



SAGE: Smart Agent Generation for Education - Framework para Construção de Sistemas Multiagentes Inteligentes em Ecossistemas de Aprendizagem

Otávio Lube dos Santos, Universidade Federal do Espírito Santo,
olube@inf.ufes.br, <https://orcid.org/0009-0000-0789-800X>

Davidson Curry, Universidade Federal do Espírito Santo,
dede@inf.ufes.br, <https://orcid.org/0000-0003-3575-6417>

Resumo: A construção de Sistemas Multiagentes (SMs) inteligentes para Ecossistemas de Aprendizagem (EAs) apresenta desafios significativos relacionados à complexidade inerente aos SMs, à necessidade de alinhamento com especificidades pedagógicas e à integração de tecnologias emergentes como a Inteligência Artificial Generativa. Este artigo apresenta o SAGE (Smart Agent Generation for Education), um framework conceitual que estrutura tanto o processo de construção quanto a arquitetura resultante de SMs educacionais. O framework propõe uma arquitetura em cinco camadas (Conhecimento, Modelos LLM, Especificação de Agentes Educacionais, Dispositivos e Aplicação) e um processo de construção em cinco fases (Análise e Requisitos, Design do SM, Design dos Agentes e Papéis, Implementação e Integração, e Avaliação e Refinamento). O SAGE foi concebido como uma extensão da Ontologia para Ecossistemas de Aprendizagem na Cultura Digital (OEACD), promovendo modularidade, reutilização e integração sistemática de Grandes Modelos de Linguagem (LLMs). O framework posiciona-se como complementar a frameworks existentes focados no design do ecossistema, oferecendo um guia metodológico específico para a construção dos componentes inteligentes. A abordagem iterativa e incremental do SAGE, especialmente na fase de avaliação e refinamento, alinha-se com os princípios da Design Science Research e facilita a evolução contínua dos sistemas desenvolvidos.

Palavras-chave: sistemas multiagentes, ecossistemas de aprendizagem, framework conceitual, inteligência artificial generativa, arquitetura em camadas.

SAGE: Smart Agent Generation for Education - Framework for Building Intelligent Multi-Agent Systems in Learning Ecosystems

Abstract: Building intelligent Multi-Agent Systems (MAS) for Learning Ecosystems (LEs) presents significant challenges related to the inherent complexity of MAS, the need for alignment with pedagogical specificities, and the integration of emerging technologies such as Generative Artificial Intelligence. This article presents SAGE (Smart Agent Generation for Education), a conceptual framework that structures both the construction process and the resulting architecture of educational MAS. The framework proposes a five-layer architecture (Knowledge, LLM Models, Educational Agent Specification, Devices, and Application) and a five-phase construction process (Analysis and Requirements, MAS Design, Agent and Role Design, Implementation and Integration, and Evaluation and Refinement). SAGE was conceived as an extension of the Ontology for Learning Ecosystems in Digital Culture (OEACD), promoting modularity, reusability, and systematic integration of Large Language Models (LLMs). The framework positions itself as complementary to existing frameworks focused on ecosystem design, offering a specific methodological guide for building intelligent components. SAGE's iterative and incremental approach, especially in the evaluation and refinement phase, aligns with Design Science Research principles and facilitates continuous evolution of developed systems.

Keywords: multi-agent systems, learning ecosystems, conceptual framework, generative artificial intelligence, layered architecture.



1. Introdução

A era digital transformou profundamente a educação, criando 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 (EAs), que reconhece a aprendizagem como um processo contínuo, distribuído e socialmente construído, ocorrendo em múltiplos contextos formais, não formais e informais (Silveira, 2022; Jackson, 2013).

Para potencializar esses ecossistemas, torna-se crucial o desenvolvimento de ambientes de aprendizagem mais inteligentes, adaptativos e personalizados. Os Smart Learning Environments (SLEs) buscam responder a essa demanda, integrando tecnologias avançadas para criar experiências educacionais mais eficazes (Spector, 2016; Hwang, 2014; Zhu; Yu e Riezebos, 2016). Dentro dos SLEs e EAs, os Sistemas Multiagentes (SMs) surgem como uma abordagem promissora para modelar e apoiar as dinâmicas complexas desses ambientes.

