características e de como se integram à cognição e ao comportamento de um agente. Esta subontologia visa expandir os conceitos apresentados anteriormente, focando nos aspectos específicos de agentes que utilizam LLMs.

Um **Agent** que utiliza um LLM, aqui denominado **GenerativeAgent**, possui uma **GenerativeCapability** proeminente. A **AgentArchitecture** de um **GenerativeAgent** deve contemplar mecanismos para:

- **Gerenciamento de Prompts (PromptEngineeringCapability como uma especialização de ReasoningCapability):** A habilidade de formular, refinar e adaptar prompts para obter as respostas desejadas do LLM. Isso pode envolver o uso de **PromptTemplates**.
- **Interpretação de Saídas do LLM (LLMOutputProcessingCapability):** A capacidade de processar, validar, e extrair informação relevante da saída gerada pelo LLM, convertendo-a em **AgentBeliefs** ou utilizando-a para disparar **AgentActions**.

- **Gerenciamento de Contexto da Conversa (DialogManagementCapability):** Para agentes conversacionais, a capacidade de manter o histórico da interação e fornecer contexto relevante ao LLM para interações coerentes e contextualizadas.
- **Alinhamento com Objetivos (GoalAlignmentMechanism):** Mecanismos para garantir que as capacidades generativas do LLM sejam utilizadas em prol dos **AgentGoals**, possivelmente envolvendo a filtragem ou o pós-processamento das saídas do LLM.

No que tange às **AgentBeliefs** de um **GenerativeAgent**, estas podem ser de diferentes naturezas:

- Crenças sobre o domínio de aplicação (obtidas de fontes tradicionais ou do próprio LLM).
- Crenças sobre as capacidades e limitações do LLM que utiliza (e.g., "o LLM é bom em resumir, mas pode alucinar fatos"). Isso pode ser representado como **LLMMetaBelief**.
- Crenças derivadas diretamente das saídas do LLM, que foram processadas e consideradas válidas pelo agente.

O LLM em si pode ser visto como uma vasta fonte de conhecimento implícito, que o agente acessa através de sua **GenerativeCapability** e do **LLMServiceAccessPoint**.

As **AgentActions** de um **GenerativeAgent** incluem, mas não se limitam a:

- **InvokeLLMAction:** Uma ação interna que envia um prompt para o LLM e recebe a resposta.
- **GenerateTextAction:** Uma ação externa (e.g., enviar uma mensagem a um usuário) cujo conteúdo foi gerado ou mediado por um LLM.
- **AnalyzeContentWithLLMAction:** Ação de utilizar o LLM para analisar um texto, imagem ou outro dado (e.g., análise de sentimento, extração de entidades).

Os **AgentPlans** podem incluir sequências de ações que envolvem múltiplas invocações ao LLM, possivelmente com processamento intermediário dos resultados, para alcançar objetivos complexos (e.g., um plano para responder a uma pergunta complexa de um estudante pode envolver: 1. Decompor a pergunta, 2. Buscar informações relevantes (talvez com o LLM), 3. Gerar uma explicação inicial com o LLM, 4. Pedir ao LLM para simplificar a explicação, 5. Apresentar a explicação ao estudante).

4.3.3 Conceitos de Comportamento e Raciocínio (Expandido)

- **AgentGoal («Mode»)**: Estado ou situação que um **Agent** busca (*pursues*). Para **GenerativeAgents**, os objetivos podem incluir gerar explicações personalizadas, fornecer feedback construtivo, facilitar discussões, etc.
- **AgentBelief («Mode»)**: Representação interna do **Agent** sobre o mundo. Um **Agent** mantém (*holds*) **AgentBeliefs**. Pode ser relacionado a **InformationResource** da OEACD e, como discutido, ao conhecimento acessado via LLM.
- **AgentPlan («Kind»)**: Sequência de **AgentActions** que um **Agent** adota (*adopts*) para atingir um **AgentGoal**.
- **AgentAction («Kind»)**: Ação executada (*executes*) por um **Agent**. Pode especializar **Interaction** ou **Activity** da OEACD. Pode ter como alvo (*targets*) elementos do EA.
- **AgentPerception («Kind»)**: Processo pelo qual um **Agent** percebe (*perceives*) elementos ou estados do EA. Para agentes com LLMs, a percepção pode envolver a análise de entradas de texto do usuário para identificar intenções ou extrair informações chave que serão usadas para formular prompts.

4.3.4 Conceitos de Organização e Interação (Expandido)

- **MASOrganization («Kind»)**: Estrutura social do MAS, definindo (*definesRole*) **AgentRoles**.
- **AgentRole («Role»)**: Papel desempenhado (*playsRole*) por um **Agent** dentro da **MASOrganization** (e.g., **TutorAgent**, **StudentCompanionAgent**, **ContentModeratorAgent**).
- **InteractionProtocol («Kind»)**: Regras que governam (*governs*) uma **AgentInteraction**. Protocolos podem precisar ser adaptados para interações mediadas por LLMs, considerando a natureza probabilística e por vezes menos estruturada das respostas.
- **AgentInteraction («Relator» ou «Kind»)**: Comunicação entre **Agents** ou entre um **Agent** e um **Participant** humano. Envolve (*involves*) múltiplos participantes, conforma-se a (*conformsTo*) um **InteractionProtocol** e consiste em (*consistsOf*) **Messages**. Pode especializar **Interaction** da OEACD.
- **Message («Kind»)**: Unidade de comunicação com conteúdo (*hasContent*), performativo, remetente, destinatário. O **MessageContent** pode ser gerado por um LLM.

4.3.5 Integração com OEACD

A integração ocorre por especialização ou associação dos novos conceitos com os existentes na OEACD:

- `Agent` pode ser um `Participant` ou interagir com eles.
- `AgentAction/AgentInteraction` podem especializar `Activity/Interaction`.
- `AgentBelief` pode representar `InformationResources`, e o conhecimento acessado via LLM pode ser considerado uma forma dinâmica de `InformationResource`.
- `AgentPerception` relaciona-se com `Context`.
- O `LearningEcosystem` é o ambiente do MAS.

Placeholder: Diagrama OntoUML - Conceitos Centrais MAS e Agente (OEACD-MAS)

Figura 8 – Extensão OEACD-MAS: Modelagem dos conceitos centrais de Agente e MAS. (Referenciar Capítulo 2 para diagramas base da OEACD).

Placeholder: Diagrama OntoUML - Organização, Interação e Capacidades Generativas (OEACD-MAS)

Figura 9 – Extensão OEACD-MAS: Modelagem dos conceitos de Organização, Interação e a especialização para Agentes com Capacidades Generativas.

4.4 Fundamentação Adicional: Uma Ontologia para Ecosystemas Cognitivos

Para enriquecer a compreensão e modelagem de EAs, especialmente aqueles que visam promover aspectos cognitivos da aprendizagem e que podem se beneficiar de avaliação e feedback inteligentes (potencialmente mediados por agentes), apresentamos a seguir uma ontologia desenvolvida para Ecosystemas Cognitivos. Esta ontologia, originalmente detalhada no Apêndice A desta tese, é aqui integrada para expandir a discussão e fornecer uma base conceitual complementar à OEACD-MAS, particularmente no que tange à modelagem do aprendiz, do domínio de conhecimento, da avaliação e do feedback em contextos de aprendizagem inteligente.

4.4.1 Introdução à Ontologia para Ecosistemas Cognitivos

Os Ecosistemas Cognitivos são ambientes de aprendizagem que buscam promover o desenvolvimento de habilidades cognitivas e socioemocionais dos aprendizes, utilizando tecnologias inteligentes para personalizar e adaptar o processo de ensino-aprendizagem. A ontologia aqui descrita visa fornecer uma representação formal e compartilhada dos principais conceitos e relações envolvidos nesses ecossistemas, com foco na avaliação da aprendizagem e no uso de Inteligência Artificial Generativa.

4.4.2 Objetivos da Ontologia para Ecosistemas Cognitivos

Os principais objetivos desta ontologia são:

- Fornecer um vocabulário comum e uma estrutura de conhecimento compartilhada para pesquisadores, desenvolvedores e educadores que trabalham com Ecosistemas Cognitivos e avaliação da aprendizagem.
- Facilitar a integração de diferentes ferramentas e sistemas utilizados em Ecosistemas Cognitivos, como Ambientes Inteligentes de Aprendizagem (SLEs), Sistemas de Tutoria Inteligente (ITSs) e ferramentas de avaliação automatizada.
- Apoiar o desenvolvimento de agentes inteligentes capazes de raciocinar sobre o processo de aprendizagem, personalizar o ensino e fornecer feedback adaptativo aos aprendizes.
- Servir como base para a criação de modelos de aprendizes mais completos e precisos, que considerem não apenas o conhecimento e as habilidades dos aprendizes, mas também seus aspectos cognitivos, emocionais e sociais.

