

EDUPersona: A Multi-Agent Environment for Personalized Guidance through Learning Objects

Gustavo F. P. da Silva¹, Felipe J. R. Vieira¹, Jorge P. G. Júnior¹,
Alisson N. S. de Oliveira¹, Célia G. Ralha¹

Computer Institute – University of Bahia (UFBA)
Campus Ondina, 40.170-110 Salvador, Brasil

gustavopaim@ufba.br, felipejrvieira@gmail.com, jorgeguimaraes@ufba.br,
alissonnonato@ufba.br, celiaralha@ufba.br

Resumo. *O avanço das tecnologias educacionais inteligentes intensifica o desafio de criar sistemas capazes de compreender a complexidade do aprendizado humano e adaptar-se aos estudantes. Nesse cenário, sistemas multiagentes oferecem uma abordagem promissora ao empregar agentes autônomos orientados por objetivos para atuar em ambientes educacionais. Este trabalho apresenta o EDUPersona, um ambiente multiagente integrado a um chatbot baseado em LLM, desenvolvido para identificar metas, planejar intervenções e fornecer recomendações de objetos de aprendizagem. A combinação entre abordagens de raciocínio de agentes inteligentes e interação em linguagem natural possibilita uma tutoria digital que promove autonomia e eficiência na aprendizagem.*

Abstract. *The advancement of intelligent educational technologies intensifies the challenge of creating systems capable of understanding the complexity of human learning and adapting to students. In this scenario, multi-agent systems offer a promising approach by employing goal-oriented autonomous agents to operate within educational environments. This paper presents EDUPersona, a multi-agent environment integrated with an LLM-based chatbot, developed to identify goals, plan interventions, and provide recommendations for learning objects. The combination of intelligent agent reasoning approaches and natural language interaction enables digital tutoring that fosters autonomy and efficiency in learning.*

1. Introdução

O avanço das tecnologias educacionais tem impulsionado estratégias voltadas à personalização do ensino e à ampliação das oportunidades de aprendizagem [Coelho et al. 2025]. Entretanto, muitos sistemas ainda apresentam limitações quanto à adaptação dinâmica e contínua aos perfis, às necessidades e ao ritmo de aprendizagem dos estudantes, desconsiderando suas particularidades cognitivas, comportamentais e contextuais [Yin 2022, Mohamedhen et al. 2024].

Nesse contexto, os Sistemas Multiagentes (SMA) constituem uma alternativa promissora para o desenvolvimento de soluções educacionais adaptativas [Jiang et al. 2024, Dahal et al. 2026]. Um agente inteligente pode ser compreendido como uma entidade capaz de perceber o ambiente por meio de sensores e atuar sobre ele mediante atuadores, orientando suas ações segundo objetivos previamente estabelecidos [Wooldridge 2009, Russell and Norvig 2020]. Os SMA têm sido aplicados à

personalização do ensino, particularmente na recomendação de Objetos de Aprendizagem (OA) segundo conhecimentos, preferências e características dos estudantes [Mohamedhen et al. 2024, Mourão and Netto 2019, Nouzri et al. 2024]. Um OA corresponde a qualquer entidade, digital ou não, que possa ser utilizada, reutilizada ou referenciada durante a aprendizagem apoiada por tecnologia [Wiley 2002, IEEE Learning Technology Standards Committee 2020].

Considerando a heterogeneidade dos estudantes e a necessidade de reconhecer suas particularidades para ações pedagógicas eficazes, o uso de SMA e mecanismos de comunicação baseados em linguagem clara e adaptável se mostra relevante ao possibilitar a adaptação contínua dos conteúdos às demandas dos discentes observadas ao longo do processo de aprendizagem [Wang et al. 2024, Chu et al. 2025]. Ademais, tendo em vista as desigualdades no acesso às tecnologias educacionais por parcela significativa dos estudantes, bem como a predominância de dispositivos móveis como principal meio de interação [Cardoso et al. 2020, Comitê Gestor da Internet no Brasil 2025], evidencia-se a necessidade de desenvolver soluções acessíveis, responsivas e inclusivas, capazes de se adaptar a diferentes dispositivos e contextos socioeconômicos.