SMs 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; Stone e Veloso, 2000). Sua capacidade de distribuir tarefas, adaptar-se a mudanças e exibir comportamentos sociais os torna particularmente adequados para os desafios educacionais contemporâneos (Dorri; Kanhere e Jurdak, 2018; Gama; Gonçalves e Alessio, 2012).

O advento da Inteligência Artificial Generativa (IAG), especialmente através dos Grandes Modelos de Linguagem (LLMs) baseados na arquitetura Transformer (Vaswani *et al.*, 2017; Devlin *et al.*, 2018), revolucionou as possibilidades de criação de agentes inteligentes. Esses modelos demonstram capacidades avançadas de compreensão de linguagem natural, geração de conteúdo, diálogo e raciocínio (OpenAI, 2023; Brown *et al.*, 2020; Touvron *et al.*, 2023), oferecendo oportunidades sem precedentes para desenvolver agentes educacionais mais sofisticados e eficazes.

Apesar do potencial evidente, a construção de SMs inteligentes para EAs apresenta desafios significativos. A complexidade inerente aos SMs, a necessidade de alinhamento com especificidades pedagógicas e contextuais dos EAs, e a integração de tecnologias emergentes como a IAG carecem de abordagens sistemáticas e bem fundamentadas (Jennings, 2000).

A literatura existente frequentemente foca em aspectos específicos, como algoritmos de recomendação, arquiteturas de agentes isoladas ou frameworks para o design do ecossistema (Silveira, 2022; Klusch, 2003). Contudo, percebe-se uma lacuna no que diz respeito a um guia metodológico robusto que oriente especificamente o processo de construção dos Sistemas Multiagentes que irão operar nesses ecossistemas, considerando tanto aspectos arquiteturais quanto processuais.

Este artigo apresenta o SAGE (Smart Agent Generation for Education), um framework conceitual que visa preencher essa lacuna metodológica. O SAGE oferece tanto uma arquitetura em camadas para estruturar SMs educacionais quanto um processo sistemático para sua construção, fundamentado como uma extensão da Ontologia para Ecossistemas de Aprendizagem na Cultura Digital (OEACD) e alinhado com os princípios da Design Science Research (Hevner *et al.*, 2004; Peffers *et al.*, 2007).



2. Fundamentação Teórica

2.1 Sistemas Multiagentes em Contextos Educacionais

Os Sistemas Multiagentes têm sido aplicados em diversos contextos educacionais, demonstrando sua versatilidade e eficácia para modelar interações complexas (Wooldridge, 2009; Ferber, 1999). Em ambientes educacionais, os agentes podem assumir múltiplos papéis, incluindo tutores virtuais, companheiros de aprendizagem, facilitadores de colaboração, avaliadores automatizados e recomendadores de conteúdo (Bordini *et al.*, 2007; Bellifemine; Caire e Greenwood, 2007).

A natureza distribuída dos SMs permite que diferentes tipos de agentes trabalhem cooperativamente para fornecer experiências de aprendizagem ricas e personalizadas (Boissier *et al.*, 2013; Rao e Georgeff, 1995). Esta capacidade de distribuição de tarefas e especialização é particularmente valiosa em EAs, onde múltiplos atores e recursos interagem de forma dinâmica e complexa.

Pesquisas recentes têm explorado a aplicação de SMs em diversos domínios educacionais, desde sistemas tutores inteligentes até ambientes colaborativos de aprendizagem (Stone e Veloso, 2000; Gama; Gonçalves e Alessio, 2012). A capacidade dos agentes de exibir comportamentos autônomos e sociais os torna adequados para modelar as complexas interações presentes nos processos de ensino e aprendizagem (Dorri; Kanhere e Jurdak, 2018).