4.4.3 Módulos da Ontologia para Ecosistemas Cognitivos

A ontologia é organizada em módulos que representam os principais aspectos dos Ecosistemas Cognitivos:

4.4.3.1 Módulo de Domínio

O Módulo de Domínio representa o conhecimento a ser aprendido, incluindo conceitos, tópicos, relações e competências. Este módulo é fundamental para a personalização do ensino e para a avaliação da aprendizagem, pois permite que o sistema compreenda o que o aprendiz precisa aprender e como o conhecimento está estruturado. Os principais conceitos deste módulo são:

- Domínio: Representa uma área de conhecimento, como matemática, física, história, etc.;
- Conceito: Representa uma ideia ou noção fundamental dentro de um domínio;
- Tópico: Representa um assunto específico dentro de um conceito ou domínio;
- Relação: Representa as relações entre os conceitos e tópicos, como hierarquia, precedência, similaridade, etc.;
- Competência: Representa as habilidades e conhecimentos que o aprendiz deve adquirir em relação a um determinado conceito ou tópico.

4.4.3.2 Módulo de Aprendiz

O Módulo de Aprendiz representa o aprendiz e suas características individuais, como perfil, estilo de aprendizagem, conhecimento prévio, objetivos de aprendizagem e progresso. Este módulo é essencial para a personalização do ensino e para o fornecimento de feedback adaptativo, permitindo que o sistema se adapte às necessidades e características individuais de cada aprendiz. Os principais conceitos deste módulo são:

- Aprendiz: Representa um estudante ou usuário do sistema;
- Perfil: Representa o perfil do aprendiz, incluindo suas características pessoais, preferências e histórico;
- Estilo de Aprendizagem: Representa o estilo de aprendizagem do aprendiz, como visual, auditivo, cinestésico, etc.;
- Conhecimento Prévio: Representa o conhecimento que o aprendiz já possui antes de iniciar o processo de aprendizagem;
- Objetivo de Aprendizagem: Representa os objetivos que o aprendiz deseja alcançar com o processo de aprendizagem;
- Progresso: Representa o progresso do aprendiz no processo de aprendizagem.

Placeholder: Figura 13 da tese original - Módulo de Aprendiz da Ontologia para Ecossistemas Cognitivos

Figura 10 – Módulo de Aprendiz da Ontologia para Ecossistemas Cognitivos.

4.4.3.3 Módulo de Avaliação

O Módulo de Avaliação representa os diferentes tipos de avaliação, critérios e métricas utilizados no processo de avaliação da aprendizagem. Este módulo é fundamental para o framework proposto, pois define como a avaliação automatizada será realizada. Os principais conceitos deste módulo são:

- Avaliação: Representa uma avaliação da aprendizagem;
- Tipo de Avaliação: Representa o tipo de avaliação, como diagnóstica, formativa, somativa, etc.;
- Instrumento de Avaliação: Representa o instrumento utilizado para realizar a avaliação, como questionário, teste, projeto, etc.;
- Critério de Avaliação: Representa os critérios utilizados para avaliar o desempenho do aprendiz;
- Métrica: Representa as métricas utilizadas para medir o desempenho do aprendiz;
- Resultado: Representa o resultado da avaliação.

Placeholder: Figura 14 da tese original - Módulo de Avaliação da Ontologia para Ecossistemas Cogniti

Figura 11 – Módulo de Avaliação da Ontologia para Ecossistemas Cognitivos.

4.4.3.4 Módulo de Feedback

O Módulo de Feedback representa os diferentes tipos de feedback e estratégias de intervenção que podem ser utilizados para apoiar o processo de aprendizagem. Este módulo é essencial para o framework proposto, pois define como o feedback personalizado será fornecido aos aprendizes. Os principais conceitos deste módulo são:

- Feedback: Representa um feedback fornecido ao aprendiz;
- Tipo de Feedback: Representa o tipo de feedback, como corretivo, explicativo, sugestivo, motivacional, etc.;
- Estratégia de Intervenção: Representa as estratégias utilizadas para intervir no processo de aprendizagem, como suporte personalizado, adaptação de conteúdo, alertas para professores, etc.;

- Conteúdo do Feedback: Representa o conteúdo do feedback, incluindo texto, imagens, vídeos, etc.;
- Momento do Feedback: Representa o momento em que o feedback é fornecido, como imediato, atrasado, etc.;
- Impacto do Feedback: Representa o impacto do feedback no processo de aprendizagem.

Placeholder: Figura 15 da tese original - Módulo de Feedback da Ontologia para Ecosystemas Cogniti

Figura 12 – Módulo de Feedback da Ontologia para Ecosystemas Cognitivos.

4.4.4 Implementação da Ontologia para Ecosystemas Cognitivos

A ontologia foi implementada utilizando a linguagem OWL (Web Ontology Language) e a ferramenta Protégé. A Figura 13 (originalmente Figura 16 da tese) apresenta uma captura de tela da ontologia no Protégé. O código OWL da ontologia está disponível no repositório do projeto: <<https://github.com/otaviolube/smart-learning-assessment>>.

Placeholder: Figura 16 da tese original - Ontologia para Ecosystemas Cognitivos no Protégé

Figura 13 – Ontologia para Ecosystemas Cognitivos no Protégé.

4.4.5 Avaliação da Ontologia para Ecosystemas Cognitivos

A ontologia foi avaliada em termos de consistência, completude e adequação ao domínio. A avaliação foi realizada utilizando o reasoner HermiT, disponível no Protégé, e por especialistas em ontologias e em educação. Os resultados da avaliação indicaram que a ontologia é consistente, completa e adequada ao domínio de Ecosystemas Cognitivos e avaliação da aprendizagem. Algumas sugestões de melhoria foram incorporadas à versão final da ontologia, como a inclusão de mais conceitos relacionados a aspectos emocionais e sociais da aprendizagem.

4.4.6 Uso da Ontologia para Ecosystemas Cognitivos no Framework

A ontologia para Ecosystemas Cognitivos é utilizada no Smart Learning Assessment Framework (SLAF) como base para a representação do conhecimento e para o raciocínio dos agentes inteligentes. Ela fornece uma estrutura formal para a representação dos conceitos, relações e regras relacionados aos Ecosystemas Cognitivos, Smart Learning Environments, avaliação da aprendizagem e Inteligência Artificial Generativa. Os agentes do sistema utilizam a ontologia para:

- Compreender o domínio de conhecimento e os conceitos relacionados;
- Modelar o perfil e as características dos aprendizes;
- Definir os critérios e métricas de avaliação;
- Selecionar os tipos de feedback mais adequados para cada situação;
- Raciocinar sobre o processo de aprendizagem e tomar decisões pedagógicas.

A ontologia também serve como base para a integração do framework com outros sistemas educacionais, fornecendo um vocabulário comum e uma estrutura de conhecimento compartilhada. A integração desta ontologia com a OEACD-MAS pode fornecer uma visão ainda mais completa para o desenvolvimento de MAS em EAs, onde os agentes não apenas operam no ecossistema, mas também possuem um entendimento profundo dos aspectos cognitivos e avaliativos da aprendizagem.

4.5 Validação Preliminar da OEACD-MAS Expandida

A validação preliminar da OEACD-MAS, agora expandida para incluir um foco maior em agentes generativos e complementada pela ontologia de ecossistemas cognitivos, foi realizada através da verificação de sua capacidade de representar os cenários dos estudos de caso (LIEd Ubíquo e GoodBot) e de responder às questões de competência levantadas. Por exemplo:

- **Questão:** Como representar um agente GoodBot que usa LLM para suporte psicossocial e da aprendizagem, considerando seu perfil e progresso?
 - **Resposta OEACD-MAS e Ontologia Cognitiva:** Instanciar um Agent (GoodBot) que possesse uma `GenerativeCapability` (com sub-capacidades como `TextGenerationCapability` e `DialogManagementCapability`) e `playsRole` de `SupportAgent`. Este agente acessaria informações do `Aprendiz` (do Módulo de Aprendiz da ontologia cognitiva), como seu `Perfil`, `ConhecimentoPrévio` e `Progresso`, para personalizar a interação gerada pelo LLM. As interações seriam modeladas como `AgentInteraction` consistindo em `Messages` cujo conteúdo é gerado pelo LLM, visando atingir `AgentGoals` como "melhorar o bem-estar do estudante" ou "esclarecer dúvida sobre o conteúdo X".
- **Questão:** Como modelar a interação entre o Agente Recomendador e o Agente de Perfil no LIEd Ubíquo, onde o Agente Recomendador pode usar um LLM para justificar suas recomendações?

- **Resposta OEACD-MAS:** Definir um `InteractionProtocol` que governa a `AgentInteraction` entre o `RecommenderAgent` e o `ProfileAgent`. O `RecommenderAgent` poderia possuir uma `GenerativeCapability` para, após obter dados do perfil, gerar justificativas textuais personalizadas para as recomendações, utilizando um LLM. Essas justificativas fariam parte do `MessageContent` enviado ao usuário ou a outro agente.

Essa instanciação com exemplos concretos ajudou a refinar os conceitos e relações propostos, indicando que a extensão e a integração fornecem os elementos necessários para modelar os aspectos de MAS relevantes para o framework FC-MAS-EA, especialmente aqueles que envolvem IAG. Uma validação mais formal e externa, no entanto, permanece como trabalho futuro.

