EVENTO ON-LINE
ConBRepro
XVI CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO
02 a 04 de dezembro de 2026
Inovação e Transformação Digital como Estratégia Competitiva nas Engenharias

EVES.AI: Modelo Inteligente para Previsão e Explicação do Risco de Evasão e Recomendação de Ações para a Permanência Estudantil

Alexandre Souza dos Santos
Curso de Bacharelado em Sistemas de Informação - Instituto Federal do Tocantins (IFTO)
Artur Muniz dos Santos
Curso de Bacharelado em Sistemas de Informação - Instituto Federal do Tocantins (IFTO)
Maísa Santos Ribeiro
Curso de Bacharelado em Sistemas de Informação - Instituto Federal do Tocantins (IFTO)
Pedro Henrique Campos Mendes
Curso de Bacharelado em Sistemas de Informação - Instituto Federal do Tocantins (IFTO)
Arthur da Silva Magalhães
Curso de Bacharelado em Sistemas de Informação - Instituto Federal do Tocantins (IFTO)

Resumo: A evasão é um dos principais desafios das Instituições Federais de Ensino (IFE), com taxa média próxima de 41% nos cursos técnicos da Rede Federal. Embora existam planos de permanência e êxito, o acompanhamento ainda depende de planilhas e processos manuais, e os modelos preditivos descritos na literatura raramente se convertem em intervenções. Este artigo apresenta o EVES.AI, produto mínimo viável (MVP) de uma plataforma de inteligência artificial que identifica estudantes em risco, explica os fatores desse risco e sugere planos de ação fundamentados nas normas nacionais e nos documentos de cada instituição. A pesquisa seguiu a *Design Science Research*, com o CRISP-DM no componente preditivo. O MVP foi implementado em Python como microsserviços FastAPI que trocam eventos pelo RabbitMQ, com PostgreSQL para dados transacionais e auditoria, Redis para cache e controle de concorrência e um módulo de Geração Aumentada por Recuperação (RAG) que combina embeddings multilíngues indexados no Qdrant a um modelo de linguagem aberto executado na infraestrutura da instituição. São apresentadas as telas da plataforma, as decisões de arquitetura e a validação funcional do fluxo completo, da ingestão dos dados à aprovação humana do plano de ação, com dados sintéticos e o Instituto Federal do Tocantins (IFTO) como caso de referência. Os resultados mostram que a arquitetura fecha o ciclo predição–explicação–ação com recomendações rastreáveis, isolamento de dados por instituição e aderência à LGPD, o que a deixa pronta para o piloto com dados reais.

Palavras-chave: Evasão escolar, Inteligência artificial generativa, Geração aumentada por recuperação, Microsserviços, Instituições federais de ensino.

EVES.AI: An Intelligent Model for Predicting and Explaining Dropout Risk and Recommending Actions for Student Retention

Abstract: Student dropout is one of the main challenges of Brazilian Federal Education Institutions (FEIs), reaching an average of about 41% in technical courses of the Federal Network. Although retention plans exist, monitoring still relies on spreadsheets and manual processes, and the predictive models found in the literature rarely turn into interventions. This paper presents EVES.AI, the minimum viable product (MVP) of an artificial intelligence platform that identifies

at-risk students, explains the factors behind the risk and suggests action plans grounded in national regulations and in each institution's own documents. The research followed Design Science Research, with CRISP-DM for the predictive component. The MVP was implemented in Python as FastAPI microservices exchanging events through RabbitMQ, with PostgreSQL for transactional data and auditing, Redis for caching and concurrency control, and a Retrieval-Augmented Generation (RAG) module that combines multilingual embeddings indexed in Qdrant with an open-weight language model running on the institution's infrastructure. The paper shows the platform's screens, the architectural decisions and the functional validation of the complete flow, from data ingestion to human approval of the action plan, using synthetic data and the Federal Institute of Tocantins (IFTO) as reference case. Results show that the architecture closes the prediction–explanation–action loop with traceable recommendations, per-institution data isolation and compliance with Brazil's General Data Protection Law, making it ready for a pilot with real data.

Keywords: Student dropout, Generative artificial intelligence, Retrieval-augmented generation, Microservices, Federal education institutions.