Diante desse cenário, este trabalho apresenta o EDUPersona, um sistema multiagente projetado para compreender o nível de conhecimento do estudante, identificar seus objetivos, planejar e executar ações pedagógicas e estabelecer interações em linguagem natural, fornecendo *feedback* e recomendações personalizadas. A integração entre agentes inteligentes e processamento de linguagem natural possibilita uma tutoria digital adaptativa, orientada por crenças continuamente atualizadas e por interações mais humanizadas. Busca-se, assim, favorecer a autonomia, o engajamento e a efetividade do processo de aprendizagem. Este artigo está organizado da seguinte forma: a Seção 2 apresenta os trabalhos relacionados; a Seção 3 descreve a modelagem, a arquitetura, o modelo de raciocínio dos agentes e a implementação do protótipo; a Seção 4 apresenta os experimentos realizados; por fim, a Seção 5 apresenta as conclusões.

2. Trabalhos Relacionados

Os SMA têm sido empregados como estratégia para ampliar a personalização, a adaptabilidade e a responsividade de ambientes educacionais, por meio da recomendação personalizada de OA, construção de ambientes adaptativos e mediação da interação entre estudantes e agentes inteligentes.

O trabalho de [Nouzri et al. 2024] apresenta um sistema multiagente destinado ao ensino da língua luxemburguesa, no qual agentes especializados são modelados por meio da *Business Process Management Notation* e integrados a *Large Language Models* (LLM). A arquitetura distribui funcionalidades entre agentes e possibilita a adaptação das interações em tempo real, aproximando a experiência educacional de uma tutoria personalizada. O estudo evidencia, assim, o potencial da integração entre SMA e LLM para ampliar a capacidade adaptativa e interativa de sistemas educacionais.

No contexto da recomendação de OA, diversas abordagens utilizam SMA para personalizar a experiência educacional a partir das necessidades individuais dos estudantes. Enquanto [Almeida et al. 2021] adotam o modelo deliberativo *Belief-Desire-Intention* (BDI) para orientar a seleção de conteúdos em Ambientes Virtuais de Aprendizagem via perfil e histórico acadêmico, [Frade 2015] integra SMA a algoritmos genéticos

em um ambiente virtual tridimensional. Ampliando essa personalização para a acessibilidade, o SIMROAA [Mourão and Netto 2019] utiliza agentes desenvolvidos em JADE para filtrar OA considerando o tipo de deficiência do usuário e a confiança em comunidades de prática. Em conjunto, essas propostas evidenciam a eficácia de articular SMA a diferentes técnicas computacionais para aprimorar a seleção e a interatividade dos recursos educacionais.

Sob uma perspectiva arquitetural, [Ciloglugil and Inceoglu 2018] propõem um ambiente de *e-learning* adaptativo fundamentado no Metamodelo de Agentes e Artefatos (A&A). A abordagem organiza agentes e artefatos de forma complementar, permitindo representar tanto comportamentos autônomos quanto recursos e modelos envolvidos na adaptação do ambiente. Essa estrutura proporciona maior flexibilidade na representação dos diferentes componentes do processo educacional.

Em síntese, os estudos evidenciam a relevância dos SMA para diferentes dimensões da personalização educacional, contemplando aprendizagem de domínios específicos [Nouzri et al. 2024], recomendação baseada em perfil e histórico [Almeida et al. 2021], acessibilidade [Mourão and Netto 2019], flexibilidade arquitetural [Ciloglugil and Inceoglu 2018] e ambientes virtuais associados à inteligência computacional [Frade 2015]. Contudo, observa-se limitada integração entre interação em linguagem natural, modelagem do estudante, tomada de decisão autônoma, recomendação de OA e orientação acadêmica em uma arquitetura unificada.

Nesse contexto, o EDUPersona diferencia-se ao integrar agentes autônomos e especializados, LLM e mecanismos de recomendação de OA em uma arquitetura orientada à personalização. A interação em linguagem natural permite identificar necessidades e compreender o contexto do estudante, enquanto a cooperação entre agentes subsidia a análise do perfil acadêmico, a seleção de recursos e a definição de orientações individualizadas. Dessa forma, a proposta transcende a recomendação isolada de conteúdos, configurando uma abordagem de orientação acadêmica adaptativa, contextualizada e centrada no estudante.