2.2 Inteligência Artificial Generativa e LLMs

A emergência da IA Generativa, especialmente através dos LLMs, tem transformado o panorama da inteligência artificial aplicada à educação (Brown *et al.*, 2020; Radford *et al.*, 2019). Modelos como GPT-4, Gemini e outros demonstram capacidades impressionantes em tarefas de compreensão e geração de linguagem natural, oferecendo novas possibilidades para agentes educacionais (OpenAI, 2023; Touvron *et al.*, 2023).

No contexto de SMs educacionais, a integração de LLMs permite que agentes possuam capacidades avançadas de diálogo, geração de conteúdo personalizado, explicações adaptativas e suporte conversacional (Wei *et al.*, 2022; Ouyang *et al.*, 2022). Esta integração, contudo, requer considerações arquiteturais específicas para garantir eficiência, escalabilidade e alinhamento com objetivos pedagógicos.

A arquitetura Transformer (Vaswani *et al.*, 2017) revolucionou o processamento de linguagem natural, permitindo que modelos como BERT (Devlin *et al.*, 2018) e GPT (Radford *et al.*, 2019) demonstrassem capacidades sem precedentes em compreensão e geração de texto. Esses avanços abriram novas possibilidades para a criação de agentes educacionais mais sofisticados e capazes de interações naturais com estudantes.

2.3 Ontologias para Ecossistemas de Aprendizagem

A Ontologia para Ecossistemas de Aprendizagem na Cultura Digital (OEACD) (Silveira, 2022) fornece uma base conceitual rica para descrever EAs, incluindo participantes, recursos, atividades e contextos. Esta ontologia estabelece um vocabulário compartilhado que facilita a compreensão e modelagem de ecossistemas educacionais complexos.

Para guiar especificamente a construção de SMs que operam nesses ecossistemas, uma extensão ontológica se faz necessária. O desenvolvimento de ontologias específicas para domínios tem sido uma prática estabelecida na engenharia de conhecimento (Falbo; Nardi e Guizzardi, 2014; Guizzardi, 2007), permitindo a criação de vocabulários especializados que atendam às necessidades específicas de diferentes áreas de aplicação.



A metodologia SABiO (Systematic Approach for Building Ontologies) (Falbo; Nardi e Guizzardi, 2014) oferece um processo estruturado para o desenvolvimento de ontologias, incluindo a identificação de requisitos, reutilização de conceitos existentes e definição de novos conceitos em linguagens formais como OntoUML (Guizzardi, 2007).

3. O Framework SAGE

3.1 Visão Geral e Princípios

O SAGE é um framework conceitual que estrutura tanto o processo de construção quanto a arquitetura resultante de SMs para EAs. Diferentemente de abordagens que focam apenas em aspectos processuais ou arquiteturais isoladamente, o SAGE oferece uma visão integrada que abrange desde a análise inicial de requisitos até a arquitetura em camadas do sistema resultante.

Os princípios norteadores do SAGE incluem:

Extensão Ontológica: O framework foi concebido como uma extensão da OEACD, incorporando conceitos específicos de SMs para garantir alinhamento semântico entre o design do SM e a representação do Ecossistema de Aprendizagem.

Modularidade e Reutilização: O framework incentiva a concepção de agentes com capacidades bem definidas e arquiteturas que facilitem a reutilização de componentes e a extensibilidade do SM.

Integração Sistemática de LLMs: O framework prevê a incorporação estruturada de Grandes Modelos de Linguagem através de uma camada dedicada, promovendo abstração e flexibilidade na utilização dessas tecnologias.

Processo Iterativo e Incremental: O framework suporta uma abordagem iterativa, especialmente através da fase de avaliação e refinamento, permitindo evolução contínua do sistema.

Complementaridade: O framework foi concebido para complementar abordagens existentes focadas no design do ecossistema, concentrando-se especificamente na construção dos componentes inteligentes.