1. Introdução

A expansão das Instituições Federais de Ensino (IFE), com a interiorização das universidades federais e a criação da Rede Federal de Educação Profissional, Científica e Tecnológica pela Lei nº 11.892/2008 (BRASIL, 2008), ampliou o acesso à educação pública no interior do país, mas não assegurou a permanência dos estudantes. Dados de 2024 indicam taxa média de evasão próxima de 41% nos cursos técnicos da Rede Federal (DIAS, 2025) e, no ensino superior, o Censo registrou em 2022 taxa de desistência acumulada de 58% (INEP, 2023). Em resposta, a SETEC/MEC orientou a elaboração de Planos Estratégicos de Permanência e Êxito (BRASIL, 2014), e a Lei nº 14.914/2024 instituiu a Política Nacional de Assistência Estudantil – PNAES (BRASIL, 2024).

O Instituto Federal do Tocantins (IFTO), caso de referência deste trabalho, ilustra o problema. O plano de permanência e êxito do seu Centro de Referência em Educação a Distância registra evasão de 6,53% a 20,37% entre cursos e descreve ações como acompanhamento semanal de frequência, busca ativa e comunicação por e-mail e WhatsApp, apoiadas por formulários e relatórios (IFTO, 2023). São ações valiosas, porém manuais, reativas e sem orientação sistemática sobre qual intervenção é mais adequada a cada perfil de estudante.

A pesquisa em Mineração de Dados Educacionais já produz modelos precisos de predição da evasão, inclusive em instituições brasileiras, mas esses modelos raramente chegam às equipes pedagógicas e, quando chegam, não indicam o que fazer (COLPO *et al.*, 2024). Com os grandes modelos de linguagem (*Large Language Models* – LLMs), tornou-se viável converter predições e explicações numéricas em recomendações claras, o chamado "problema da última milha" (DAVAZDAHEMAMI; DELEN; DELEN, 2025; PEREIRA *et al.*, 2026). Falta, contudo, levar essa ideia a um sistema de engenharia de software que opere com os sistemas acadêmicos das IFE, respeite a Lei Geral de Proteção de Dados (LGPD) e possa ser replicado entre instituições.

O objetivo deste artigo é apresentar o produto mínimo viável (MVP) do EVES.AI, plataforma que integra predição de risco, explicabilidade e IA generativa com Geração Aumentada por Recuperação (RAG) para sugerir planos de ação personalizados, construída em Python sobre uma arquitetura de microsserviços com RabbitMQ, PostgreSQL, Redis e Qdrant. Especificamente, descrevem-se a arquitetura e as decisões que a fundamentam, o módulo de recomendação, as interfaces da plataforma e a validação funcional do fluxo completo. O trabalho adota a *Design Science Research* e está dividido em seis seções: a Seção 2 apresenta o referencial teórico e os trabalhos

relacionados; a Seção 3, a metodologia; a Seção 4, o MVP e sua validação; a Seção 5 discute diferenciais e limitações; e a Seção 6 traz as conclusões.

2. Referencial teórico

2.1 Evasão e permanência nas Instituições Federais de Ensino

A evasão é um fenômeno multicausal. O modelo de Tinto (1975) a explica pela interação entre características prévias do estudante, seu compromisso com os objetivos educacionais e seu grau de integração acadêmica e social. No contexto da Rede Federal, o documento orientador da SETEC agrupa os fatores em individuais (dificuldades de aprendizagem, necessidade de trabalhar, saúde), internos à instituição (currículo, infraestrutura, relação professor-aluno) e externos (condições socioeconômicas, transporte, contexto familiar) (BRASIL, 2014). Como um mesmo nível de risco pode ter causas distintas, a resposta também precisa ser distinta: apoio pedagógico, auxílio estudantil, acompanhamento psicológico ou flexibilização de horários.

2.2 Predição da evasão e explicabilidade

Na predição da evasão predominam classificadores baseados em comitês de árvores, como Random Forest, XGBoost, LightGBM e CatBoost, aplicados a variáveis acadêmicas, demográficas e socioeconômicas (COLPO *et al.*, 2024). O LightGBM destaca-se pela eficiência em dados tabulares (KE *et al.*, 2017). Para superar o caráter de caixa-preta desses modelos, o SHAP (*SHapley Additive exPlanations*) estima a contribuição de cada variável para a predição de um estudante específico (LUNDBERG; LEE, 2017), o que permite ao sistema dizer não apenas quem está em risco, mas por quê.

2.3 IA generativa, RAG e bancos de dados vetoriais

LLMs geram texto em linguagem natural, mas tendem a produzir respostas genéricas ou incorretas quando não dispõem do contexto adequado. A técnica RAG recupera trechos relevantes de uma base documental e os insere no *prompt*, ancorando a resposta em fontes verificáveis (LEWIS *et al.*, 2020). Para isso, os documentos são divididos em trechos (*chunks*) e convertidos em vetores (*embeddings*); modelos como o BGE-M3 produzem, em um único passo, representações densas e esparsas para mais de cem idiomas, inclusive o português (CHEN *et al.*, 2024). Os vetores são armazenados em bancos de dados vetoriais, que realizam busca aproximada por vizinhos mais próximos com índices como o HNSW (MALKOV; YASHUNIN, 2020).