3. Proposta

A concepção do EDUPersona fundamenta-se em teorias clássicas da aprendizagem que compreendem o estudante como sujeito ativo na construção do conhecimento. Segundo [Piaget 2010], o desenvolvimento cognitivo ocorre continuamente a partir da interação do indivíduo com o meio, sendo mediado pelos processos de assimilação e acomodação. A assimilação corresponde à incorporação de novas experiências aos esquemas cognitivos existentes, enquanto a acomodação consiste na reorganização desses esquemas diante de situações que não podem ser adequadamente compreendidas com base nos conhecimentos prévios. Esses processos evidenciam que a aprendizagem constitui um processo ativo de adaptação e construção intelectual, em oposição à perspectiva de mera transmissão de informações.

Complementarmente, [Vygotsky et al. 1984] enfatiza a dimensão sociocultural da aprendizagem, compreendendo o conhecimento como uma construção mediada pelas interações sociais, pela linguagem e pelos artefatos culturais. Nessa perspectiva, a aprendizagem é favorecida pela interação com um “outro mais experiente”, capaz de oferecer suporte e orientação durante a realização de atividades que o estudante ainda não consegue

executar autonomamente. Esse espaço entre o nível de desenvolvimento real e o nível de desenvolvimento potencial é denominado Zona de Desenvolvimento Proximal (ZDP). A mediação nesse contexto contribui para a aquisição progressiva de competências, favorecendo a internalização do conhecimento e o desenvolvimento da autonomia do aprendiz.

3.1. Modelagem

Alinhado a esses pressupostos teóricos, o EDUPersona é estruturado por três agentes interconectados, cada qual com responsabilidades específicas:

- **Agente de Comunicação** - Atua como principal interface entre o sistema e o estudante, mediando a interação em linguagem natural por meio de LLM. Além de promover uma comunicação contextualizada e adaptativa, coleta *feedbacks* que subsidiam as inferências dos demais agentes.
- **Agente Avaliador** - Realiza a caracterização do perfil discente mediante a análise do desempenho, do nível de proficiência e de sua evolução ao longo do tempo. Com base nessas informações e em regras previamente estabelecidas, o agente classifica e diagnostica a situação acadêmica do estudante, atualiza seu histórico de aprendizagem e produz indicadores analíticos que subsidiam intervenções pedagógicas mais precisas, oportunas e alinhadas às suas necessidades individuais.
- **Agente Tutor** - Analisa os *feedbacks* e as demandas identificadas para recomendar OA disponíveis. Busca maximizar a adequação pedagógica das recomendações, considerando critérios de qualidade, relevância e personalização, de modo a favorecer a aprendizagem e a evolução do desempenho do estudante.

A Tabela 1 apresenta a modelagem PEAS (*Performance Measures, Environment, Actuators and Sensors*), caracterizando desempenho, ambiente, atuadores e sensores dos agentes do sistema [Russell and Norvig 2020].

Tabela 1. Tabela PEAS dos agentes.

PEAS	Descrição
Performance Measure	Agente de Comunicação: Tradução das intenções pedagógicas de forma acessível e humanizada. Agente Avaliador: Precisão na avaliação e diagnóstico do aluno. Agente Tutor: Precisão das recomendações e tempo de resposta.
Environment	Todos: Parcialmente observável, não determinístico, sequencial, dinâmico, discreto e multiagente.
Actuators	Agente de Comunicação: Interface de recomendação, fornecimento <i>feedbacks</i> e disponibilização de OA. Agente Avaliador: Processar dados a partir de evidências de aprendizagem, geração de relatórios e atualização de informações. Agente Tutor: Pesquisa por OA na internet em bases acadêmicas, repositórios educacionais e plataformas institucionais previamente selecionadas por sua confiabilidade e relevância, recomendação de OA e maximização recompensas a partir da recomendação de OA.
Sensors	Agente de Comunicação: Registros de conversas, dados de preferência, histórico de interação, dados de requisições e coleta de <i>feedbacks</i> . Agente Avaliador: Registros de avaliações, histórico de desempenho. Agente Tutor: Informações de desempenho, requisição de OA e <i>feedbacks</i> .