3.2 Fundamentação Ontológica

O SAGE foi desenvolvido como uma extensão da OEACD, incorporando conceitos fundamentais de SMs para criar um vocabulário especializado que atenda às necessidades específicas da construção de sistemas multiagentes educacionais. Esta extensão ontológica fornece o vocabulário e a estrutura semântica necessários para compreender e modelar o contexto do EA, especificar requisitos do SM, guiar o design dos agentes, facilitar a comunicação e interoperabilidade, e conectar design e implementação.

A extensão incorpora conceitos centrais de SMs, incluindo Agent (entidade computacional autônoma), AgentCapability (habilidades intrínsecas incluindo capacidades generativas), AgentArchitecture (estrutura interna do agente), SMOrganization (estrutura organizacional do sistema) e InteractionProtocol (protocolos de comunicação entre agentes).

3.3 Arquitetura Conceitual em Camadas

O SAGE propõe uma arquitetura conceitual em cinco camadas que organiza os componentes de um SM educacional em níveis de abstração distintos, facilitando desenvolvimento, manutenção e evolução do sistema.




Figura 1. Arquitetura em Camadas de um SM-EA segundo o SAGE

3.3.1 Knowledge Layer (Camada de Conhecimento)

Esta camada representa a base de informações e dados que o SM-EA utiliza e sobre a qual opera. Ela é fundamental para que os agentes possam contextualizar suas ações e personalizar suas interações. A camada inclui dados estruturados e não estruturados, acesso à Web, integração com Smart Learning Environments (SLE), conexão com sistemas ERP (Enterprise Resource Planning) e interoperabilidade com Ambientes Virtuais de Aprendizagem (AVAs).

A extensão ontológica do SAGE desempenha papel crucial na organização e semantização das informações desta camada, permitindo que os agentes compreendam e raciocinem sobre as diversas fontes de conhecimento de forma unificada.

3.3.2 LLM Models Layer (Camada de Modelos LLM)

Esta camada é dedicada à incorporação de Grandes Modelos de Linguagem como componentes centrais para as capacidades de IA generativa dos agentes. A camada pode incluir múltiplos LLMs especializados ou genéricos, desde modelos de propósito geral até modelos menores especializados e ajustados para tarefas educacionais específicas.

A camada também fornece abstração de acesso aos LLMs através de interfaces e mecanismos padronizados, permitindo que os agentes interajam com diferentes modelos independentemente do provedor ou tecnologia específica. Isso inclui gerenciamento de prompts, processamento de respostas e tratamento de limitações dos modelos.



3.3.3 Educational Agent Specification Layer (Camada de Especificação do Agente Educacional)

Esta camada define a estrutura e o comportamento dos agentes educacionais que compõem o SM. As especificações incluem descrições detalhadas de cada tipo de agente em formatos estruturados (como JSON), incluindo objetivos, papéis, capacidades, arquitetura interna e protocolos de interação.

Crucialmente, as especificações dos agentes devem estar explicitamente alinhadas com os conceitos da extensão ontológica do SAGE, garantindo consistência semântica e facilitando o raciocínio sobre o sistema como um todo.

3.3.4 Devices Layer (Camada de Dispositivos)

Esta camada representa os diversos canais e interfaces através dos quais os usuários interagem com o SM-EA. A capacidade de interagir através de múltiplos dispositivos é essencial para a ubiquidade e acessibilidade em Ecossistemas de Aprendizagem modernos.

A camada inclui APIs (Application Programming Interfaces), sensores para captura de dados do ambiente físico ou do usuário, wearables para coleta de dados sobre atividade e contexto, interfaces de Realidade Virtual/Aumentada (VR/AR) para experiências imersivas, e smartphones e dispositivos móveis como principais pontos de acesso.

3.3.5 Application Layer (Camada de Aplicação)

Esta é a camada mais externa, onde as funcionalidades e serviços do SM-EA são expostos aos usuários finais. Ela materializa os objetivos do sistema em termos de aplicações e interfaces concretas, incluindo ferramentas de administração, sistemas de notificações, suporte e ajuda conversacional, entrega de conteúdo multimídia e serviços de recomendação personalizados.