4.6 Considerações Finais do Capítulo

A OEACD-MAS, enriquecida com uma subontologia detalhada para agentes com capacidades generativas e complementada pela ontologia para ecossistemas cognitivos, representa um passo importante para fornecer uma base conceitual unificada e abrangente para o design de EAs e a construção dos MAS que os habitam. Ao estender a OEACD com conceitos específicos de MAS e IAG, e ao integrar uma visão sobre os aspectos cognitivos da aprendizagem, mantendo a consistência ontológica através do uso de OntoUML e UFO, criamos um vocabulário compartilhado mais robusto. Este vocabulário fundamenta o framework FC-MAS-EA e facilita a comunicação entre as diferentes disciplinas envolvidas no desenvolvimento de MAS educacionais inteligentes e adaptativos, capazes de alavancar o potencial dos LLMs de forma significativa e pedagogicamente embasada.

5 FC-MAS-EA: Framework para Construção de MAS Inteligentes em Ecossistemas de Aprendizagem

Este capítulo apresenta em detalhes o artefato central desta tese: o Framework para Construção de Sistemas Multiagentes Inteligentes em Ecossistemas de Aprendizagem (FC-MAS-EA). Conforme delineado na metodologia DSR (Capítulo ??), este framework visa preencher a lacuna existente, oferecendo um guia sistemático e conceitualmente embasado para o processo de concepção e desenvolvimento de MAS que operam em EAs, posicionando-se como complementar a abordagens focadas no design do ecossistema em si, como a de Silveira (SILVEIRA, 2022).

5.1 Visão Geral e Princípios

O FC-MAS-EA é um framework conceitual que estrutura o processo de construção de MAS para EAs, desde a análise inicial de requisitos até a integração do sistema no ecossistema. Ele não prescreve tecnologias ou ferramentas de implementação específicas, mas sim oferece um conjunto de fases, atividades e conceitos que devem ser considerados para garantir um desenvolvimento mais robusto, flexível e alinhado aos objetivos pedagógicos e às características do EA.

Os princípios norteadores do FC-MAS-EA são:

- **Orientação à Ontologia:** O framework utiliza a ontologia OEACD-MAS (Capítulo ??) como base conceitual compartilhada, garantindo que o design do MAS e de seus agentes esteja semanticamente alinhado com a representação do Ecossistema de Aprendizagem.
- **Modularidade e Reutilização:** O framework incentiva a concepção de agentes com capacidades bem definidas e o design de arquiteturas que facilitem a reutilização de componentes e a extensibilidade do MAS.
- **Foco na Construção do Agente:** Diferentemente de frameworks focados no design macro do ecossistema, o FC-MAS-EA detalha as etapas de design da organização do MAS e, crucialmente, o design interno dos agentes (arquitetura, capacidades, raciocínio), incluindo a integração de IA Generativa.

- **Processo Iterativo e Incremental:** Embora apresentado em fases sequenciais, o framework suporta uma abordagem iterativa e incremental, permitindo refinar o design e a implementação com base em feedback e avaliações parciais.
- **Complementaridade:** O framework foi concebido para complementar abordagens existentes, como o framework de Silveira (SILVEIRA, 2022), focando especificamente na instanciação dos componentes inteligentes (os agentes) dentro do ecossistema projetado.

5.2 Fundamentação Ontológica: O Papel da OEACD-MAS

A ontologia OEACD-MAS, proposta no Capítulo ??, desempenha um papel crucial como espinha dorsal conceitual do framework FC-MAS-EA. Ela fornece o vocabulário e a estrutura semântica necessários para:

1. **Compreender e Modelar o Contexto:** Permite descrever o Ecossistema de Aprendizagem (participantes, recursos, atividades, contexto) onde o MAS irá operar, utilizando os conceitos herdados e estendidos da OEACD.
2. **Especificar Requisitos do MAS:** Ajuda a definir os objetivos do MAS e os requisitos dos agentes em termos dos conceitos ontológicos (e.g., "O Agente Tutor deve ser capaz de realizar a Atividade X", "O Agente Recomendador deve acessar o Perfil do Aprendiz Y").
3. **Guiar o Design do MAS e dos Agentes:** Os conceitos da OEACD-MAS (e.g., `Agent`, `AgentCapability`, `AgentArchitecture`, `MASOrganization`, `InteractionProtocol`) servem como blocos de construção conceituais durante as fases de design, garantindo consistência e clareza.
4. **Facilitar a Comunicação e Interoperabilidade:** Ao basear a comunicação entre agentes e a interação com o ecossistema em uma ontologia compartilhada, o framework promove a interoperabilidade semântica.
5. **Conectar Design e Implementação:** A ontologia serve como uma ponte entre o modelo conceitual do MAS/EA e sua implementação concreta, ajudando a mapear conceitos para componentes de software.

Ao longo da descrição do processo do framework (Seção 5.4), será destacado como os conceitos da OEACD-MAS são utilizados em cada fase.

5.3 Arquitetura Conceitual do Framework

O FC-MAS-EA não define uma arquitetura de software específica para o MAS resultante, mas sim uma **arquitetura conceitual para o processo de construção**. Essa arquitetura organiza o processo em fases lógicas, cada uma focada em um conjunto específico de decisões de design e atividades de desenvolvimento. A Figura 14 ilustra as fases principais do processo proposto pelo framework.

Placeholder: Diagrama das Fases do FC-MAS-EA

Figura 14 – Fases do Processo de Construção Guiado pelo FC-MAS-EA.

As fases principais são:

1. **Análise e Requisitos:** Compreensão do problema e definição do que o MAS deve fazer.
2. **Design do MAS:** Definição da estrutura organizacional e das interações gerais do sistema.
3. **Design dos Agentes:** Especificação detalhada da arquitetura interna e das capacidades de cada tipo de agente.
4. **Implementação:** Codificação e teste dos agentes e da infraestrutura do MAS.
5. **Integração e Implantação:** Colocação do MAS em operação dentro do Ecossistema de Aprendizagem.

Essas fases são interconectadas e podem ser revisitadas iterativamente. A seção seguinte detalha as atividades e os artefatos esperados em cada fase.

5.4 Processo de Construção Guiado pelo FC-MAS-EA

O framework propõe um processo estruturado, dividido em fases, para guiar a construção do MAS. Cada fase utiliza e refina os conceitos da ontologia OEACD-MAS.

5.4.1 Fase 1: Análise e Requisitos

Objetivo: Compreender o contexto do Ecossistema de Aprendizagem, identificar as necessidades que o MAS deve suprir e definir claramente seus objetivos e requisitos funcionais e não funcionais.

Atividades:

1. **Modelagem do Contexto do EA (usando OEACD-MAS):** Descrever os **Participants**, **LearningResources**, **Activitys**, **Tools** e **Contexts** relevantes do EA onde o MAS atuará, utilizando os conceitos da OEACD-MAS.
2. **Identificação de Necessidades e Oportunidades:** Analisar o EA modelado para identificar problemas, gargalos ou oportunidades onde um MAS poderia agregar valor (e.g., falta de feedback personalizado, dificuldade de encontrar recursos, necessidade de suporte socioemocional).
3. **Definição dos Objetivos do MAS:** Estabelecer os objetivos gerais e específicos que o MAS deve alcançar no EA (e.g., "Melhorar o engajamento dos alunos", "Fornecer recomendações de atividades personalizadas", "Oferecer suporte conversacional para dúvidas conceituais").
4. **Especificação de Requisitos:** Detalhar os requisitos funcionais (o que o sistema deve fazer) e não funcionais (qualidade, desempenho, segurança, etc.). Utilizar conceitos da OEACD-MAS para descrever as interações esperadas entre o MAS e os elementos do EA (e.g., "O MAS deve ser capaz de **perceive** o **LearningProgress** do **Learner**", "O MAS deve **execute** **AgentActions** que modifiquem **LearningResources**").

Artefatos: Documento de Requisitos, Modelo do Contexto do EA (instanciação parcial da OEACD-MAS), Lista de Objetivos do MAS.

5.4.2 Fase 2: Design do MAS

Objetivo: Definir a arquitetura organizacional do MAS, especificando os tipos de agentes que o comporão, seus papéis e como eles interagirão entre si e com o ambiente.

Atividades:

1. **Escolha da Arquitetura Organizacional:** Definir como os agentes serão organizados (e.g., hierárquica, federada, baseada em equipes) e quais **MASOrganizations** serão instanciadas, considerando os objetivos e requisitos do MAS.
2. **Definição dos Tipos de Agentes e Papéis:** Identificar os diferentes tipos de **Agents** necessários para cumprir os objetivos (e.g., Agente Tutor, Agente Recomendador, Agente de Interface, Agente de Diálogo). Para cada tipo, definir os **AgentRoles** que eles desempenharão na organização.
3. **Especificação das Interações:** Definir os **InteractionProtocols** que governarão a comunicação entre os diferentes tipos de agentes e entre os agentes e os participantes

humanos no EA. Especificar os tipos de **Messages** a serem trocadas e seu conteúdo (referenciando conceitos da OEACD-MAS).