A metodologia Tropos foi adotada para a modelagem e especificação dos requisitos do sistema, por constituir uma abordagem de engenharia de software orientada a

agentes e fundamentada na modelagem orientada a objetivos (*Goal-Oriented Requirements Engineering*) [Bresciani et al. 2004]. Baseada no modelo *i** [Yu et al. 2011], esta abordagem emprega atores, objetivos e dependências para representar processos organizacionais e explicitar as motivações e responsabilidades dos *stakeholders*. Seu ciclo de desenvolvimento compreende cinco fases: (i) requisitos iniciais; (ii) requisitos finais; (iii) projeto arquitetural; (iv) projeto detalhado; e (v) implementação.

Os requisitos iniciais do projeto, elaborados com o auxílio da ferramenta PiStar [Pimentel and Castro 2018] são apresentados na Figura 1. O modelo evidencia os principais atores envolvidos e as respectivas relações de dependência estabelecidas entre eles, onde as setas indicam origem/destino de interação entre as entidades. Além disso, o diagrama explicita os objetivos, as metas e as tarefas centrais do sistema, proporcionando uma visão integrada do contexto organizacional e das motivações que fundamentam seu funcionamento e orientam os processos de tomada de decisão.




Figura 1. Requisitos iniciais do EDUPersona.

Esse modelo apresenta tarefas essenciais do sistema, a começar pela interação entre o Aluno e o Agente de Comunicação. Este atua como mediador, encaminhando evidências de aprendizagem ao Agente Avaliador para diagnóstico e solicitando conteúdos didáticos ao Agente Tutor. Por sua vez, o Agente Avaliador subsidia o Agente Tutor com os resultados desses diagnósticos, permitindo a recomendação precisa de OA para o estudante. Desse modo, o modelo consolida uma visão integrada dos requisitos, assegurando o alinhamento entre os objetivos pedagógicos, a tomada de decisão dos agentes e o suporte à aprendizagem adaptativa.

3.2. Arquitetura de Software

A arquitetura de *software* é estruturada em camadas verticalizadas, com fluxo bidirecional de processamento organizado em duas etapas. Na primeira, as solicitações do estudante são recebidas, interpretadas e processadas a partir das informações contextuais disponíveis, incluindo dados acadêmicos e histórico de interações. Na segunda, os resultados desse processamento subsidiam a tomada de decisão dos agentes e a geração da resposta final, posteriormente encaminhada ao estudante por meio da interface. Essa organização promove a separação de responsabilidades, o desacoplamento funcional e a coordenação entre os componentes, integrando os mecanismos de interação humano-computador, os processos de raciocínio inteligente e a persistência de dados.

A Figura 2 apresenta uma visão geral da arquitetura, evidenciando a organização das camadas e a interação entre os agentes durante o processo de orientação educacional.




Figura 2. Arquitetura de software do EDUPersona.

- **Camada de Interface** – Media a interação entre o estudante e o sistema por meio de um *chat* inteligente. Nessa camada, solicitações, preferências e informações acadêmicas são estruturadas em *prompts*, interações conversacionais e atividades didático-pedagógicas. O Agente de Comunicação, integrado a um modelo LLM, interpreta as solicitações, processa informações contextuais e conduz o diálogo em linguagem natural, adaptando-se às características e necessidades do usuário. Adicionalmente, apresenta respostas, lembretes e resultados decorrentes das interações.
- **Camada de Agentes** – Responsável pelo processamento cognitivo, pela tomada de decisão e pela adaptação pedagógica. Nessa camada atuam os Agentes Avaliador e Tutor. O primeiro analisa evidências de aprendizagem e produz diagnósticos do desempenho discente; o segundo ajusta políticas de recomendação, avalia recompensas associadas às intervenções e seleciona OA adequados. A comunicação entre os agentes utiliza o protocolo XMPP, favorecendo a interoperabilidade e a escalabilidade da solução.
- **Camada de Dados** - A camada de dados armazena, organiza e disponibiliza informações necessárias ao funcionamento do sistema e ao raciocínio dos agentes. Mantém registros do progresso acadêmico, desempenho, histórico de interações, preferências e conversas, subsidiando os processos de diagnóstico, personalização e recomendação educacional.