4. Processo de Construção

O SAGE propõe um processo estruturado em cinco fases para guiar a construção do SM, cada uma utilizando e refinando os conceitos da extensão ontológica proposta.




Figura 2. Fases do Processo de Construção Guiado pelo SAGE



4.1 Fase 1: Análise e Requisitos

O objetivo desta fase é compreender profundamente o contexto do Ecossistema de Aprendizagem, identificar necessidades que o SM deve suprir e definir claramente objetivos e requisitos funcionais e não funcionais.

As atividades principais incluem modelagem abrangente do contexto do EA utilizando conceitos da extensão ontológica do SAGE, identificação sistemática de necessidades e oportunidades, definição clara e mensurável dos objetivos do SM, especificação detalhada de requisitos funcionais e não funcionais, e análise de stakeholders e restrições.

A modelagem do contexto envolve identificação e caracterização de todos os participantes relevantes, catalogação de recursos de aprendizagem disponíveis, mapeamento de atividades educacionais existentes, inventário de ferramentas e tecnologias em uso, e análise dos diversos contextos em que o aprendizado ocorre.

Os artefatos produzidos incluem Documento de Requisitos Detalhado, Modelo Formal do Contexto do EA, Lista Priorizada de Objetivos do SM, Matriz de Stakeholders e suas Necessidades, e Análise de Restrições e Riscos.

4.2 Fase 2: Design do SM

Esta fase define a arquitetura organizacional do SM, especificando tipos de agentes, seus papéis, responsabilidades e interações para alcançar os objetivos estabelecidos na Fase 1.

As atividades incluem seleção e justificação da arquitetura organizacional (hierárquica, federada, baseada em equipes ou híbrida), identificação e especificação detalhada dos tipos de agentes necessários, definição de papéis e responsabilidades utilizando conceitos da extensão ontológica, especificação de protocolos de interação e comunicação, e mapeamento para a arquitetura em camadas proposta pelo framework.

A escolha da arquitetura organizacional considera objetivos, complexidade do domínio e características do EA. Arquiteturas hierárquicas são adequadas para divisões claras de autoridade, federadas para subsistemas autônomos que precisam colaborar, baseadas em equipes para tarefas colaborativas complexas, e híbridas para necessidades específicas complexas.

4.3 Fase 3: Design dos Agentes e Papéis

Esta fase crucial especifica detalhadamente a arquitetura interna, papéis e capacidades de cada tipo de agente. A abordagem iterativa permite refinamento contínuo dos agentes com base em feedback e avaliações parciais.

As atividades incluem especificação detalhada da arquitetura interna de cada agente, definição de capacidades específicas (incluindo capacidades generativas), modelagem da base de conhecimento e crenças, design de mecanismos de raciocínio e tomada de decisão, especificação de interfaces de percepção e ação, e integração com LLMs quando aplicável.

Para agentes que utilizam LLMs, esta fase requer atenção especial ao gerenciamento de prompts, interpretação de saídas dos modelos, gerenciamento de contexto conversacional e integração com a arquitetura geral do agente.

4.4 Fase 4: Implementação e Integração

Esta fase traduz o design em código executável e integra o SM ao Ecossistema de Aprendizagem. As atividades incluem seleção de tecnologias e plataformas, codificação dos agentes conforme especificações, implementação da infraestrutura



do SM, desenvolvimento de interfaces e adaptadores para integração com sistemas existentes, e realização de testes unitários e de integração.

A integração considera as diferentes fontes da Camada de Conhecimento e os diversos dispositivos da Camada de Dispositivos, garantindo que o SM possa operar efetivamente no ambiente real do EA.

4.5 Fase 5: Avaliação e Refinamento

Esta é uma fase contínua e cíclica, fundamental no SAGE, que permeia todo o processo. A avaliação pode ser realizada em diferentes níveis (agente individual, interação entre agentes, SM como um todo) utilizando diversas técnicas (simulação, estudos de caso, experimentos com usuários).