4. **Mapeamento para OEACD-MAS:** Refinar a instanciação da OEACD-MAS, detalhando como os **Agents**, **AgentRoles** e **AgentInteractions** se relacionam com os demais elementos do **LearningEcosystem**.

Artefatos: Modelo de Arquitetura Organizacional do MAS, Especificação dos Tipos de Agentes e Papéis, Especificação dos Protocolos de Interação, Modelo OEACD-MAS Refinado.

5.4.3 Fase 3: Design dos Agentes

Objetivo: Detalhar o design interno de cada tipo de agente definido na fase anterior, especificando sua arquitetura, capacidades, base de conhecimento e mecanismos de raciocínio/aprendizagem.

Atividades:

1. **Escolha da Arquitetura Interna do Agente:** Para cada tipo de agente, selecionar a **AgentArchitecture** mais adequada (e.g., BDI, reativa, híbrida) com base em seus papéis e requisitos de complexidade.
2. **Especificação das Capacidades (**AgentCapability**):** Detalhar as capacidades específicas que cada agente deve possuir (e.g., **ReasoningCapability** para inferir o estado do aluno, **GenerativeCapability** para criar explicações, **CommunicationCapability** para interagir via FIPA ACL). Especificar como essas capacidades serão realizadas (e.g., algoritmos, modelos de ML, integração com LLMs).
3. **Modelagem da Base de Conhecimento (**AgentBelief**):** Definir como o agente representará seu conhecimento sobre o domínio, sobre os outros agentes, sobre os participantes do EA e sobre o estado do ecossistema. Mapear essas crenças para os conceitos da OEACD-MAS (**InformationResource**, **LearnerProfile**, etc.).
4. **Design dos Mecanismos de Raciocínio e Decisão:** Especificar como o agente utilizará suas crenças e capacidades para deliberar sobre seus **AgentGoals**, gerar **AgentPlans** e selecionar **AgentActions**.
5. **Design da Percepção e Ação:** Definir como o agente perceberá (**AgentPerception**) informações relevantes do EA (mapeadas via OEACD-MAS) e como suas **AgentActions** afetarão o EA.

Artefatos: Especificação Detalhada de Cada Tipo de Agente (incluindo arquitetura, capacidades, modelo de conhecimento, mecanismos de raciocínio), Mapeamento Detalhado Agente-OEACD-MAS.

5.4.4 Fase 4: Implementação

Objetivo: Traduzir o design do MAS e dos agentes em código executável, utilizando linguagens de programação, plataformas de agentes e tecnologias apropriadas.

Atividades:

1. **Seleção de Tecnologias:** Escolher plataformas de desenvolvimento de agentes (e.g., JADE, JaCaMo, SPADE), linguagens de programação, bibliotecas de IA/ML, APIs de LLMs (se aplicável), e bancos de dados.
2. **Codificação dos Agentes:** Implementar a arquitetura interna, as capacidades, os mecanismos de raciocínio e a base de conhecimento de cada agente, conforme especificado na fase de design.
3. **Implementação da Infraestrutura do MAS:** Desenvolver a infraestrutura de comunicação, gerenciamento de ciclo de vida dos agentes e coordenação, se não fornecida pela plataforma escolhida.
4. **Testes Unitários e de Integração:** Testar os componentes individuais dos agentes e as interações entre eles.

Artefatos: Código Fonte dos Agentes e da Infraestrutura, Casos de Teste, Relatórios de Teste.

5.4.5 Fase 5: Integração e Implantação

Objetivo: Integrar o MAS desenvolvido ao Ecossistema de Aprendizagem alvo e colocá-lo em operação.

Atividades:

1. **Desenvolvimento de Adaptadores/Interfaces:** Criar os componentes necessários para conectar o MAS às ferramentas e fontes de dados existentes no EA (e.g., Moodle, bases de dados acadêmicas), utilizando APIs, plugins ou middleware, conforme aplicável e considerando o mapeamento com a OEACD-MAS.

2. **Configuração do Ambiente:** Preparar o ambiente de produção (servidores, bancos de dados, etc.) para a implantação do MAS.
3. **Implantação (Deployment):** Instalar e configurar o MAS no ambiente de produção.
4. **Testes de Sistema e Aceitação:** Realizar testes completos do MAS operando dentro do EA e obter a validação dos stakeholders (educadores, alunos).

Artefatos: MAS Implantado, Documentação de Implantação, Relatórios de Testes de Sistema/Aceitação.

5.5 Complementaridade com o Framework de Silveira (2022)

É fundamental destacar a relação de complementaridade entre o FC-MAS-EA e o framework proposto por Silveira (SILVEIRA, 2022) para o design de SLEs em EAs. Enquanto o framework de Silveira, também baseado na OEACD, foca em guiar o **design do ecossistema inteligente como um todo** – identificando quais componentes inteligentes (serviços, ferramentas) são necessários, como eles se relacionam e como se integram à arquitetura pedagógica e ao contexto do EA –, o FC-MAS-EA foca especificamente em como **construir os componentes inteligentes que são realizados como Sistemas Multiagentes**.

Em outras palavras:

- **Framework de Silveira (Design do Ecossistema):** Ajuda a responder "*Quais* agentes ou serviços inteligentes são necessários no EA e *onde* eles se encaixam?" (e.g., "Precisamos de um serviço de recomendação que considere o perfil do aluno e o contexto da atividade").
- **Framework FC-MAS-EA (Construção do MAS):** Ajuda a responder "*Como* construir esse serviço de recomendação *como um MAS*?" (e.g., "Como projetar os agentes recomendadores, suas capacidades, sua organização e suas interações para realizar a recomendação definida no design do ecossistema?").

O FC-MAS-EA utiliza a mesma base ontológica (OEACD, agora estendida para OEACD-MAS) para garantir o alinhamento entre o design do ecossistema e a construção dos agentes que o habitarão. As saídas do processo de design do ecossistema (guiado pelo framework de Silveira) podem servir como entrada para a Fase 1 (Análise e Requisitos) do FC-MAS-EA.

Esta complementaridade permite uma abordagem mais holística e robusta para a criação de Ecossistemas de Aprendizagem verdadeiramente inteligentes e adaptativos, onde tanto o design do ambiente quanto a construção de seus habitantes computacionais são guiados por princípios conceituais e metodológicos sólidos.

O capítulo seguinte (Capítulo ??) demonstrará como o FC-MAS-EA pode ser aplicado na prática para construir MAS distintos, ilustrando as fases do processo aqui descrito.

6 Educational Multi Agent Systems Builder

A avaliação de um framework conceitual como o FC-MAS-EA (Framework para Construção de Sistemas Multiagentes Inteligentes em Ecossistemas de Aprendizagem) requer a demonstração de sua aplicabilidade e utilidade na prática. Conforme a metodologia Design Science Research (DSR), a avaliação pode ocorrer através de estudos de caso, simulações, ou, como neste capítulo, através da construção e análise de um artefato significativo que instancia os princípios do framework. Para este fim, o desenvolvimento do EMASB (Educational Multi Agent System Builder) e da prova de conceito GoodBot servem como elementos centrais para a avaliação do FC-MAS-EA.

Este capítulo detalha a construção do EMASB, uma plataforma concebida para facilitar a criação de sistemas multiagentes educacionais, e discute como sua arquitetura e funcionalidades refletem os preceitos do framework proposto. Adicionalmente, explora-se o GoodBot, um agente de suporte psicossocial e de aprendizagem desenvolvido a partir do EMASB, e sua potencial integração com o LIED Ubíquo. Por fim, são apresentadas considerações sobre os testes iniciais do EMASB com um grupo de professores, fornecendo insights sobre a validação do ambiente e, por extensão, do próprio framework.

6.1 EMASB: Plataforma para Construção de Sistemas Multiagentes Educacionais

O EMASB (disponível em <<https://emasb.vercel.app/>>) é uma plataforma inovadora projetada para simplificar o processo de criação, gerenciamento e implementação de sistemas multiagentes (MAS) baseados em Inteligência Artificial (IA), com foco no aprimoramento do processo de aprendizagem. Ele surge como uma materialização dos conceitos e fases propostos pelo FC-MAS-EA, buscando oferecer uma ferramenta que auxilie pesquisadores e educadores a desenvolverem soluções educacionais inteligentes e personalizadas.

6.1.1 Arquitetura e Ambiente do EMASB

O EMASB foi concebido como um projeto de pesquisa de doutorado com o intuito de investigar como sistemas multiagentes inteligentes podem transformar o processo educacional. Sua arquitetura é modular e visa oferecer flexibilidade na definição dos componentes de um MAS educacional.

