



UNIVERSIDADE FEDERAL DO MARANHÃO
Curso de Engenharia da Computação

Katarina Ires de Castro Pinheiro

**Monitoramento e Predição do Engajamento
Acadêmico: Um Sistema Baseado em Análise de
Dados Educacionais**

São Luís
2026

Katarina Ires de Castro Pinheiro

Monitoramento e Predição do Engajamento Acadêmico: Um Sistema Baseado em Análise de Dados Educacionais

Trabalho de Contextualização e Integração Curricular II (TCC II) apresentado como requisito parcial para Graduação em Bacharelado em Engenharia da Computação pela Universidade Federal do Maranhão – UFMA

São Luís
2026

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Diretoria Integrada de Bibliotecas/UFMA

Pinheiro, Katarina Ires de Castro.

Monitoramento e Predição do Engajamento Acadêmico: Um Sistema Baseado em Análise de Dados Educacionais / Katarina Ires de Castro Pinheiro. - 2026.

83 f.

Orientador(a): Alana de Araújo Oliveira Meireles Teixeira.

Curso de Engenharia da Computação, Universidade Federal do Maranhão, São Luís, 2026.

1. Engajamento Acadêmico. 2. Evasão Universitária. 3. Learning Analytics. 4. Monitoramento Educacional. 5. Classificação de Risco. I. Teixeira, Alana de Araújo Oliveira Meireles. II. Título.

Katarina Ires de Castro Pinheiro

Monitoramento e Predição do Engajamento Acadêmico: Um Sistema Baseado em Análise de Dados Educacionais

Trabalho de Contextualização e Integração Curricular II (TCC II) apresentado como requisito parcial para Graduação em Bacharelado em Engenharia da Computação pela Universidade Federal do Maranhão – UFMA

Trabalho **aprovado** em São Luís, 23 de janeiro de 2026:

**Profa. Dra. Alana de Araújo Oliveira
Maireles Teixeira**
Orientadora

Prof. Dr. Davi Viana dos Santos
Examinador

Prof. Dr. Mário Maireles Teixeira
Examinador

São Luís
2026

Agradecimentos

Primeiramente, agradeço a Deus e à Nossa Senhora de Nazaré por todas as bênçãos alcançadas até aqui, pela proteção diária, pela força nos momentos de cansaço e pela condução ao longo de toda essa caminhada.

À minha base, à minha família, que é o meu alicerce e a razão de tudo. À minha mãe, Regina, ao meu pai, Collins, e ao meu irmão, Klinger, pelo amor incondicional, pelo apoio em todas as decisões e por nunca medirem esforços para que eu pudesse seguir em frente. Obrigada por dividirem comigo os choros, os medos, as inseguranças e as preocupações com o futuro, acolhendo minhas angústias com amor, paciência e incentivo. Tudo o que sou e tudo o que conquistei devo a cada um de vocês. Estendo também meu sincero agradecimento a toda a minha família, pela torcida e presença constantes.

De forma muito especial, agradeço à concha do mar, que tem sido minha calmaria em meio à intensa conciliação entre formação acadêmica, vida profissional e vida pessoal. Um refúgio silencioso, mais que essencial, que me acolhe, me acalma e me fortalece tanto nos dias de jornadas turbulentas quanto nos dias calmos. Foi um dos achados mais especiais da minha vida, e que desejo levar para sempre.

Aos meus amigos de Belém, que, mesmo com a distância, sempre se mantiveram presentes em cada conquista da minha vida, e aos que conquistei aqui em São Luís, por tornarem essa jornada mais leve, compartilhando momentos de alegria, desafios e aprendizados.

À minha orientadora, Alana Oliveira, meu profundo agradecimento por ter aceitado me orientar e por todo o suporte oferecido ao longo desses meses. Por ter sido também minha professora no primeiro semestre na UFMA, essa trajetória se tornou ainda mais significativa, motivo de grande carinho e admiração.

Aos meus amigos da TIC da empresa, agradeço pela paciência, compreensão e apoio durante o desenvolvimento deste TCC, bem como pela confiança para conciliar minhas atividades profissionais com a produção acadêmica.