2.4 Trabalhos relacionados

Iniciativas internacionais como o Course Signals, da Purdue University (ARNOLD; PISTILLI, 2012), o GPS Advising, da Georgia State University (GEORGIA STATE UNIVERSITY, 2024), e o OU Analyse, da Open University (KUZILEK *et al.*, 2015), combinam alertas de risco com a atuação de professores e orientadores. Davazdahemami, Delen e Delen (2025) acrescentaram SHAP e IA generativa para sugerir intervenções a estudantes do primeiro ano, e Pereira *et al.* (2026) usaram LLMs para traduzir explicações SHAP em *feedback* com dados de instituições brasileiras. No Brasil, destacam-se o SIDE, do IFSP (ALMEIDA; MARQUES, 2024), a solução de aprendizado de máquina da UFLA (UFLA, 2023) e o simulador PrevIA, baseado na Plataforma Nilo Peçanha (DIAS, 2025). O Quadro 1 sintetiza a comparação.

Quadro 1 – Comparação entre ferramentas de prevenção da evasão

Ferramenta (contexto)	Predição individual	Explicação dos fatores	Recomendação de ações	Várias instituições
Course Signals (Purdue, EUA)	Sim	Parcial	Mensagens do professor	Não

Ferramenta (contexto)	Predição individual	Explicação dos fatores	Recomendação de ações	Várias instituições
GPS Advising (Georgia State, EUA)	Sim	Parcial	Orientadores humanos	Não
OU Analyse (Open University, Reino Unido)	Sim	Parcial	Não automatizada	Não
Davazdahemami, Delen e Delen (2025)	Sim	Sim (SHAP)	Sim (IA generativa)	Não
Pereira *et al.* (2026)	Sim	Sim (SHAP)	*Feedback* via LLM	Não
SIDE (IFSP) e solução da UFLA	Sim	Parcial	Não	Não
PrevIA (Rede Federal, PNP)	Sim (simulador)	Sim (SHAP)	Não	Parcial
EVES.AI – MVP (IFE, referência IFTO)	Sim	Sim (SHAP)	Sim (RAG com citação das normas)	Sim

Fonte: Elaborado pelos autores (2026)

Em síntese, as soluções se concentram na predição, dependem de fluxos manuais para agir ou foram concebidas para uma única instituição. Nenhuma das iniciativas identificadas combina predição, explicação e recomendação fundamentada nas normas nacionais e nos documentos de cada IFE em uma arquitetura replicável.

3. Metodologia

Trata-se de pesquisa aplicada, de abordagem qualitativa e caráter exploratório e descritivo, conduzida segundo a *Design Science Research Methodology* (PEFFERS *et al.*, 2007), adequada à construção e avaliação de artefatos tecnológicos. As seis atividades do método foram assim instanciadas:

a) identificação do problema: levantamento bibliográfico e análise dos planos de permanência e êxito, do PNAES e do documento orientador da SETEC;

b) definição dos objetivos da solução: requisitos funcionais e não funcionais, com prioridade para rastreabilidade das recomendações, isolamento de dados entre IFE e execução local dos modelos;

c) projeto e desenvolvimento: construção incremental do MVP em ciclos curtos, com o componente preditivo guiado pelo CRISP-DM (CHAPMAN *et al.*, 2000);

d) demonstração: execução do fluxo completo sobre uma base sintética gerada a partir do modelo comum de atributos, com volumes e proporções inspirados em indicadores públicos da Rede Federal, e sobre documentos normativos públicos do IFTO;

e) avaliação: validação funcional por cenários de teste ponta a ponta, verificando cada requisito do MVP;

f) comunicação: o presente artigo.

O escopo do MVP inclui ingestão e pseudonimização de dados, cálculo do risco com explicação, base de conhecimento com RAG, geração e aprovação de planos de ação, trilha de auditoria e painéis. Ficam para a etapa seguinte a avaliação preditiva com dados reais, a validação das recomendações por especialistas e a medição de impacto na permanência, que dependem de aprovação no Comitê de Ética em Pesquisa e do piloto institucional. O uso exclusivo de dados sintéticos nesta fase é deliberado: permite desenvolver e testar a plataforma sem expor dados pessoais de estudantes.