3.3. Modelo de Raciocínio dos Agentes

O EDUPersona adota um modelo de raciocínio híbrido, integrando diferentes paradigmas de agentes inteligentes para ampliar sua capacidade de adaptação, autonomia e tomada de decisão. Essa abordagem permite combinar as características complementares de cada

paradigma, favorecendo respostas adequadas às demandas pedagógicas e às dinâmicas do processo de aprendizagem.

O Agente de Comunicação emprega um modelo híbrido reativo–deliberativo, combinando mecanismos reativos para o tratamento de demandas imediatas e mecanismos deliberativos para situações que requerem planejamento. O agente considera informações históricas do estudante, avalia alternativas de interação e seleciona estratégias comunicacionais compatíveis com o contexto, favorecendo interações naturais e empáticas. Essa capacidade é complementada pela integração com um módulo baseado em LLM, responsável por adaptar o vocabulário, a complexidade textual e o estilo discursivo às características da interação. A Figura 3 apresenta o fluxo de raciocínio adotado pelo Agente de Comunicação.




Figura 3. Fluxo de raciocínio do Agente de Comunicação.

O Agente Avaliador é concebido como um agente reativo, fundamentado em regras e heurísticas predefinidas, responsável por analisar o desempenho acadêmico do estudante a partir dos resultados obtidos em avaliações associadas aos OA, previamente recomendados pelo Agente Tutor e realizadas na própria ferramenta. A partir desses indicadores, o agente identifica lacunas de aprendizagem, classifica o desempenho discente e gera um relatório encaminhado ao Agente Tutor, subsidiando o refinamento das recomendações pedagógicas. A cada atualização dos indicadores avaliativos, a análise é reexecutada, permitindo verificar a manutenção ou a evolução da classificação de desempenho do estudante.

Paralelamente, o Agente Tutor coleta *feedbacks* provenientes das interações do estudante com o sistema e os utiliza para ajustar progressivamente suas recomendações. Esse mecanismo orienta a seleção de OA com vistas à maximização das recompensas associadas à efetividade das intervenções pedagógicas e à evolução do desempenho discente, promovendo a adaptação contínua das recomendações às necessidades individuais do estudante.

3.4. Implementação do Protótipo

O protótipo do EDUPersona foi desenvolvido com o framework SPADE e o *plugin* SpadeLLM, responsável pela integração com modelos de linguagem de grande escala. Essa integração possibilita adaptar dinamicamente o vocabulário, a complexidade textual e o estilo de interação ao contexto do usuário. O suporte a *tools* amplia essa capacidade ao permitir o acesso a recursos externos e informações atualizadas. Adicionalmente, mecanismos de *guardrails* foram incorporados para mitigar alucinações, proteger informações sensíveis e detectar ou bloquear tentativas de injeção de *prompts* [Biswas and Talukdar 2023]. Essa camada valida assincronamente as mensagens com base em termos-chave educacionais, restringindo o processamento ao escopo pedagógico definido e orientando o usuário diante de desvios temáticos, conforme exemplo de interação ilustrado na Figura 4.

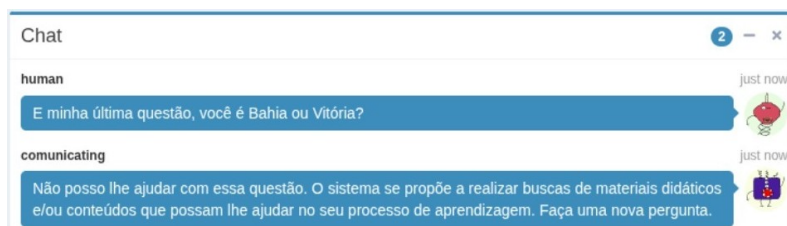


Figura 4. Mecanismo de *guardrail* na interação com o Agente de Comunicação.

4. Experimentos

Com o objetivo de avaliar a viabilidade do EDUPersona, foram implementadas funcionalidades essenciais ao suporte à orientação educacional personalizada e sensível ao contexto, mediada por OA. Destacam-se: (i) a recuperação de informações discentes a partir de um sistema acadêmico simulado; (ii) a análise e inferência da situação acadêmica; (iii) a geração de relatórios avaliativos; e (iv) a recomendação adaptativa de OA. A comunicação entre os agentes foi estabelecida por meio da troca de mensagens utilizando o protocolo XMPP. As etapas de desenvolvimento são apresentadas a seguir, contemplando os procedimentos adotados na concepção, implementação e validação da solução, bem como os principais elementos da abordagem proposta.