Sou profundamente grata à Universidade Federal do Maranhão e a todo o corpo docente, que contribuíram não apenas para minha formação profissional, mas também para meu crescimento pessoal. Aos amigos da UFMA, com quem compartilhei momentos de felicidade, tensão e superação, levo cada lembrança com carinho.

Por fim, desejo que todos nós possamos alcançar aquilo que verdadeiramente almejamos e que jamais nos esqueçamos de ser gratos, todos os dias, pelo dom da vida.

*"Cada fim na história contém
necessariamente um novo começo."*

Hannah Arent, em *"Entre o Passado e o Futuro"*

Resumo

A evasão acadêmica é um desafio relevante no ensino superior, com impactos na qualidade educacional e na eficiência institucional. Nesse contexto, o engajamento acadêmico destaca-se como um fator essencial para a permanência e o desempenho dos estudantes. Este trabalho apresenta a concepção e o desenvolvimento de um protótipo funcional voltado ao monitoramento do engajamento e à classificação de risco acadêmico, fundamentado em princípios de *Learning Analytics* e em uma lógica de classificação baseada em regras, por meio de heurísticas com pesos e limiares. O protótipo disponibiliza interfaces para visualização de indicadores e padrões de comportamento associados ao baixo engajamento, permitindo apoiar o planejamento de intervenções pedagógicas de forma mais direcionada. A metodologia adotada baseia-se em prototipagem de alta fidelidade, incluindo a estruturação de dados, o mapeamento de métricas educacionais e a demonstração visual dos critérios de risco. O desenvolvimento seguiu uma estrutura modular e utilizou dados sintéticos para verificação da viabilidade técnica das funcionalidades e da clareza na apresentação dos indicadores. Os resultados evidenciam o funcionamento do monitoramento e a capacidade do protótipo em sinalizar riscos acadêmicos por meio de alertas simulados, além de consolidar informações em painéis de apoio à decisão. Como contribuição, o trabalho apresenta uma prova de conceito que pode servir de base para instituições de ensino superior interessadas em ferramentas de suporte ao acompanhamento acadêmico e à identificação proativa de estudantes em situação de risco.

Palavras-chave: Engajamento acadêmico. Evasão universitária. *Learning Analytics*. Monitoramento educacional. Classificação de risco.

Abstract

Academic dropout is a significant challenge in higher education, affecting educational quality and institutional efficiency. In this context, academic engagement stands out as a key factor for student retention and performance. This work presents the design and development of a functional prototype aimed at monitoring academic engagement and classifying academic risk, grounded in *Learning Analytics* principles and a rule-based classification logic using heuristics with weights and thresholds. The prototype provides interfaces to visualize indicators and behavior patterns associated with low engagement, supporting more targeted pedagogical interventions. The adopted methodology is based on high-fidelity prototyping, including data structuring, mapping of educational metrics, and a visual demonstration of risk classification criteria. The development followed a modular architecture and used synthetic data to verify the technical feasibility of the proposed functionalities and the clarity of the presented indicators. The results demonstrate the operation of the monitoring features and the prototype's ability to signal academic risks through simulated alerts, while consolidating information into dashboards that support decision-making. As a contribution, this work offers a proof of concept that can serve as a basis for higher education institutions interested in data-driven tools to support academic monitoring and proactively identify students at risk.

Keywords: Academic engagement. University dropout. *Learning Analytics*. Educational monitoring. Risk classification.