4. Resultados: o MVP do EVES.AI

4.1 Arquitetura de microsserviços

A Figura 1 apresenta a arquitetura do MVP. Os usuários acessam uma aplicação web que consome a API REST de um *gateway* em FastAPI, responsável por autenticação, autorização por perfil e por instituição (*tenant*) e limitação de requisições. Atrás dele operam seis microsserviços em Python, executados em contêineres: (1) ingestão e conectores; (2) predição e explicabilidade; (3) base de conhecimento; (4) recomendação com RAG; (5) intervenções; e (6) notificação e auditoria.

Figura 1 – Arquitetura de microsserviços do MVP do EVES.AI

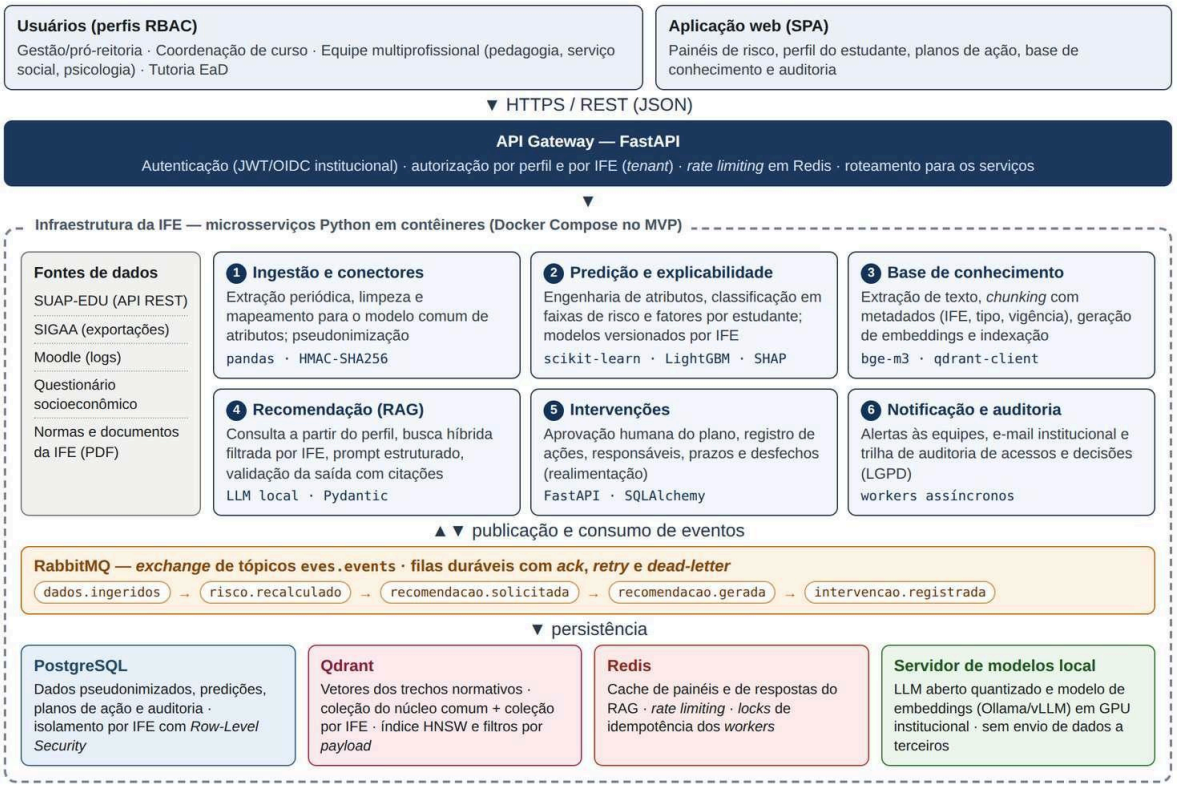

Fonte: Elaborado pelos autores (2026)

A comunicação entre os serviços é predominantemente assíncrona. Ao concluir uma carga, o serviço de ingestão publica o evento dados.ingeridos na *exchange* de tópicos do RabbitMQ; o serviço de predição o consome, recalcula o risco e publica risco.recalculado; para estudantes que entram na faixa de risco alto, é emitido recomendacao.solicitada, consumido pelo serviço de recomendação, cujo resultado (recomendacao.gerada) alimenta o painel e as notificações. Cada fila é durável, com confirmação explícita (*ack*), novas tentativas com espera crescente e fila de mensagens mortas (*dead-letter*). Como uma mesma mensagem pode ser entregue mais de uma vez, os *workers* usam *locks* no Redis, com chave derivada do identificador do evento, para garantir processamento idempotente. O Quadro 2 resume as principais decisões de arquitetura.