4.1. Preparação do Ambiente e Geração dos Dados

Inicialmente, com o objetivo de subsidiar os experimentos e a validação do protótipo, foi desenvolvida uma base de dados sintéticos, utilizando a ferramenta ChatGPT, destinada à simulação de um sistema acadêmico simplificado. A modelagem dessa base de dados adotou uma estrutura relacional composta pelas entidades Aluno, Avaliação, Disciplina, Matrícula, Professor e Turma. Adicionalmente, foi elaborado um arquivo estruturado contendo um conjunto de OA empregados na simulação, no qual cada registro corresponde

a um OA associado a uma disciplina específica, também gerado por meio do ChatGPT. Tanto o sistema acadêmico simulado quanto o arquivo de OA foram utilizados como recursos externos acessados pelos agentes, cujo acesso foi viabilizado por meio de funções específicas disponibilizadas via mecanismo de *tools*.

4.2. Estratégias Cognitivas

A construção dos Agentes de Comunicação e Tutor fundamentou-se no uso de *personas*, estabelecidas para orientar comportamentos, processos de raciocínio e interações conforme papéis e responsabilidades previamente definidos. Essa estratégia promove o alinhamento das decisões aos objetivos pedagógicos do sistema, conferindo maior consistência e coerência às atuações dos agentes. As respectivas *personas* são apresentadas na Tabela 2.

Tabela 2. Definição de *personas* do Agente de Comunicação e Agente Tutor.

Agente	Persona
Agente de Comunicação	Você é um agente de interface para interação em uma ferramenta de apoio pedagógico.
Agente Tutor	Você é um especialista pedagógico com o propósito de auxiliar alunos por meio de recomendação de Objetos de Aprendizagem.

Posteriormente, definiu-se o fluxo de trabalho individual de cada agente com base na estratégia de *chain-of-thought*, empregada para estruturar, em linguagem natural, as etapas intermediárias de raciocínio associadas à execução das tarefas e à tomada de decisão [Wei et al. 2022]. Essa abordagem sistematiza o processamento dos agentes, favorecendo a organização das inferências e decisões, além de possibilitar o refinamento dos fluxos de execução e a identificação de inconsistências. Como exemplo, o fluxo adotado pelo Agente de Comunicação compreende:

1. Identificar se a solicitação está relacionada ao desempenho acadêmico ou à recomendação de objetos de aprendizagem;
2. Caso esteja relacionada ao desempenho, identificar a matrícula do estudante;
3. Utilizar *tools* de consulta para recuperar os respectivos dados de desempenho;
4. Caso esteja relacionada à recomendação de objetos de aprendizagem, identificar a disciplina para a qual o estudante solicita a recomendação.

A construção dos Agentes de Comunicação e Tutor incorporou *templates* destinados à padronização e estruturação das saídas textuais, assegurando sua aderência aos requisitos do sistema. Essa estratégia favorece a interoperabilidade, reduz ambiguidades interpretativas e promove maior consistência no fluxo informacional. O Agente Tutor, por exemplo, organiza as recomendações mediante a apresentação do título e da descrição do OA, estabelecendo um formato uniforme.

Para o Agente Avaliador, adotou-se uma estratégia cognitiva baseada em quatro faixas de desempenho, definidas a partir de critérios avaliativos derivados das interações do discente com os OA no sistema e de registros de desempenho acadêmico armazenados em banco de dados. Essa estratégia permite classificar o desempenho, identificar lacunas de aprendizagem e subsidiar a recomendação de OA, conforme apresentado na Tabela 3.

Tabela 3. Classificação do desempenho discente e recomendações.

Faixa de desempenho	Classificação	Diagnóstico/Recomendação ao Agente Tutor
Nota < 5.0	Baixo	Materiais introdutórios; conteúdos fundamentais; glossários de conceitos; recursos de passo a passo.
$5.0 \leq \text{Nota} < 7.5$	Regular	Materiais de reforço; revisões estruturadas; exemplos contextualizados; quizzes diagnósticos.
$7.5 \leq \text{Nota} < 9.0$	Alto	Materiais intermediários e avançados; estudos de caso; materiais de aplicação prática; simulações; resolução de problemas contextualizados com menor tutoria.
$9.0 \leq \text{Nota} \leq 10.0$	Excelente	Materiais avançados e aprofundados; projetos práticos; problemas complexos com menor ou nenhuma tutoria.