Lista de ilustrações

Figura 1 – Diagrama de Casos de Uso	28
Figura 2 – Tela de Login do Sistema	42
Figura 3 – Tela de Cadastro	43
Figura 4 – <i>Dashboard</i> Principal de Engajamento	44
Figura 5 – Sistema de Alertas com Filtros e Status	45
Figura 6 – Interface de Predição por Perfil de Estudantes	46
Figura 7 – Interface de Tipos de Modelos	46
Figura 8 – Análise de Fatores	47
Figura 9 – Recursos de Engajamento: Vídeos recomendados	48
Figura 10 – Recursos de Engajamento: Vídeos recomendados por alunos	48
Figura 11 – Recursos de Engajamento: Fóruns	49
Figura 12 – Recursos de Engajamento: Artigos	49
Figura 13 – Recursos de Engajamento: Quizzes	50
Figura 14 – Sistema de Fórum com Categorias e Interações	51
Figura 15 – Tela de comparação entre turmas e cursos	52
Figura 16 – Monitoramento Pessoal (Perfil Aluno)	53
Figura 17 – <i>Interface</i> do questionário <i>System Usability Scale</i>	54
Figura 18 – Tela de apresentação dos resultados da avaliação SUS com <i>score</i> e interpretação.	55
Figura 19 – UC08 - Sistema de Fórum (Perfil Aluno)	66
Figura 20 – UC09 - Monitoramento Pessoal (Perfil Aluno)	67
Figura 21 – UC10 - Tela de Login	68
Figura 22 – UC11 - Tela de Cadastro	69
Figura 23 – Arquitetura de Coleções do Firestore	70

Lista de tabelas

Tabela 1 – Comparativo entre trabalhos relacionados e a proposta atual	24
Tabela 2 – Lista de Requisitos Funcionais do Sistema	26
Tabela 3 – Lista de Requisitos Não Funcionais	27
Tabela 4 – Classificação de Níveis de Engajamento	35
Tabela 5 – Variáveis de Acesso	37
Tabela 6 – Variáveis de Desempenho	37
Tabela 7 – Variáveis de Interação	38
Tabela 8 – Exemplos de Perfis Gerados para Verificação Funcional do Sistema . .	58
Tabela 9 – Validação Funcional dos Casos de Uso Implementados	70
Tabela 10 – Estratégia de Desnormalização	79
Tabela 11 – Estimativa de Volumetria por Coleção	80
Tabela 12 – Validação dos Resultados Esperados	80

Lista de abreviaturas e siglas

ECP	<i>Engenharia da Computação</i>
UFMA	<i>Universidade Federal do Maranhão</i>
SIA	Sistema de Informação de Acadêmica
LGPD	<i>Lei Geral de Proteção de Dados</i>
EAD	<i>Educação a Distância</i>
TICs	<i>Tecnologias da Informação e Comunicação</i>
AVAs	<i>Ambientes Virtuais de Aprendizagem</i>
IES	<i>Instituições de Ensino Superior</i>
EDM	<i>Mineração de Dados Educacionai</i>
LA	<i>Analítica da Aprendizagem</i>
SPA	<i>Single Page Applications</i>
DOM	<i>Document Object Model</i>
BaaS	<i>Backend-as-a-Service</i>
SUS	<i>Avaliação de Usabilidade</i>
CDN	<i>Redes de Entrega de Conteúdo</i>
LMS	<i>Learning Management Systems</i>
NLP	<i>Natural Language Processing</i>
LTI	<i>Learning Tools Interoperability</i>
UML	<i>Unified Modeling Language</i>

Sumário

1	INTRODUÇÃO	15
1.1	Justificativa	17
1.2	Objetivos	17
1.2.1	Objetivo Geral	17
1.2.2	Objetivos Específicos	18
1.2.3	Organização do Trabalho	18
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	Engajamento Acadêmico e Evasão no Ensino Superior	19
2.2	Learning Analytics e Mineração de Dados Educacionais	20
2.3	Tecnologias para Desenvolvimento de Aplicações Web Modernas	20
2.3.1	Desenvolvimento <i>Front-end</i> com <i>React</i>	21
2.3.2	Tipagem Estática e Robustez com TypeScript	21
2.3.3	Arquitetura Serverless e Banco de Dados com Firebase	21
2.4	Considerações do Capítulo	22
3	TRABALHOS RELACIONADOS	23
3.1	Análise Comparativa	24
4	METODOLOGIA	25
4.1	Definição de Requisitos	25
4.1.1	Requisitos Funcionais (RF)	25
4.1.2	Requisitos Não Funcionais (RNF)	26
4.2	Modelagem do Sistema	27
4.3	Módulo 1: Monitoramento de Engajamento	28
4.4	Módulo 2: Lógica de Classificação de Risco Acadêmico	29
4.4.1	Definição das Métricas e do Cálculo do Score de Risco	29
4.4.2	Etapas da Lógica de Classificação de Risco	30
4.5	Módulo 3: Motor de Alertas	31
5	PROPOSTA	32
5.1	M1: Monitoramento de Engajamento	32
5.1.1	Coleta e Agregação de Dados	33
5.1.2	Normalização das Variáveis Brutas	33
5.1.3	Cálculo do Score de Engajamento	34
5.1.4	Cálculo de Indicadores de Risco	35