O feedback da avaliação alimenta o refinamento do design e da implementação em iterações subsequentes, alinhado com os princípios da Design Science Research. Esta abordagem iterativa é especialmente importante dado a natureza emergente e complexa dos SMs educacionais.

5. Aplicação Prática

5.1 Plataforma para Construção de SMs Educacionais

Para demonstrar a aplicabilidade do framework SAGE, foi desenvolvida uma plataforma inovadora projetada para simplificar o processo de criação, gerenciamento e implementação de sistemas multiagentes educacionais.

A plataforma materializa os conceitos e fases propostos pelo SAGE, oferecendo uma ferramenta que auxilia pesquisadores e educadores a desenvolverem soluções educacionais inteligentes e personalizadas. Sua arquitetura modular visa oferecer flexibilidade na definição dos componentes de um SM educacional.

Os principais recursos da plataforma incluem a criação de agentes inteligentes personalizados com diferentes personalidades e papéis, facilitação da colaboração multiagente, adaptação ao aprendiz individual, integração com IA Generativa através de LLMs, análise de desempenho, e interface de configuração intuitiva.

O processo de construção de um sistema multiagente na plataforma segue três etapas principais que espelham as fases do SAGE: definição dos agentes, estabelecimento de interações, e implementação e monitoramento.

5.2 Prova de Conceito

Uma prova de conceito foi desenvolvida utilizando os princípios do SAGE e implementada através da plataforma. Trata-se de um agente de suporte psicossocial e de aprendizagem projetado especificamente para estudantes de engenharia e computação.

O desenvolvimento seguiu rigorosamente as fases do framework SAGE. Na fase de análise e requisitos, foi identificada a necessidade de suporte psicossocial para estudantes em cursos técnicos. Na fase de design do SM, foi definida uma arquitetura simples com um agente principal equipado com capacidades generativas. Na fase de design dos agentes, foram especificadas as capacidades conversacionais e de suporte emocional.

A prova de conceito demonstra como agentes educacionais podem ser equipados com capacidades generativas avançadas para fornecer suporte personalizado e contextualizado aos estudantes, validando a eficácia do framework proposto.



Figura 3. Interface da prova de conceito demonstrando interação conversacional com estudante

6. Complementaridade com Frameworks Existentes

O SAGE posiciona-se como complementar a frameworks existentes para design de SLEs em EAs, particularmente o framework proposto por Silveira (Silveira, 2022). Esta complementaridade manifesta-se através de diferenciação de escopo e foco, sinergia metodológica, fluxo de integração e benefícios da abordagem integrada.

Enquanto o framework de Silveira foca no design do ecossistema inteligente como um todo, identificando quais componentes inteligentes são necessários e como eles se relacionam, o SAGE concentra-se especificamente em como construir os componentes inteligentes realizados como Sistemas Multiagentes.

A sinergia metodológica utiliza a mesma base ontológica (OEACD, estendida pelo SAGE) para garantir alinhamento entre o design do ecossistema e a construção dos agentes. As saídas do processo de design do ecossistema podem servir como entrada para a Fase 1 do SAGE.

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.

7. Discussão e Implicações

O SAGE representa uma contribuição significativa para a área de Informática na Educação ao oferecer uma abordagem estruturada e fundamentada teoricamente para a construção de SMs educacionais. A arquitetura em camadas proposta facilita a modularidade e a integração de tecnologias emergentes, especialmente LLMs, de forma sistemática e escalável.

A fase de avaliação e refinamento, como componente central e contínuo do framework, alinha-se com as melhores práticas da Design Science Research e reconhece a natureza evolutiva dos sistemas educacionais. Esta abordagem iterativa é particularmente importante em um domínio onde as necessidades e tecnologias evoluem rapidamente.