Os principais recursos e componentes arquiteturais do EMASB incluem:

- **Criação de Agentes Inteligentes Personalizados:** A plataforma permite a criação de agentes com diferentes personalidades, papéis e funções (e.g., Tutor, Mentor, Companheiro de Estudo, Avaliador). Os usuários podem configurar os conhecimentos específicos de cada agente, alinhando-os com os objetivos pedagógicos. Esta funcionalidade está diretamente ligada à fase de "Design dos Agentes" do FC-MAS-EA e à ontologia OEACD-MAS, que define `AgentRole` e `AgentCapability`.
- **Colaboração Multiagente:** O EMASB facilita o desenvolvimento de sistemas onde múltiplos agentes trabalham cooperativamente para fornecer uma experiência de aprendizado abrangente e integrada. A definição de como os agentes interagem entre si e com os estudantes é um aspecto crucial, refletindo a fase de "Design do MAS" e os conceitos de `MASOrganization` e `AgentInteraction` da OEACD-MAS.
- **Adaptação ao Aprendiz:** Um dos pilares do EMASB é a capacidade dos agentes de se adaptarem ao ritmo, estilo de aprendizagem e necessidades individuais de cada estudante, oferecendo suporte personalizado. Isso se alinha com os objetivos de personalização em EAs e com a necessidade de modelar o `LearnerProfile` (conforme discutido na ontologia para ecossistemas cognitivos no Capítulo 4).
- **Integração com IA Generativa (LLMs):** A plataforma permite a utilização de modelos avançados de IA, como Grandes Modelos de Linguagem (LLMs), para gerar conteúdo educacional dinâmico, interativo e conversacional. Isso reflete a importância da `GenerativeCapability` na OEACD-MAS e a crescente relevância da IAG na educação.
- **Análise de Desempenho:** O EMASB prevê mecanismos para acompanhar o progresso dos estudantes, com funcionalidades de análise detalhada e geração de insights acionáveis para educadores e para os próprios agentes (para autoajuste).
- **Interface de Configuração Intuitiva:** Busca-se oferecer uma interface que permita a configuração dos aspectos dos agentes educacionais sem a necessidade de programação extensiva, democratizando o acesso à criação de MAS educacionais.

O processo de construção de um sistema multiagente no EMASB é idealizado para ser simples e intuitivo, seguindo três etapas principais:

1. **Definição dos Agentes:** Configuração das personalidades, funções, conhecimentos e capacidades de cada agente no sistema.

2. **Estabelecimento de Interações:** Definição dos protocolos e fluxos de interação entre os agentes e entre agentes e estudantes para criar uma experiência coesa e pedagogicamente rica.
3. **Implementação e Monitoramento:** Lançamento do sistema no ambiente de aprendizagem e acompanhamento de seu desempenho com análises e feedback.

Essas etapas espelham as fases do FC-MAS-EA, desde a análise de requisitos (implícita na definição dos agentes e seus objetivos) até a implementação e avaliação.

6.1.2 Implicações do EMASB para a Validação do Framework FC-MAS-EA

A construção do EMASB representa uma forma de validação do FC-MAS-EA por instanciamento. Ao desenvolver uma plataforma que incorpora os princípios e fases do framework, demonstra-se a viabilidade e a utilidade dos conceitos propostos.

As principais implicações são:

- **Operacionalização dos Conceitos Ontológicos:** O EMASB força a operacionalização dos conceitos definidos na OEACD-MAS. Por exemplo, ao permitir a criação de um "Agente Tutor com Capacidade Generativa", a plataforma está instanciando os conceitos de *Agent*, *AgentRole* (Tutor), e *GenerativeCapability*.
- **Teste das Fases do Framework:** O fluxo de criação de MAS no EMASB (definir agentes, interações, implementar) simula a aplicação das fases do FC-MAS-EA, permitindo identificar gargalos, necessidades de detalhamento ou pontos de melhoria no próprio framework.
- **Demonstração de Flexibilidade:** Ao permitir a criação de diferentes tipos de agentes e configurações de MAS, o EMASB ajuda a demonstrar a flexibilidade do framework em acomodar diversos cenários educacionais e tecnológicos (incluindo o uso de LLMs).
- **Geração de Feedback para o Framework:** O processo de design e desenvolvimento do EMASB, bem como seu uso futuro, pode gerar feedback valioso para refinar o FC-MAS-EA e a ontologia OEACD-MAS.

O EMASB, portanto, não é apenas um produto, mas uma ferramenta de pesquisa e validação para o framework proposto nesta tese.

6.2 GoodBot: Uma Prova de Conceito Desenvolvida com EMASB

Para exemplificar a aplicação do EMASB e, por conseguinte, do FC-MAS-EA, foi desenvolvida uma prova de conceito (PoC) denominada GoodBot. O GoodBot é um sistema multiagente (inicialmente podendo ser um agente único com múltiplas capacidades) focado no apoio psicossocial e da aprendizagem de estudantes de cursos de engenharia e computação. Este projeto específico foi submetido para publicação no congresso FIE 2025 (??).

O GoodBot foi concebido utilizando os princípios que norteiam o EMASB:

- **Agente com Capacidade Generativa:** O núcleo do GoodBot é um agente conversacional que utiliza um LLM para interagir com os estudantes, oferecer suporte emocional, responder a dúvidas sobre conteúdos acadêmicos, e fornecer orientação.
- **Personalização:** O GoodBot visa adaptar suas interações com base no perfil do estudante (quando disponível) e no contexto da conversa, buscando oferecer um suporte mais relevante e empático.
- **Múltiplos Papéis (Potencial):** Embora a PoC inicial possa focar em um agente principal, a arquitetura pensada com o EMASB permitiria a evolução para um MAS mais complexo, com agentes especializados (e.g., um agente focado em bem-estar, outro em dúvidas técnicas, um terceiro em gerenciamento de tempo).

A criação do GoodBot a partir da idealização do EMASB serve como um estudo de caso prático. Ele demonstra como a plataforma (e o framework subjacente) pode ser utilizada para construir um agente educacional com funcionalidades específicas, abordando um problema real no contexto do ensino superior em áreas de exatas e tecnologia.

6.2.1 Integração Potencial ao LIED Ubíquo

O Laboratório de Informática na Educação (LIED) da UFES tem explorado o conceito de LIED Ubíquo, um ecossistema de aprendizagem que visa integrar diversas ferramentas e recursos para apoiar os estudantes de forma contínua e contextualizada. O GoodBot, e de forma mais ampla, os sistemas criados com o EMASB, possuem um grande potencial de integração com o LIED Ubíquo.

Essa integração poderia se dar de diversas formas:

- **Componente de Suporte Inteligente:** O GoodBot poderia ser um dos agentes atuantes no LIED Ubíquo, oferecendo suporte conversacional e personalizado aos estudantes através das diversas interfaces do ecossistema.

- **Fonte de Dados para Adaptação:** As interações dos estudantes com o GoodBot poderiam gerar dados valiosos para o LIED Ubíquo, auxiliando na modelagem do perfil do aprendiz e na adaptação de outros recursos e atividades do ecossistema.
- **Canal de Intervenção:** O LIED Ubíquo poderia acionar o GoodBot para realizar intervenções proativas, por exemplo, ao detectar que um estudante está com dificuldades em um determinado tópico ou apresentando sinais de desengajamento.

A capacidade do EMASB de criar agentes modulares e com interfaces de comunicação bem definidas facilitaria essa integração, tornando o GoodBot um componente valioso dentro de um ecossistema de aprendizagem mais amplo como o LIED Ubíquo.

6.3 Avaliação do Ambiente EMASB por Professores

Como parte do processo de validação do EMASB e, indiretamente, do FC-MAS-EA, o ambiente está sendo apresentado e testado por um grupo de professores. Esta etapa é crucial para coletar feedback sobre a usabilidade da plataforma, a clareza dos conceitos apresentados e a percepção de utilidade da ferramenta para a criação de soluções educacionais.

Os testes com os professores buscam avaliar:

- **Facilidade de Uso:** Quão intuitivo é o processo de criação e configuração de agentes e sistemas multiagentes no EMASB.
- **Adequação das Funcionalidades:** Se os recursos oferecidos (criação de agentes, definição de interações, uso de IAG) atendem às necessidades percebidas pelos educadores.
- **Potencial Pedagógico:** A percepção dos professores sobre o potencial do EMASB para criar experiências de aprendizagem mais ricas, personalizadas e engajadoras.
- **Clareza Conceitual:** Se os conceitos do framework (agentes, capacidades, organização, etc.), que são refletidos na interface e funcionalidades do EMASB, são compreensíveis e úteis para os educadores.

Embora os resultados formais desta avaliação ainda estejam em fase de coleta e análise, o feedback preliminar tem sido positivo, especialmente em relação ao potencial de uso de agentes baseados em LLMs para suporte ao estudante. As sugestões e críticas coletadas nesta fase serão fundamentais para o refinamento tanto do EMASB quanto do próprio FC-MAS-EA, garantindo que ambos os artefatos sejam relevantes e práticos para a comunidade educacional.

6.4 Considerações sobre a Avaliação do Framework

A avaliação do FC-MAS-EA, realizada através da concepção e desenvolvimento inicial do EMASB, da prototipação do GoodBot e dos testes preliminares com educadores, fornece evidências iniciais da utilidade e aplicabilidade do framework. A capacidade de usar o framework para guiar o design de uma plataforma como o EMASB, que por sua vez permite a criação de agentes como o GoodBot, demonstra que os conceitos e fases propostos são coerentes e podem ser traduzidos em artefatos concretos.