Quadro 2 – Principais decisões de arquitetura do MVP

Decisão	Alternativas avaliadas	Justificativa
Microsserviços em Python (FastAPI)	Monolito modular	Escalar à parte o serviço que usa GPU, isolar falhas e aproveitar o ecossistema Python de ciência de dados
Mensageria com RabbitMQ	Chamadas síncronas; Apache Kafka	Geração com LLM leva segundos; filas de trabalho com *ack*, *retry* e *dead-letter* atendem ao volume das IFE com menor custo operacional que o Kafka

Decisão	Alternativas avaliadas	Justificativa
PostgreSQL com *Row-Level Security*	Um banco por IFE	Transações, integridade e auditoria; isolamento por instituição sem multiplicar instâncias no MVP
Qdrant como banco vetorial	pgvector no PostgreSQL	Busca híbrida densa e esparsa, filtros por *payload* (IFE, vigência) e coleções por instituição, sem sobrecarregar o banco transacional
Redis	Cache em memória do processo	Cache compartilhado entre réplicas, *rate limiting* no *gateway* e *locks* de idempotência dos *workers*
LLM aberto e embeddings BGE-M3 locais	APIs comerciais de LLM	Dados de estudantes não saem da IFE (LGPD), custo previsível e bom desempenho em português
Saída estruturada com citação obrigatória	Texto livre	Permite validar automaticamente o plano e rastrear cada ação até a norma que a fundamenta

Fonte: Elaborado pelos autores (2026)

As decisões seguem o princípio de manter o MVP simples de operar sem comprometer a evolução. A separação em serviços com fronteiras definidas pelo domínio (NEWMAN, 2021) permite, por exemplo, que o servidor de modelos de linguagem, único componente que exige GPU, seja dimensionado à parte, e que uma falha no RAG não interrompa a ingestão nem os painéis. O uso de PostgreSQL e Qdrant em paralelo divide responsabilidades: o primeiro guarda o que precisa de transações e auditoria; o segundo, os vetores e os filtros semânticos.

4.2 Componente preditivo e explicativo

O serviço de ingestão mapeia os dados do SUAP-EDU, de exportações do SIGAA, dos registros do Moodle e do questionário socioeconômico para um modelo comum de atributos. Antes da persistência, a matrícula é substituída por um pseudônimo calculado com HMAC-SHA256 e chave secreta mantida pela IFE, e os campos identificáveis desnecessários são descartados. O serviço de predição deriva atributos como tendência de frequência, faltas consecutivas, variação de notas e reprovações acumuladas, e mantém um *pipeline* reprodutível que compara Regressão Logística, Random Forest e LightGBM com validação cruzada estratificada, priorizando *recall*, F1 e AUC-ROC. Cada modelo é versionado por IFE e nível de ensino, e os limiares das faixas de risco (baixo, moderado e alto) são parâmetros configuráveis pela instituição. Para cada estudante, o SHAP identifica os fatores que elevam ou reduzem o risco, agrupados nas dimensões individual, institucional e externa (BRASIL, 2014).

4.3 Módulo de recomendação com RAG

O módulo de recomendação opera em duas etapas (Figura 2). Na indexação, os documentos do núcleo comum (PNAES e orientações da SETEC) e os da IFE (organização didático-pedagógica, política de assistência estudantil, planos de permanência e regulamentos de monitoria) têm o texto extraído e dividido por seção, com sobreposição entre trechos. Cada trecho recebe metadados de instituição, tipo de norma, vigência e página, e é convertido em vetores denso e esparso pelo BGE-M3, executado localmente. Os vetores são gravados no Qdrant em uma coleção do núcleo comum e em uma coleção por IFE.