A fundamentação ontológica através da extensão da OEACD garante consistência conceitual e facilita a interoperabilidade entre diferentes sistemas e componentes. Isso é especialmente relevante em EAs, onde múltiplos sistemas e stakeholders precisam colaborar efetivamente.

As implicações práticas do framework incluem a possibilidade de desenvolvimento mais sistemático de SMs educacionais, maior reutilização de componentes, melhor integração com tecnologias emergentes e facilidade de manutenção e evolução dos sistemas desenvolvidos.



8. Limitações e Trabalhos Futuros

Algumas limitações do framework atual incluem a necessidade de maior detalhamento em aspectos específicos de implementação, a dependência de conhecimento prévio em SMs por parte dos desenvolvedores, e a necessidade de validação em contextos educacionais mais diversos.

Trabalhos futuros incluem a validação mais ampla do framework em diferentes contextos educacionais, o desenvolvimento de ferramentas de apoio para facilitar a aplicação do SAGE, a investigação de métricas específicas para avaliar a qualidade dos SMs educacionais construídos, e o refinamento das fases e atividades com base em feedback de aplicações práticas.

Adicionalmente, pretende-se explorar a integração com outras tecnologias emergentes além dos LLMs, como modelos multimodais e técnicas de aprendizado por reforço, e investigar aspectos éticos e de privacidade específicos para SMs educacionais.

9. Conclusão

Este artigo apresentou o SAGE (Smart Agent Generation for Education), um framework conceitual abrangente para guiar a construção de Sistemas Multiagentes inteligentes em Ecossistemas de Aprendizagem. O framework oferece tanto uma arquitetura em cinco camadas quanto um processo estruturado em cinco fases, fundamentados como uma extensão da OEACD e alinhados com os princípios da Design Science Research.

As principais contribuições incluem uma abordagem integrada que abrange aspectos arquiteturais e processuais, a incorporação sistemática de LLMs através de uma camada dedicada, um processo iterativo com foco em avaliação e refinamento contínuos, e a complementaridade com frameworks existentes para design de ecossistemas.

A arquitetura em camadas facilita a modularidade, reutilização e integração de tecnologias emergentes, enquanto o processo estruturado oferece um guia metodológico claro para desenvolvedores e pesquisadores. A fundamentação ontológica garante consistência conceitual e facilita a interoperabilidade.

O SAGE representa um passo importante na direção de uma abordagem mais sistemática e fundamentada para a construção de sistemas multiagentes educacionais, contribuindo para o avanço da área de Informática na Educação e para o desenvolvimento de Ecossistemas de Aprendizagem verdadeiramente inteligentes e adaptativos.

A natureza iterativa e incremental do framework, especialmente através da fase de avaliação e refinamento, reconhece a complexidade e a natureza evolutiva dos sistemas educacionais, oferecendo flexibilidade para adaptação a diferentes contextos e necessidades.

Referências

- Bellifemine, F. L.; Caire, G.; Greenwood, D. **Developing multi-agent systems with JADE**. Chichester, UK: John Wiley & Sons, 2007.
- Boissier, O.; Bordini, R. H.; Hübner, J. F.; Ricci, A.; Santi, A. Multi-agent oriented programming with jacamo. **Science of Computer Programming**, Elsevier, v. 78, n. 6, p. 747–761, 2013.
- Bordini, R. H.; Dastani, M.; Dix, J.; Seghrouchni, A. E. F. Multi-agent programming: Languages, platforms and applications. **Multiagent Systems, Artificial Societies, and Simulated Organizations**, Springer, v. 15, 2007.