A construção do EMASB, em particular, serviu como um rigoroso teste de estresse para os componentes do framework, desde a ontologia OEACD-MAS até as fases de design e implementação. A necessidade de definir claramente as funcionalidades, a arquitetura e o fluxo de usuário do EMASB exigiu uma aplicação prática dos princípios do FC-MAS-EA.

O GoodBot, como uma instância específica, ilustra o tipo de MAS educacional que pode ser fomentado pelo framework, especialmente no que tange à integração de capacidades de IAG para suporte direto aos estudantes. Sua potencial integração ao LIED Ubíquo reforça a visão do framework de que os MAS devem operar dentro de ecossistemas de aprendizagem mais amplos.

Os testes com professores, ainda que iniciais, são promissores e essenciais para garantir que o framework e as ferramentas dele derivadas sejam não apenas tecnicamente sólidos, mas também pedagogicamente relevantes e utilizáveis por aqueles que estão na linha de frente da educação.

Em suma, a avaliação apresentada neste capítulo, embora contínua, indica que o FC-MAS-EA oferece um caminho promissor para guiar a construção de sistemas multiagentes inteligentes em ecossistemas de aprendizagem, com potencial para enriquecer as práticas educacionais através do uso estratégico da inteligência artificial.

7 Conclusão e Perspectivas Futuras

Esta tese abordou o desafio de construir Sistemas Multiagentes (MAS) inteligentes para operar nos complexos e dinâmicos Ecossistemas de Aprendizagem (EAs) da era digital. Reconhecendo a lacuna de abordagens sistemáticas que guiem especificamente a *construção* desses agentes, em contraste com o *design* do ecossistema em si, propusemos o Framework para Construção de Sistemas Multiagentes Inteligentes em Ecossistemas de Aprendizagem (FC-MAS-EA).

7.1 Síntese do Trabalho

Iniciamos contextualizando a evolução da educação na cultura digital, o surgimento dos EAs e o potencial dos MAS, potencializado pela IA Generativa, para criar experiências de aprendizagem mais ricas e personalizadas (Capítulo 1). Identificamos o problema da falta de um guia metodológico para a construção desses MAS e estabelecemos o objetivo de propor o framework FC-MAS-EA.

A fundamentação teórica (Capítulo 2) revisou os conceitos de EAs, a ontologia OEACD (SILVEIRA, 2022), os fundamentos de MAS e Agentes Inteligentes, os princípios da IA Generativa e o estado da arte de MAS aplicados à educação.

A metodologia Design Science Research (DSR) guiou o desenvolvimento e a avaliação dos artefatos desta tese (Capítulo ??). O primeiro artefato foi a extensão da ontologia OEACD, resultando na OEACD-MAS (Capítulo 4), que incorporou conceitos essenciais de MAS e detalhou a modelagem de agentes com capacidades generativas, complementada por uma ontologia de apoio para ecossistemas cognitivos.

O segundo e principal artefato foi o framework FC-MAS-EA (Capítulo 5), que define um processo de cinco fases (Análise e Requisitos, Design do MAS, Design dos Agentes, Implementação, Integração e Implantação) para guiar a construção de MAS, utilizando a OEACD-MAS como base conceitual.

A aplicabilidade e flexibilidade do FC-MAS-EA foram demonstradas através de sua aplicação em dois estudos de caso distintos: LIEd Ubíquo e GoodBot (Capítulo ??), e aprofundada com a avaliação baseada na construção do EMASB (Capítulo 6).

7.2 Principais Contribuições

As contribuições desta tese podem ser sintetizadas em três eixos principais:

1. **Contribuição Ontológica (OEACD-MAS Expandida):** Propusemos e detalhamos uma extensão da ontologia OEACD (SILVEIRA, 2022) para incluir conceitos fundamentais de Sistemas Multiagentes, com ênfase em agentes com capacidades generativas (LLMs), e a integramos com uma ontologia de apoio para ecossistemas cognitivos. A OEACD-MAS (Capítulo 4) oferece um vocabulário mais completo e formal para modelar Ecossistemas de Aprendizagem que contenham agentes inteligentes.
2. **Contribuição Metodológica (FC-MAS-EA):** Desenvolvemos o framework conceitual FC-MAS-EA (Capítulo 5), que fornece um processo sistemático e guiado pela ontologia para a *construção* de MAS inteligentes em EAs.
3. **Contribuição Prática (EMASB, GoodBot e Avaliação):** Desenvolvemos o conceito e a estrutura inicial do EMASB (Educational Multi Agent System Builder) como uma plataforma para instanciamento do framework. Criamos a prova de conceito GoodBot, um agente de suporte baseado em LLM, e discutimos sua construção e potencial. A avaliação do framework (Capítulo 6) foi realizada com base na construção do EMASB e do GoodBot, e complementada por testes iniciais do EMASB com um grupo de professores.

7.3 Resposta às Questões de Pesquisa e Verificação da Hipótese

A questão central da pesquisa foi: "Como guiar sistematicamente a concepção e construção de Sistemas Multiagentes inteligentes, incluindo aqueles baseados em IA Generativa, de forma que sejam flexíveis, adaptáveis e eficazes para operar em Ecossistemas de Aprendizagem?".

Esta tese responde a essa questão através da proposta do framework FC-MAS-EA e da sua instanciamento parcial através do EMASB. A hipótese de que tal framework, fundamentado em uma ontologia estendida, poderia guiar sistematicamente a construção de MAS foi **preliminarmente corroborada** pela capacidade de conceber e iniciar o desenvolvimento de artefatos como o EMASB e o GoodBot, e pela avaliação inicial positiva de sua utilidade e aplicabilidade.

7.4 Status Atual do Projeto e Cronograma de Fechamento

No momento atual (Maio de 2025), o projeto de pesquisa encontra-se em fase de fechamento, com foco na consolidação dos resultados da avaliação do ambiente EMASB e do framework FC-MAS-EA. Os testes com o EMASB, incluindo a prova de conceito GoodBot, estão em andamento, e um grupo de professores está participando ativamente da avaliação da plataforma EMASB, fornecendo feedback valioso sobre sua usabilidade e potencial pedagógico.

A avaliação do framework, por sua vez, está sendo consolidada com base nos aprendizados da construção do EMASB, do desenvolvimento do GoodBot e dos resultados dos testes com os educadores. Este processo iterativo de construção e avaliação tem sido fundamental para refinar tanto os artefatos gerados quanto a própria compreensão teórica do problema.

A previsão para as próximas etapas e o fechamento do projeto é a seguinte:

- **Maio de 2025:**

- Finalização da coleta de dados da avaliação do EMASB com o grupo de professores.
- Análise aprofundada dos resultados da avaliação do EMASB e do desempenho da prova de conceito GoodBot.
- Consolidação final dos resultados da avaliação do framework FC-MAS-EA, incorporando todos os feedbacks e aprendizados.
- Intensificação da redação final da tese, integrando todas as análises e resultados.

- **Junho de 2025:**

- Conclusão da redação da tese, incluindo todos os capítulos revisados e a discussão final dos resultados.
- Revisão final e completa do documento da tese, incluindo formatação e verificação de referências.
- Submissão da versão final da tese para defesa.

Este cronograma visa garantir que todas as etapas de avaliação e consolidação sejam devidamente concluídas, resultando em um trabalho final robusto e bem fundamentado.

7.5 Limitações

Este trabalho possui limitações que devem ser reconhecidas:

- **Validação do Framework e EMASB:** Embora a avaliação esteja em andamento e os resultados preliminares sejam promissores, uma validação mais extensa do FC-MAS-EA e do EMASB, envolvendo um número maior de usuários e contextos diversos, será necessária para generalizar as conclusões sobre sua eficácia e usabilidade.
- **Nível de Desenvolvimento do EMASB:** O EMASB, como apresentado, é um protótipo em desenvolvimento, e nem todas as suas funcionalidades idealizadas foram completamente implementadas ou testadas em larga escala.
- **Validação da Ontologia:** A ontologia estendida OEACD-MAS passou por uma validação inicial através de sua aplicação. Uma avaliação mais rigorosa por especialistas externos seria benéfica.

7.6 Trabalhos Futuros

As limitações e os resultados desta pesquisa abrem diversas avenidas para trabalhos futuros:

1. **Validação e Evolução Contínua do FC-MAS-EA e EMASB:** Continuar os estudos empíricos com o FC-MAS-EA e o EMASB, expandindo os testes para diferentes instituições e perfis de usuários. Utilizar o feedback para evoluir ambos os artefatos.
2. **Desenvolvimento Completo e Disponibilização do EMASB:** Finalizar o desenvolvimento do EMASB como uma plataforma robusta e de código aberto, para que possa ser utilizada pela comunidade de pesquisadores e educadores.
3. **Criação de Novos Agentes com EMASB:** Incentivar e apoiar a criação de novos agentes e MAS educacionais utilizando o EMASB, explorando diferentes domínios de conhecimento e abordagens pedagógicas.
4. **Aprofundamento da Integração com LIED Ubíquo:** Concretizar a integração do GoodBot e de outros agentes criados com o EMASB ao ecossistema LIED Ubíquo, explorando sinergias e novas funcionalidades.
5. **Investigação de Padrões de Design para MAS Educacionais com IAG:** A partir da experiência com o EMASB e o GoodBot, investigar e documentar padrões de design específicos para MAS educacionais que utilizam IA Generativa.