5.1.5	Classificação Inicial de Níveis de Engajamento	35
5.1.6	Alimentação dos Outros Módulos	35
5.2	M2: Lógica de Classificação de Risco	36
5.2.1	Entradas do Sistema (<i>Features</i>)	36
5.2.2	Métricas de Acesso	36
5.2.3	Métricas de Desempenho	36
5.2.4	Métricas de Interação	37
5.2.5	Camada de Modelagem e Classificação de Risco	37
5.2.5.1	Indicador Percentual de Risco de Evasão	38
5.2.5.2	Estimativa de Risco de Reprovação	38
5.2.5.3	Classificação de Perfis de Engajamento	38
5.2.5.4	Saídas da Lógica de Classificação de Risco	39
5.3	M3: Motor de Alertas	39
5.3.1	Monitoramento Automatizado	39
5.3.2	Tipos de Alertas	39
5.3.3	Priorização e Contextualização	40
5.3.4	Gerenciamento do Ciclo de Vida	40
5.3.5	Feedback e Aprendizado	40
5.3.6	Fluxo de Integração entre os Módulos	41
5.3.7	Ciclo de Melhoria Contínua	41
6	PROTÓTIPO DO SISTEMA	42
6.1	Sistema de Autenticação e Controle de Acesso	42
6.2	Dashboard de Engajamento e Monitoramento	43
6.3	Sistema de Alertas Contextualizados	44
6.4	Modelagem e Simulação de Risco	45
6.5	Recursos de Engajamento Personalizados	48
6.6	Fórum Colaborativo	50
6.7	Análise Comparativa entre Cursos e Turmas	51
6.8	Dashboard de Monitoramento Pessoal do Estudante	53
6.9	Instrumento de Avaliação de Usabilidade (SUS)	54
6.10	Painel de Resultados da Avaliação de Usabilidade (SUS)	54
7	RESULTADOS E DISCUSSÕES	56
7.1	Arquitetura Implementada e Verificação Tecnológica	56
7.1.1	Implementação da Arquitetura <i>Serverless</i>	56
7.1.2	Implementação do Modelo de Dados <i>NoSQL</i>	57
7.1.3	Dados Sintéticos e Verificação Funcional do Sistema	57
7.1.4	Contribuições Tecnológicas Alcançadas	58
7.1.4.1	Arquitetura de Referência	58

7.1.4.2	Modelo de Dados Escalável	59
7.2	Impactos Práticos e Pedagógicos	59
7.2.1	Detecção Precoce de Risco	59
7.2.2	Intervenção Proativa e Rastreabilidade	59
7.2.3	Personalização da Experiência de Aprendizagem	60
7.2.4	Discussão Crítica e Limitações	60
7.2.4.1	Limitações Identificadas	60
7.2.4.2	Trabalhos Futuros	61
7.3	Resultados dos Casos de Uso Implementados	62
7.3.1	Casos de Uso - Perfil Professor	62
7.3.2	Casos de Uso - Perfil Aluno	65
7.3.3	Casos de Uso - Autenticação e Controle de Acesso	67
7.3.4	Resumo de Cobertura dos Casos de Uso	70
7.4	Visão Geral da Arquitetura de Dados	70
7.4.1	Coleção: <i>Users</i> (Usuários)	71
7.4.2	Coleção: <i>Students</i> (Estudantes)	71
7.4.3	Coleção: <i>AccessLogs</i> (Logs de Acesso)	72
7.4.4	Coleção: <i>WeeklyAccess</i> (Frequência Semanal)	72
7.4.5	Coleção: <i>Assessments</i> (Avaliações)	72
7.4.6	Coleção: <i>Submissions</i> (Entregas)	73
7.4.7	Coleção: <i>AcademicPerformance</i> (Desempenho Acadêmico)	74
7.4.8	Coleção: <i>ForumPosts</i> (Postagens em Fórum)	74
7.4.9	Coleção: <i>MaterialInteractions</i> (Interações com Materiais)	75
7.4.10	Coleção: <i>SocialEngagement</i> (Engajamento Social)	75
7.4.11	Coleção: <i>StudentBehavior</i> (Comportamento Completo)	76
7.4.12	Coleção: <i>Alerts</i> (Alertas)	77
7.4.13	Coleção: <i>AlertConfig</i> (Configuração de Alertas)	77
7.5	Relacionamentos e Consultas Otimizadas	78
7.5.1	Estratégia de Desnormalização	79
7.6	Volumetria Estimada	80
7.7	Validação dos Resultados Esperados	80
8	CONSIDERAÇÕES FINAIS	81
8.1	Limitações do Trabalho	81
8.2	Trabalhos Futuros	82
	REFERÊNCIAS	84