4.3. Simulação de Interação no Ambiente do EDUPersona

O fluxo inicia-se com o fornecimento da matrícula pelo usuário, que, em seguida, solicita informações relacionadas ao seu desempenho acadêmico. A partir dessa requisição, o Agente de Comunicação consulta os dados acadêmicos pertinentes, complementando as informações necessárias e encaminhando-as ao Agente Avaliador. Com base nas regras estabelecidas e nos dados obtidos, o Agente Avaliador realiza o diagnóstico da situação acadêmica do discente.

Posteriormente, as informações resultantes são encaminhadas ao Agente Tutor, responsável por identificar e recomendar materiais didáticos adequados às necessidades de aprendizagem do discente. O sistema também permite a solicitação de OA em formatos específicos. Esse recurso é ilustrado na Figura 5, na qual o usuário manifesta interesse por recomendações personalizadas e explicita suas preferências quanto ao formato dos materiais educacionais. Tal funcionalidade demonstra a capacidade do sistema de incorporar características e preferências individuais ao processo de recomendação, favorecendo experiências de aprendizagem mais adaptativas e alinhadas às necessidades pedagógicas do discente.



Figura 5. Solicitação de OA em formato específico de vídeo.

5. Conclusão

Este trabalho apresentou o EDUPersona, um sistema multiagente destinado à orientação educacional personalizada e sensível ao contexto, fundamentada na recomendação adaptativa de OA. A proposta integra agentes com papéis complementares para analisar o perfil, o desempenho e a evolução do estudante, promovendo interações alinhadas às suas necessidades de aprendizagem. Como principais resultados, destacam-se a definição conceitual baseada no modelo PEAS, a modelagem segundo a metodologia Tropos, a

especificação da arquitetura de *software* e o desenvolvimento de um protótipo funcional. Este contempla as etapas (ii) Requisitos Finais e (iii) Projeto Arquitetural, conforme definido na Subseção 3.1. O código-fonte e a documentação estão disponíveis em: <https://github.com/jorgepgjr/edupersona>.

Os resultados obtidos evidenciam o potencial do EDUPersona para o desenvolvimento de tutores digitais adaptativos, integrando SMA e LLM em uma abordagem centrada no estudante. Como trabalhos futuros, pretende-se investigar estratégias de aprendizagem por reforço, incluindo *SARSA* e *Q-Learning*, bem como realizar experimentos em contextos educacionais reais, com o emprego de repositórios de OA, visando avaliar o desempenho, a usabilidade e o impacto pedagógico da solução.

Referências

- Almeida, T. O., De Magalhães Netto, J. F., and Lopes, A. M. M. (2021). Multi-agent system for recommending learning objects in e-learning environments. In *2021 IEEE Frontiers in Education Conference (FIE)*, pages 1–5.
- Biswas, A. and Talukdar, W. (2023). Guardrails for trust, safety, and ethical development and deployment of large language models (llm). *Journal of Science amp; Technology*, 4(6):55–82.
- Bresciani, P., Perini, A., Giorgini, P., Giunchiglia, F., and Mylopoulos, J. (2004). Tropos: An agent-oriented software development methodology. *Autonomous Agents and Multi-Agent Systems*, 8(3):203–236.
- Cardoso, C. A., Ferreira, V. A., and Barbosa, F. C. G. (2020). (des) igualdade de acesso à educação em tempos de pandemia: uma análise do acesso às tecnologias e das alternativas de ensino remoto. *Revista Com Censo: Estudos Educacionais do Distrito Federal*, 7(3):38–46.
- Chu, Z., Wang, S., Xie, J., Zhu, T., Yan, Y., Ye, J., Zhong, A., Hu, X., Liang, J., Yu, P. S., and Wen, Q. (2025). Llm agents for education: Advances and applications.
- Ciloglugil, B. and Inceoglu, M. M. (2018). An adaptive e-learning environment architecture based on agents and artifacts metamodel. In *2018 IEEE 18th International Conference on Advanced Learning Technologies (ICALT)*, pages 72–74.
- Coelho, N. L. N., Willima, K. G., da Cruz Ferreira, C., and Souza, L. B. P. (2025). Gamificação na educação contemporânea: Estratégia de engajamento e personalização do ensino. *Revista Multidisciplinar do Nordeste Mineiro*, 3(1):1–14.
- Comitê Gestor da Internet no Brasil (2025). *Pesquisa sobre o uso das tecnologias de informação e comunicação nas escolas brasileiras: TIC Educação 2024*. Comitê Gestor da Internet no Brasil, São Paulo, 1 edition, ISBN: 978-65-85417-93-8. Disponível em: https://cetic.br/media/docs/publicacoes/2/pt-br/20251217165522/tic_educacao_2024_livro_completo.pdf.
- Dahal, C., Chen, J., Ye, M., and Xiong, Z. (2026). Multi-agent systems in education: A survey from the trustworthiness perspective. *IEEE Transactions on Artificial Intelligence*, pages 1–16.