Figura 2 – Etapas de indexação e de geração do plano de ação no módulo RAG

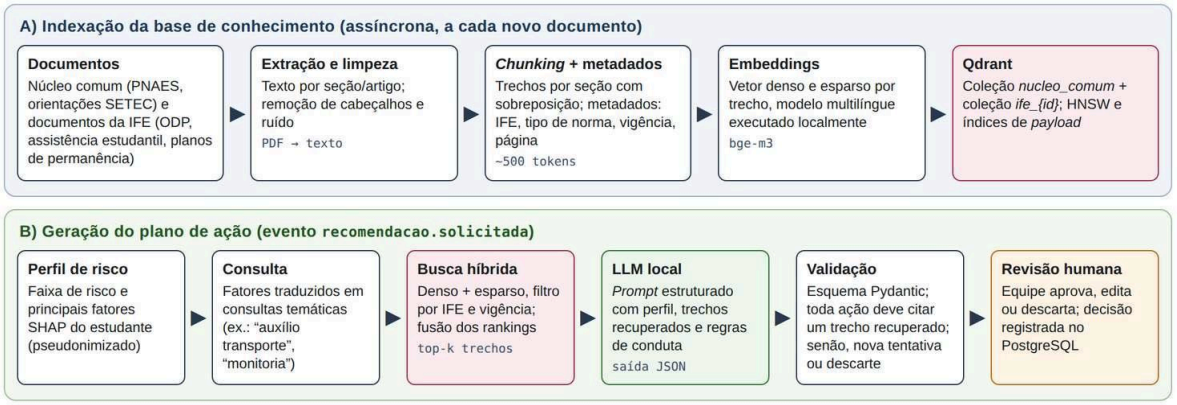

Fonte: Elaborado pelos autores (2026)

Na geração, os principais fatores SHAP do estudante são convertidos em consultas temáticas (por exemplo, "auxílio transporte" ou "monitoria"). A busca é híbrida (densa e esparsa), filtrada pela instituição do estudante e pela vigência do documento, com fusão dos rankings. Os trechos recuperados, o perfil pseudonimizado e as regras de conduta (linguagem acolhedora, não estigmatizar, não prometer benefícios fora dos editais) compõem um *prompt* estruturado enviado a um LLM aberto quantizado, servido na infraestrutura institucional. A resposta deve seguir um esquema JSON validado com Pydantic, no qual cada ação traz justificativa, responsável, prazo e ao menos uma citação a um trecho efetivamente recuperado. Respostas sem citação válida são descartadas e geradas novamente, o que reduz o risco de alucinações. O plano só se torna uma intervenção após aprovação da equipe (*human-in-the-loop*), e a decisão fica registrada no PostgreSQL.

4.4 Interfaces da plataforma

A Figura 3 mostra o painel de risco, com filtros por campus, nível de ensino e período, indicadores de estudantes monitorados e em cada faixa, distribuição do risco por campus, evolução semanal dos alertas e uma fila de priorização em que cada estudante aparece apenas pelo pseudônimo, com seus principais fatores e a situação do plano de ação. Os dados exibidos são sintéticos.

Figura 3 – Painel de risco de evasão do MVP (dados sintéticos)



Fonte: Elaborado pelos autores (2026)

A Figura 4 apresenta o perfil do estudante. À esquerda, os valores SHAP mostram o que aumenta e o que reduz o risco; à direita, o plano de ação gerado indica, para cada ação, a justificativa, o responsável, o prazo e a fonte normativa. Os botões de aprovar, editar e descartar materializam a supervisão humana, e o histórico registra a evolução do risco e as decisões anteriores da equipe.

Figura 4 – Perfil do estudante com fatores explicativos e plano de ação sugerido (dados sintéticos)



Fonte: Elaborado pelos autores (2026)

4.5 Validação funcional

A validação foi conduzida por cenários de teste ponta a ponta sobre a base sintética, com duas instituições fictícias configuradas para verificar o isolamento entre IFE. O Quadro 3 apresenta os requisitos do MVP e o resultado de cada verificação.

Quadro 3 – Requisitos do MVP e resultado da validação funcional

Código	Requisito verificado	Resultado
RF01	Ingerir dados acadêmicos e socioeconômicos e mapeá-los ao modelo comum de atributos	Atendido (SUAP); parcial (SIGAA via CSV)
RF02	Pseudonimizar identificadores antes da persistência	Atendido
RF03	Calcular o risco e os fatores SHAP de cada estudante a cada nova carga	Atendido
RF04	Indexar documentos normativos com metadados por instituição	Atendido
RF05	Gerar plano de ação com citação obrigatória de trechos recuperados	Atendido
RF06	Aprovar, editar ou descartar o plano, com registro na trilha de auditoria	Atendido
RF07	Isolar dados e documentos entre instituições	Atendido
RF08	Reprocessar mensagens com falha sem duplicar resultados	Atendido
RF09	Notificar as equipes por e-mail institucional	Parcial
RF10	Medir a efetividade das intervenções por perfil	Previsto para o piloto

Fonte: Elaborado pelos autores (2026)

Os cenários confirmaram o encadeamento completo do fluxo: uma nova carga de dados dispara o recálculo do risco, que gera a solicitação de recomendação, cujo plano aparece no painel para aprovação. Também se verificou que um usuário de uma instituição não acessa estudantes nem documentos de outra, tanto no PostgreSQL, pelas políticas de *Row-Level Security*, quanto no Qdrant, pelas coleções e filtros por instituição, e que a reentrega de mensagens não duplica planos nem intervenções.