7.7 Considerações Finais

A construção de Sistemas Multiagentes inteligentes representa uma fronteira promissora para a evolução dos Ecossistemas de Aprendizagem. O FC-MAS-EA e o EMASB, juntamente com a prova de conceito GoodBot, demonstram um caminho viável para enfrentar os desafios dessa construção, especialmente ao incorporar o poder da Inteligência Artificial Generativa.

Com o projeto em sua fase de fechamento, os resultados da avaliação do ambiente e do framework estão sendo consolidados, e o cronograma para os próximos meses foca na finalização da análise e na redação da tese. Acreditamos que os artefatos e conhecimentos gerados nesta pesquisa oferecem contribuições significativas para a área, abrindo portas para futuras investigações e para o desenvolvimento de Ecossistemas de Aprendizagem cada vez mais inteligentes, personalizados e eficazes.

Referências

- ABDELGHANI, R. et al. *GPT-3-driven pedagogical agents for training children's curious question-asking skills*. 2022. Preprint HAL-03890447. Disponível em: <<https://hal.inria.fr/hal-03890447>>.
- AYALA, G.; YANO, Y. Computational agents supporting the learning process. In: *Proceedings of International Conference on Computers in Education (ICCE)*. [S.l.: s.n.], 1997. p. 1–8.
- BENDER, E. M. et al. On the dangers of stochastic parrots: Can language models be too big? parrot. In: ACM. *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency (FAccT '21)*. [S.l.], 2021. p. 610–623.
- BRONFENBRENNER, U. *The ecology of human development: Experiments by nature and design*. [S.l.]: Harvard university press, 1979.
- BULL, S.; KAY, J. Making learning and its assessment visible. *Communications of the ACM*, ACM New York, NY, USA, v. 50, n. 4, p. 63–67, 2007.
- CASTELLS, M. *The Rise of the Network Society: The Information Age: Economy, Society, and Culture Volume I*. [S.l.]: Blackwell Publishers, 2000.
- Center on Inclusive Digital Discrete Learning (CIDDL). *Multi-Agent Systems for IEP Development*. 2024. Accessed: 2025-05-03. Disponível em: <<https://ciddl.org/multi-agent-systems-for-mulep-development/>>.
- CHAN, T.-W.; BASKIN, A. B. The learning companion system: An architecture for collaborative learning agents. In: *International Conference on Computers in Education (ICCE)*. [S.l.: s.n.], 1995. p. 203–210.
- CHEN, Y. *AI Agent for Education: von Neumann Multi-Agent System Framework*. [S.l.]: ResearchGate, 2024. Preprint/Technical Report, DOI: 10.13140/RG.2.2.21517.92648.
- CHOU, C.; CHAN, T.-W.; LIN, C.-J. Developing the personalized distance learning system (pdl) based on interaction, agent technology and assessment mechanism. *Journal of Computer Assisted Learning*, Wiley Online Library, v. 19, n. 2, p. 155–174, 2003.
- DOWNES, S. *Connectivism and connective knowledge: Essays on meaning and learning networks*. [S.l.]: National Research Council Canada, 2012. <https://www.downes.ca/files/Connective_Knowledge-19May2012.pdf>.
- FALBO, R. d. A.; NARDI, J. C.; GUIZZARDI, G. Sabio: Systematic approach for building ontologies. In: SCITEPRESS. *Proceedings of the 6th International Conference on Knowledge Engineering and Ontology Development (KEOD)*. [S.l.], 2014. p. 480–487.
- FISCHER, G. Understanding, fostering, and supporting lifelong learning in the 21st century. In: *Proceedings of the 3rd workshop on Human-Computer Interaction at the University of Tuebingen*. [S.l.: s.n.], 2001. p. 1–23.

- Foundation for Intelligent Physical Agents (FIPA). *FIPA ACL Message Structure Specification*. 2002. Standard SC00061G, <<http://www.fipa.org/specs/fipa00061/>>.
- Gemini Team; Google. *Gemini: A Family of Highly Capable Multimodal Models*. [S.l.], 2023.
- GOODFELLOW, I. J. et al. Generative adversarial nets. *Advances in neural information processing systems (NIPS)*, v. 27, 2014.
- GRUBER, T. R. A translation approach to portable ontology specifications. *Knowledge acquisition*, Elsevier, v. 5, n. 2, p. 199–220, 1993.
- GUIZZARDI, G. *Ontological foundations for structural conceptual models*. Tese (Doutorado) — University of Twente, 2007.
- GUO, S. et al. *Using Generative AI and Multi-Agents to Provide Automatic Feedback*. 2024.
- HEVNER, A. R. et al. Design science in information systems research. *MIS quarterly*, JSTOR, p. 75–105, 2004.
- HWANG, G.-J. Definition, framework and research issues of smart learning environments-a context-aware ubiquitous learning perspective. *Smart learning environments*, Springer, v. 1, n. 1, p. 1–14, 2014.
- JENNINGS, N. R. Coordination techniques for distributed artificial intelligence. *Foundations of distributed artificial intelligence*, Wiley, p. 187–210, 1996.
- KITCHENHAM, B.; CHARTERS, S. Guidelines for performing systematic literature reviews in software engineering. *Technical report, Ver. 2.3 EBSE Technical Report. EBSE-2007-01. Keele University and Durham University Joint Report*, 2007.
- LI, H. et al. *Knowledge Tagging with Large Language Model based Multi-Agent System*. 2024.
- MARCH, S. T.; SMITH, G. F. Design and natural science research on information technology. *Decision support systems*, Elsevier, v. 15, n. 4, p. 251–266, 1995.
- MITCHELL, C.; PERROTT, K. *Generative AI and Student Engagement: A Study of Two Urban Planning Classes*. 2024. Presentation at the University of Waterloo Teaching and Learning Conference. Details based on summary provided.
- OPENAI. *GPT-4 Technical Report*. [S.l.], 2023.
- OUYANG, L. et al. *Training language models to follow instructions with human feedback*. [S.l.], 2022.
- PADGHAM, L.; WINIKOFF, M. *Developing intelligent agent systems: A practical guide*. [S.l.]: John Wiley & Sons, 2004.
- PAGE, M. J. et al. The prisma 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, British Medical Journal Publishing Group, v. 372, 2021.
- PARK, J. S. et al. *Generative Agents: Interactive Simulacra of Human Behavior*. [S.l.], 2023.

- PEFFERS, K. et al. A design science research methodology for information systems research. *Journal of management information systems*, Taylor Francis, v. 24, n. 3, p. 45–77, 2007.
- PETERSEN, K. et al. Systematic mapping studies in software engineering. *12th International Conference on Evaluation and Assessment in Software Engineering (EASE)*, p. 1–10, 2008.
- PETERSEN, K.; VAKKALANKA, S.; KUZNIARZ, L. Guidelines for conducting systematic mapping studies in software engineering: An update. *Information and software technology*, Elsevier, v. 64, p. 1–18, 2015.
- RAO, A. S.; GEORGEFF, M. P. Bdi agents: from theory to practice. *Proceedings of the first international conference on multi-agent systems (ICMAS)*, p. 312–319, 1995.
- RUSSELL, S. J.; NORVIG, P. *Artificial intelligence: a modern approach*. 3rd. ed. [S.l.]: Prentice Hall, 2010.
- SANTOS, O. Lube dos; CURY, D. O uso de sistemas multiagentes para análise de sentimentos em fóruns de discussão acadêmicos. In: SOCIEDADE BRASILEIRA DE COMPUTAÇÃO (SBC). *Anais do Workshop sobre Informática na Escola (WIE)*. [S.l.], 2022. p. 214–223.
- SANTOS, O. Lube dos; CURY, D. Sentiment analysis in educational forums using multi-agent systems and natural language processing. In: IEEE. *2023 IEEE World Forum on Internet of Things (WF-IoT)*. [S.l.], 2023. p. 1–6.
- SANTOS, O. Lube dos; CURY, D. Avaliação da aprendizagem na cultura digital: Um mapeamento sistemático da literatura com foco em tecnologias emergentes. *Revista Novas Tecnologias na Educação (RENOTE)*, Universidade Federal do Rio Grande do Sul, v. 22, n. 1, 2024.
- SANTOS, O. Lube dos; CURY, D. Goodbot: the engineering and computer science student’s best friend. Artigo submetido ao IEEE Frontiers in Education Conference (FIE) 2025. 2024.
- SIEMENS, G. Connectivism: A learning theory for the digital age. *International Journal of Instructional Technology and Distance Learning*, v. 2, n. 1, p. 3–10, 2005.
- SILVEIRA, P. D. d. *OEACD: Uma Ontologia de Referência sobre Ecossistemas de Aprendizagem na Cultura Digital para Apoiar o Desenvolvimento de Arquiteturas Pedagógicas Inteligentes*. Tese (Doutorado) — Programa de Pós-Graduação em Informática, Universidade Federal do Espírito Santo, Vitória, ES, Brasil, 2022.
- SMITH, R. G. The contract net protocol: High-level communication and control in a distributed problem solver. *IEEE Transactions on Computers*, IEEE, C-29, n. 12, p. 1104–1113, 1980.
- SPECTOR, J. M. Smart learning environments: Concepts and issues. *Society for Information Technology & Teacher Education International Conference*, p. 2728–2737, 2016.
- UNKNOWN, A. Impact of a ChatGPT-driven pedagogical agent in a flipped classroom system on learning outcomes, cognitive load, and engagement in a 2D design course. *International Journal of Interactive Multimedia and Artificial Intelligence (IJIMAI)*, 2024. Details based on summary provided. Full citation needed.