- Brown, T. *et al.* Language models are few-shot learners. **Advances in Neural Information Processing Systems**, v. 33, p. 1877–1901, 2020.
- Devlin, J.; Chang, M.-W.; Lee, K.; Toutanova, K. Bert: Pre-training of deep bidirectional transformers for language understanding. **arXiv preprint arXiv:1810.04805**, 2018.
- Dorri, A.; Kanhere, S. S.; Jurdak, R. Multi-agent systems: A survey. **IEEE Access**, IEEE, v. 6, p. 28573–28593, 2018.
- Falbo, R. d. A.; Nardi, J. C.; Guizzardi, G. Sabio: Systematic approach for building ontologies. **1st Joint Workshop ONTO.COM/ODISE on Ontologies in Conceptual Modeling and Information Systems Engineering**, p. 1–12, 2014.
- Ferber, J. **Multi-agent systems: an introduction to distributed artificial intelligence**. Reading, MA: Addison-Wesley Reading, 1999. v. 1.
- Gama, K.; Gonçalves, E.; Alessio, P. Characterization of multi-agent systems: A systematic literature review. **Information and Software Technology**, Elsevier, v. 54, n. 5, p. 455–468, 2012.
- Guizzardi, G. **Ontological foundations for structural conceptual models**. Enschede, Netherlands: University of Twente, 2007.
- Hevner, A. R.; March, S. T.; Park, J.; Ram, S. Design science in information systems research. **MIS Quarterly**, JSTOR, v. 28, n. 1, 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**, SpringerOpen, v. 1, n. 1, p. 1–14, 2014.
- Jackson, S. Learning through social spaces: Migrant women and lifelong learning in post-colonial london. **British Educational Research Journal**, Wiley Online Library, v. 39, n. 1, p. 142–161, 2013.
- Jennings, N. R. On agent-based software engineering. **Artificial Intelligence**, Elsevier, v. 117, n. 2, p. 277–296, 2000.
- Klusck, M. Information agent technology for the internet: A survey. In: **Data & Knowledge Engineering**. [S.l.]: Elsevier, 2003. v. 36, n. 3, p. 337–372.
- OpenAI. **GPT-4 Technical Report**. [S.l.], 2023. Disponível em: <https://arxiv.org/abs/2303.08774>.
- Ouyang, L. *et al.* Training language models to follow instructions with human feedback. **Advances in Neural Information Processing Systems**, v. 35, p. 27730–27744, 2022.
- Peppers, K.; Tuunanen, T.; Rothenberger, M. A.; Chatterjee, S. A design science research methodology for information systems research. **Journal of Management Information Systems**, Taylor & Francis, v. 24, n. 3, p. 45–77, 2007.
- Radford, A. *et al.* Language models are unsupervised multitask learners. **OpenAI Blog**, v. 1, n. 8, p. 9, 2019.
- Rao, A. S.; Georgeff, M. P. Bdi agents: from theory to practice. In: AAAI Press. **Proceedings of the First International Conference on Multi-Agent Systems (ICMAS-95)**. [S.l.], 1995. p. 312–319.
- Silveira, P. N. **Framework conceitual para concepção de Smart Learning Environments em Ecossistemas de Aprendizagem**. Tese (Doutorado) — Universidade Federal do Espírito Santo, Vitória, ES, 2022.
- Spector, J. M. Foundations of educational technology: Integrative approaches and interdisciplinary perspectives. **Educational Technology Research and Development**, Springer, v. 64, n. 4, p. 831–850, 2016.
- Stone, P.; Veloso, M. Multiagent systems: A survey from a machine learning perspective. **Autonomous Robots**, Springer, v. 8, n. 3, p. 345–383, 2000.
- Touvron, H. *et al.* Llama: Open and efficient foundation language models. **arXiv preprint arXiv:2302.13971**, 2023.



Vaswani, A. *et al.* Attention is all you need. **Advances in Neural Information Processing Systems**, v. 30, p. 5998–6008, 2017.

Wei, J. *et al.* Chain-of-thought prompting elicits reasoning in large language models. **Advances in Neural Information Processing Systems**, v. 35, p. 24824–24837, 2022.

Wooldridge, M. **An introduction to multiagent systems**. 2nd. ed. Chichester, UK: John Wiley & Sons, 2009.

Zhu, Z.; Yu, M.; Riezebos, P. A research framework of smart education. **Smart Learning Environments**, SpringerOpen, v. 3, n. 1, p. 1–17, 2016.