5. Discussão: diferenciais e limitações

Em relação às ferramentas do Quadro 1, o EVES.AI se diferencia em quatro pontos: (i) integra predição, explicação e ação em um mesmo fluxo, respondendo à lacuna apontada por Colpo *et al.* (2024); (ii) fundamenta cada recomendação em documentos recuperados e citados, o que torna o processo auditável, em linha com Pereira *et al.* (2026), mas aplicado ao contexto das IFE; (iii) é multi-institucional por construção, com conectores para o SUAP e o SIGAA, base de conhecimento em dois níveis e isolamento de dados por instituição; e (iv) executa os modelos de linguagem e de *embeddings* na própria infraestrutura, sem enviar dados de estudantes a terceiros, em conformidade com a LGPD (BRASIL, 2018). A arquitetura orientada a eventos também favorece a evolução do produto: novos consumidores, como um serviço de avaliação de impacto, podem ser acrescentados sem alterar os existentes.

Quanto à proteção de dados, o MVP adota minimização, pseudonimização, controle de acesso por perfil e trilha de auditoria, e cada IFE permanece controladora dos dados de seus estudantes. A comunicação do risco evita rotular o estudante: o painel é restrito às equipes, e o plano é sempre mediado por um profissional.

O trabalho tem limitações. O desempenho preditivo ainda não foi medido com dados reais, e os modelos precisarão ser recalibrados para cada IFE e nível de ensino. A qualidade das recomendações depende da cobertura da base documental e ainda precisa ser avaliada por especialistas. Modelos abertos de menor porte, necessários para a execução local, podem produzir textos menos elaborados que os de grandes serviços comerciais, e a validação de citações reduz, mas não elimina, o risco de alucinações. Há ainda a necessidade de auditorias de viés entre grupos e de formação das equipes. Por fim, a tecnologia não substitui políticas estruturais de permanência, mas pode ajudar a direcioná-las a quem mais precisa.

6. Conclusões

Este artigo apresentou o MVP do EVES.AI, plataforma de inteligência artificial para prevenção da evasão nas Instituições Federais de Ensino. Motivado pela lacuna entre modelos que predizem a evasão e ações que a previnem, o trabalho seguiu a *Design Science Research* e construiu um artefato em Python com microsserviços, mensageria no RabbitMQ, PostgreSQL, Redis e um módulo RAG apoiado no Qdrant e em modelos abertos executados localmente.

Os resultados mostram uma arquitetura que identifica quem está em risco, explica por quê e sugere como agir, com recomendações rastreáveis às normas nacionais e institucionais, supervisão humana obrigatória e isolamento de dados entre instituições, validada funcionalmente de ponta a ponta com dados sintéticos. A contribuição do trabalho está em transformar a proposta de "última milha" em uma solução de engenharia replicável na Rede Federal e alinhada à LGPD.

Como trabalhos futuros, preveem-se a submissão ao Comitê de Ética e o piloto em campi do IFTO com dados reais; a avaliação das métricas preditivas e de equidade; a validação das recomendações por pedagogos, assistentes sociais, psicólogos e coordenadores; a medição do impacto nas taxas de permanência e conclusão; e a replicação em outras IFE que utilizam o SUAP ou o SIGAA.

Referências

ALMEIDA, M. F. B.; MARQUES, A. SIDE – Sistema Inteligente de Detecção de Evasão: aplicação em uma instituição de educação federal. **Revista Edutec – Educação, Tecnologias Digitais e Formação Docente**, v. 4, n. 1, 2024.

ARNOLD, K. E.; PISTILLI, M. D. Course Signals at Purdue: using learning analytics to increase student success. In: INTERNATIONAL CONFERENCE ON LEARNING ANALYTICS AND KNOWLEDGE, 2., 2012, Vancouver. **Proceedings** [...]. New York: ACM, 2012. p. 267-270.

BRASIL. Lei nº 11.892, de 29 de dezembro de 2008. Institui a Rede Federal de Educação Profissional, Científica e Tecnológica, cria os Institutos Federais de Educação, Ciência e Tecnologia, e dá outras providências. **Diário Oficial da União**: seção 1, Brasília, DF, 30 dez. 2008.

BRASIL. Lei nº 13.709, de 14 de agosto de 2018. Lei Geral de Proteção de Dados Pessoais (LGPD). **Diário Oficial da União**: seção 1, Brasília, DF, 15 ago. 2018.