- Frade, R. V. C. (2015). Univirtual - ambiente virtual 3d multiagente com recomendação personalizada de objetos de aprendizagem. Master's thesis, Universidade do Estado do Rio Grande do Norte / Universidade Federal Rural do Semi-Árido, Mossoró, RN.
- IEEE Learning Technology Standards Committee (2020). *IEEE Standard for Learning Object Metadata*. Institute of Electrical and Electronics Engineers, New York.
- Jiang, Y.-H., Liu, T.-Y., Zhuang, X., Hu, H., Li, R., and Jia, R. (2024). Enhancing educational practices with multi-agent systems: A review. *Enhancing Educational Practices: Strategies for Assessing and Improving Learning Outcomes*, pages 47–65.
- Mohamedhen, A. S., Alfazi, A., Arfaoui, N., Ejbali, R., and Nanne, M. F. (2024). Towards multi-agent system for learning object recommendation. *Heliyon*, 10(20).
- Mourão, A. B. and Netto, J. F. M. (2019). Simroaa multi-agent recommendation system for recommending accessible learning objects. In *2019 IEEE Frontiers in Education Conference (FIE)*, pages 1–9.
- Nouzri, S., EL Fatimi, M., Guerin, T., Othmane, M., and Najjar, A. (2024). Beyond chatbots: Enhancing luxembourgish language learning through multi-agent systems and large language model. In *International Conference on Principles and Practice of Multi-Agent Systems*, pages 385–401. Springer.
- Piaget, J. (2010). *A formação do símbolo na criança: imitação, jogo e sonho, imagem e representação*. Biblioteca de Ciências da Educação. Zahar, Rio de Janeiro, RJ, 4 edition, ISBN: 9788521617617.
- Pimentel, J. and Castro, J. (2018). pistar tool—a pluggable online tool for goal modeling. In *2018 IEEE 26th International Requirements Engineering Conference (RE)*, pages 498–499. IEEE.
- Russell, S. and Norvig, P. (2020). *Artificial Intelligence: A Modern Approach*. Pearson, 4th edition.
- Vygotsky, L. S. et al. (1984). *A formação social da mente*. São Paulo, 3.
- Wang, L., Ma, C., Feng, X., Zhang, Z., Yang, H., Zhang, J., Chen, Z., Tang, J., Chen, X., Lin, Y., et al. (2024). A survey on large language model based autonomous agents. *Frontiers of Computer Science*, 18(6):186345.
- Wei, J., Wang, X., Schuurmans, D., Bosma, M., Xia, F., Chi, E., Le, Q. V., Zhou, D., et al. (2022). Chain-of-thought prompting elicits reasoning in large language models. *Advances in neural information processing systems*, 35:24824–24837.
- Wiley, D. A. (2002). *The Instructional Use of Learning Objects*. Association for Instructional Technology and Association for Educational Communications Technology, 1 edition, ISBN: 0-7842-0892-1.
- Wooldridge, M. (2009). *An introduction to multiagent systems*. John wiley & sons.
- Yin, W. (2022). Personalized hybrid education framework based on neuroevolution methodologies. *Computational Intelligence and Neuroscience*, 2022(1):6925668.
- Yu, E. et al. (2011). Modeling strategic relationships for process reengineering. *Social Modeling for Requirements Engineering*, 11(2011):66–87.