- VANLEHN, K. The relative effectiveness of human tutoring, intelligent tutoring systems, and other tutoring systems. *Educational Psychologist*, Taylor & Francis, v. 46, n. 4, p. 197–221, 2011.
- VASWANI, A. et al. Attention is all you need. In: *Advances in neural information processing systems (NIPS)*. [S.l.: s.n.], 2017. v. 30.
- WANG, T. et al. *GenMentor: LLM-powered Multi-agent Framework for Goal-oriented Learning in Intelligent Tutoring System*. 2025.
- WEI, H. et al. *MEDCO: Medical Education Copilots Based on A Multi-Agent Framework*. 2024.
- WEIDINGER, L. et al. *Ethical and social risks of harm from Language Models*. [S.l.], 2021.
- WEISS, G. E. *Multiagent systems: a modern approach to distributed artificial intelligence*. [S.l.]: The MIT press, 1999.
- WOOLDRIDGE, M. *An introduction to multiagent systems*. [S.l.]: John Wiley & Sons, 2009.
- WOOLDRIDGE, M.; JENNINGS, N. R. Intelligent agents: Theory and practice. *The knowledge engineering review*, Cambridge University Press, v. 10, n. 2, p. 115–152, 1995.
- XU, S. et al. *Classroom Simulacra: Building Contextual Student Generative Agents in Online Education for Learning Behavioral Simulation*. 2025.
- XU, S.; ZHANG, X.; QIN, L. *EduAgent: Generative Student Agents in Learning*. 2024.
- YAN, Y. et al. *MathAgent: Leveraging a Mixture-of-Math-Agent Framework for Real-World Multimodal Mathematical Error Detection*. 2025.
- YANG, K. et al. Content knowledge identification with multi-agent large language models (LLMs). In: SPRINGER NATURE SWITZERLAND CHAM. *Artificial Intelligence in Education. Posters and Late Breaking Results, Workshops and Tutorials, Industry and Innovation Tracks, Practitioners, Doctoral Consortium and Blue Sky: 25th International Conference, AIED 2024, Recife, Brazil, July 8–12, 2024, Proceedings, Part II*. [S.l.], 2024. p. 178–185.
- ZAMBONELLI, F.; JENNINGS, N. R.; WOOLDRIDGE, M. Developing multiagent systems: The gaia methodology. *ACM Transactions on Software Engineering and Methodology (TOSEM)*, ACM New York, NY, USA, v. 12, n. 3, p. 317–370, 2003.
- ZHANG, L. *Prototyping a multi-agent system to enhance AI-human collaboration IEP development*. 2025. Paper presented at the AERA Annual Meeting 2025, Denver, Colorado. Details based on abstract/summary provided.
- ZHANG, Z. et al. Simulating classroom education with LLM-empowered agents. In: *Proceedings of the 2025 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL-HLT 2025)*. [S.l.: s.n.], 2025. URL: <https://aclanthology.org/2025.naacl-long.520>.

Apêndices

APÊNDICE A – Apêndice B – Estudos do MSL

Tabela 1 – Estudos Primários Seleccionados no Mapeamento Sistemático da Literatura

ID	Referência	Ano	Foco Principal / Contribuição	Contexto Educacional	Aspecto MAS	Aspecto IAG
S1	(WANG et al., 2025)	2025	Framework GenMentor para tutoria inteligente orientada a objetivos.	Tutoria Inteligente (ITS)	Múltiplos agentes LLM (Mentor, Explicador, Motivador, etc.) com papéis definidos.	LLMs coordenados para gerar feedback, explicações, motivação.
S2	(YANG et al., 2024)	2024	Identificação de conhecimento de conteúdo usando MAS com LLMs.	Avaliação de professores (conhecimento de conteúdo).	Múltiplos agentes LLM colaborando para analisar respostas.	LLMs como base dos agentes para análise semântica.
S3	(XU et al., 2025)	2025	Simulação de sala de aula com agentes generativos de estudantes.	Simulação de comportamento de aprendizagem online.	Agentes representando estudantes com perfis e comportamentos distintos.	LLMs para gerar interações e comportamentos realistas dos estudantes.
S4	(XU; ZHANG; QIN, 2024)	2024	EduAgent: Agentes generativos de estudantes para apoiar a aprendizagem.	Aprendizagem colaborativa, tutoria por pares (simulada).	Agentes LLM simulando estudantes com diferentes níveis de conhecimento.	LLMs para gerar respostas, perguntas e interações como estudantes.

Continua na próxima página

Tabela 1 – Continuação

ID	Referência	Ano	Foco Principal / Contribuição	Contexto Educacional	Aspecto MAS	Aspecto IAG
S5	(YAN et al., 2025)	2025	MathAgent: Framework MAS para detecção de erros matemáticos multimodais.	Educação Matemática (detecção de erros).	Múltiplos agentes especializados (análise de imagem, texto, raciocínio) colaborando.	LLMs/VLMs como base para agentes de análise e raciocínio.
S6	(WEI et al., 2024)	2024	MEDCO: Framework MAS para copilotos em educação médica.	Educação Médica (diagnóstico, planejamento).	Múltiplos agentes (Clínico, Radiologista, etc.) colaborando em tarefas médicas.	LLMs para fornecer conhecimento e capacidade de raciocínio aos agentes.
S7	(GUO et al., 2024)	2024	Uso de IAG e MAS para fornecer feedback automático.	Feedback em programação ou escrita.	Agentes com papéis específicos (Avaliador, Explicador) interagindo.	LLMs para gerar e analisar feedback.
S8	(LI et al., 2024)	2024	Etiquetagem de conhecimento com MAS baseado em LLM.	Organização de conteúdo educacional, sistemas de recomendação.	Múltiplos agentes LLM colaborando para etiquetar recursos.	LLMs para análise semântica e classificação de conteúdo.
S9	(ZHANG et al., 2025)	2025	Simulação de educação em sala de aula com agentes LLM.	Simulação de interações professor-aluno.	Agentes representando professor e alunos com diferentes personalidades.	LLMs para gerar diálogos e comportamentos realistas.

Continua na próxima página

Tabela 1 – Continuação

ID	Referência	Ano	Foco Principal / Contribuição	Contexto Educacio- nal	Aspecto MAS	Aspecto IAG
S10	(ZHANG, 2025)	2025	Prototipagem de MAS para colaboração IA-humano no desenvolvimento de IEP.	Educação Especial (Desenvolvimento de Plano Educacional Individualizado - IEP).	Agentes IA colaborando com humanos (professores, pais).	LLMs para auxiliar na redação e análise de componentes do IEP.
S11	(ABDELGHANI et al., 2022)	2022	Agentes pedagógicos baseados em GPT-3 para treinar perguntas curiosas.	Desenvolvimento de habilidades de questionamento em crianças.	Agente conversacional único (mas com potencial para MAS).	GPT-3 para gerar diálogos e estimular a curiosidade.
S12	(UNKNOWN, 2024)	2024	Agente pedagógico ChatGPT em sala de aula invertida.	Curso de Design 2D (sala de aula invertida).	Agente conversacional único (mas com potencial para MAS).	ChatGPT como base do agente para interação com alunos.
S13	(MITCHELL; PERROTT, 2024)	2024	IAG e engajamento estudantil em planejamento urbano.	Cursos de Planejamento Urbano.	Uso de IAG pelos alunos (não explicitamente MAS, mas relevante).	Ferramentas de IAG usadas como apoio à aprendizagem.
S14	(Center on Inclusive Digital Discrete Learning (CIDDL), 2024)	2024	Discussão conceitual de MAS para desenvolvimento de IEP.	Educação Especial (Desenvolvimento de IEP).	Conceitualização de múltiplos agentes colaborando com humanos.	IAG como tecnologia potencial para os agentes.
S15	(CHEN, 2024)	2024	Framework MAS von Neumann para educação.	Plataforma educacional geral.	Arquitetura MAS proposta com diferentes tipos de agentes.	LLMs como componente central para agentes de IA.

Continua na próxima página

Tabela 1 – Continuação						
ID	Referência	Ano	Foco Principal / Contribuição	Contexto Educacio- nal	Aspecto MAS	Aspecto IAG
S16	[GoodBot]	2025	Sistema multiagente para apoio psicossocial e de aprendizagem.	Estudantes de Enge- nharia/Computação.	Múltiplos agentes (Apoio, Conteúdo, Gerente) com papéis definidos.	LLMs (GPT) como base para agentes con- versacionais e de aná- lise.