BRASIL. Lei nº 14.914, de 3 de julho de 2024. Institui a Política Nacional de Assistência Estudantil (PNAES). **Diário Oficial da União**: seção 1, Brasília, DF, 4 jul. 2024.

BRASIL. Ministério da Educação. Secretaria de Educação Profissional e Tecnológica. **Documento orientador para a superação da evasão e retenção na Rede Federal de Educação Profissional, Científica e Tecnológica**. Brasília: MEC/SETEC, 2014.

CHAPMAN, P. *et al*. **CRISP-DM 1.0**: step-by-step data mining guide. Chicago: SPSS, 2000.

CHEN, J. *et al*. **BGE M3-Embedding**: multi-lingual, multi-functionality, multi-granularity text embeddings through self-knowledge distillation. arXiv:2402.03216, 2024.

COLPO, M. P.; PRIMO, T. T.; AGUIAR, M. S.; CECHINEL, C. Mineração de dados educacionais na predição da evasão estudantil: tendências, oportunidades e desafios. **Revista Brasileira de Informática na Educação**, v. 32, 2024.

DAVAZDAHEMAMI, B.; DELEN, A. H.; DELEN, D. Generative AI-enhanced interventions: a novel framework for predicting and mitigating freshman student attrition. **Journal of Management Analytics**, v. 12, n. 2, p. 346-369, 2025.

DIAS, J. C. **Técnicas de inteligência artificial para predição da evasão em cursos técnicos na Rede Federal de Educação Profissional, Científica e Tecnológica**. 2025. Dissertação (Mestrado) – Universidade Federal do Tocantins, Palmas, 2025.

GEORGIA STATE UNIVERSITY. **Approaching student success with predictive analytics**. Atlanta: GSU, [2024]. Disponível em: https://success.gsu.edu/approach/. Acesso em: 28 set. 2026.

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO TOCANTINS (IFTO). Centro de Referência em Educação a Distância. **Plano de permanência e êxito**. Palmas: IFTO, 2023.

INSTITUTO NACIONAL DE ESTUDOS E PESQUISAS EDUCACIONAIS ANÍSIO TEIXEIRA (INEP). **Censo da Educação Superior 2022**: divulgação dos resultados. Brasília: Inep, 2023.

KE, G. *et al*. LightGBM: a highly efficient gradient boosting decision tree. **Advances in Neural Information Processing Systems**, v. 30, p. 3146-3154, 2017.

KUZILEK, J.; HLOSTA, M.; HERRMANNOVA, D.; ZDRAHAL, Z.; WOLFF, A. OU Analyse: analysing at-risk students at The Open University. **Learning Analytics Review**, LAK15-1, p. 1-16, 2015.

LEWIS, P. *et al*. Retrieval-augmented generation for knowledge-intensive NLP tasks. **Advances in Neural Information Processing Systems**, v. 33, p. 9459-9474, 2020.

LUNDBERG, S. M.; LEE, S.-I. A unified approach to interpreting model predictions. **Advances in Neural Information Processing Systems**, v. 30, p. 4765-4774, 2017.

MALKOV, Y. A.; YASHUNIN, D. A. Efficient and robust approximate nearest neighbor search using hierarchical navigable small world graphs. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 42, n. 4, p. 824-836, 2020.

NEWMAN, S. **Building microservices**: designing fine-grained systems. 2. ed. Sebastopol: O'Reilly, 2021.

PEFFERS, K.; TUUNANEN, T.; ROTHENBERGER, M. A.; CHATTERJEE, S. A design science research methodology for information systems research. **Journal of Management Information Systems**, v. 24, n. 3, p. 45-77, 2007.

PEREIRA, F. D. *et al*. Translating XAI into actionable feedback using LLMs to prevent student dropout. In: INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE IN EDUCATION (AIED), 2026. **Proceedings** [...]. Cham: Springer, 2026.

TINTO, V. Dropout from higher education: a theoretical synthesis of recent research. **Review of Educational Research**, v. 45, n. 1, p. 89-125, 1975.

UNIVERSIDADE FEDERAL DE LAVRAS (UFLA). **UFLA desenvolve solução com inteligência artificial para prever evasão e retenção de estudantes**. Lavras: UFLA, 2023. Disponível em: https://ufla.br/noticias/institucional/16395-ufla-desenvolve-solucao-com-inteligencia-artificial-para-prever-evasao-e-retencao-de-estudantes. Acesso em: 28 set. 2026.