1 Introdução

A expansão do ensino superior no Brasil, fortemente impulsionada pela consolidação da Educação a Distância (EAD), promoveu a democratização do acesso, mas também impôs novos desafios pedagógicos e de gestão. Essa transformação digital redefiniu os paradigmas educacionais, consolidando as Tecnologias da Informação e Comunicação (TICs) não apenas como ferramentas de apoio, mas como a infraestrutura central dos processos de ensino. Segundo Moran (2015), a inserção dessas tecnologias transcende a modernização instrumental, representando uma mudança profunda na forma como o conhecimento é construído e compartilhado.

Nesse ecossistema, os Ambientes Virtuais de Aprendizagem (AVAs) tornaram-se repositórios de um volume sem precedentes de dados, que vão desde cliques e tempos de permanência até interações em fóruns, constituindo o “rastros digital” do estudante. Contudo, o simples acúmulo desse “big data educacional” não garante a qualidade do ensino; o desafio contemporâneo está em analisar esses padrões complexos para transformar dados brutos em indicadores pedagógicos acionáveis.

Entretanto, a simples oferta de cursos online não garante a permanência ou o sucesso do aluno. Baggi e Lopes (2011) destacam que a evasão no ensino superior brasileiro é um fenômeno complexo, influenciado por fatores que vão desde a dificuldade de adaptação à metodologia até a falta de suporte institucional percebido. Diferente do ensino presencial, onde o desinteresse pode ser notado visualmente pelo professor em sala, no EAD o desengajamento é silencioso. Ele se manifesta na ausência de *login*, na falta de interação em fóruns e no atraso sistemático de atividades, comportamentos que muitas vezes passam despercebidos até que seja tarde demais para intervir.

Nesse cenário, o conceito de engajamento acadêmico emerge como um indicador fundamental de qualidade e sucesso. Segundo Kuh (2009), o engajamento não deve ser compreendido apenas como a frequência ou a presença física do aluno, mas sim como a qualidade e a intensidade do esforço que o estudante dedica às atividades educacionais, bem como o nível de sua interação com docentes e pares. A literatura evidencia que estudantes engajados desenvolvem maior senso de pertencimento, apresentam melhor desempenho cognitivo e possuem maiores chances de concluir a graduação (TINTO, 2012).

Nesse contexto, o engajamento acadêmico assume um papel central. Para Franciscatto, Costa e Arruda (2019), o engajamento no contexto brasileiro deve ser entendido como a vinculação ativa do estudante com o curso, envolvendo não apenas a realização de tarefas, mas o sentimento de pertencimento à comunidade acadêmica. A ausência desse vínculo é um preditor forte de evasão. O desafio, portanto, reside em

como utilizar a tecnologia não apenas para entregar conteúdo, mas para monitorar essa vinculação e identificar falhas no processo de aprendizagem em tempo real.

A consequência direta do desengajamento é a evasão universitária, um problema sistêmico que afeta a sustentabilidade das Instituições de Ensino Superior (IES) e gera prejuízos sociais significativos. No contexto brasileiro, fatores como dificuldades financeiras, desmotivação e falta de suporte pedagógico personalizado são catalisadores frequentes para o abandono (FILHO et al., 2007). A abordagem tradicional para combater a evasão tem sido predominantemente reativa, ocorrendo apenas após a consolidação do fracasso acadêmico ou da solicitação de trancamento, momento em que as intervenções institucionais possuem baixa eficácia.

Surge, assim, a oportunidade de aplicação da Mineração de Dados Educacionais (Educational Data Mining) e da Analítica da Aprendizagem (Learning Analytics) no cenário nacional. Conforme apontam Sihman, Barioni e Isotani (2016), essas técnicas permitem transformar dados brutos em inteligência pedagógica. Ao modelar o comportamento dos estudantes brasileiros, é possível criar modelos de análise que alertem gestores e docentes sobre riscos de evasão, permitindo uma atuação proativa e personalizada.

Diante dessa realidade, este trabalho propõe o desenvolvimento de um protótipo funcional para o monitoramento e a predição do engajamento acadêmico utilizando técnicas de análise de dados e lógicas algorítmicas de classificação. O objetivo é demonstrar como a identificação precoce de padrões de comportamento pode auxiliar na permanência estudantil. A solução projetada visa preencher a lacuna entre a disponibilidade de dados e a ação pedagógica, coletando e processando métricas de participação, como acessos, entregas e interações para gerar alertas automáticos destinados a tutores e gestores por meio de uma lógica algorítmica transparente. Mais do que apenas sinalizar o risco, a plataforma busca fomentar a permanência, oferecendo mecanismos de direcionamento que conectam o aluno a atividades acadêmicas relevantes, personalizando a experiência de aprendizagem e mitigando os vetores de evasão.

Contudo, a manutenção de níveis satisfatórios de engajamento apresenta-se como um desafio crítico, exacerbado pelas características inerentes ao ensino a distância, e em alguns casos ao presencial. A autonomia exigida na EAD, embora flexível, pode resultar em isolamento social e acadêmico para estudantes que não possuem estratégias robustas de autorregulação. A ausência da “sala de aula física” elimina os sinais visuais de desinteresse que professores experientes captam intuitivamente no ensino presencial, tornando a identificação de alunos em risco uma tarefa complexa e, muitas vezes, tardia.

1.1 Justificativa

A democratização do acesso ao ensino superior no Brasil, impulsionada fortemente pela expansão da modalidade a distância (EAD), trouxe consigo desafios complexos no que tange à garantia da qualidade e à permanência discente. Embora a flexibilidade da EAD seja um vetor de inclusão, ela frequentemente resulta em um distanciamento físico e temporal que dificulta a percepção de dificuldades de aprendizado por parte dos educadores.

A evasão escolar e o baixo desempenho acadêmico não são apenas estatísticas institucionais, elas representam uma perda de capital humano e recursos sociais. Estudos seminais, como os de Pascarella e Terenzini (2005), indicam que a integração social e acadêmica manifestada pela participação ativa em atividades extracurriculares e interações com o corpo docente é um dos preditores mais fortes do sucesso e da persistência universitária. Contudo, em ambientes virtuais, essa "integração" é mediada por ferramentas digitais, tornando o monitoramento humano tradicional ineficaz diante do volume massivo de dados.

No cenário nacional, Martins e Outros (2017) ressaltam que a crescente oferta de cursos traz a necessidade urgente de novas metodologias de acompanhamento. O atual modelo de gestão acadêmica, muitas vezes reativo, agindo apenas após a reprovação ou o trancamento, mostra-se insuficiente. Há, portanto, uma lacuna tecnológica: as instituições possuem os dados brutos (logs de acesso, notas, frequências), mas carecem de sistemas inteligentes que transformem esses dados em conhecimento estratégico em tempo real.

A justificativa para o desenvolvimento deste sistema reside, assim, na capacidade de aplicar técnicas de Aprendizado de Máquina (*Machine Learning*) e Mineração de Dados Educacionais para transitar de um paradigma corretivo para um paradigma preventivo. Ao identificar padrões sutis que precedem a evasão (como a latência entre o acesso e a entrega de tarefas) por meio de uma lógica algorítmica de classificação de risco a ferramenta proposta permite que a intervenção pedagógica ocorra no momento crítico de decisão do aluno. Além disso, ao recomendar atividades de forma personalizada, o sistema não apenas “vigia” o risco, mas atua como um agente motivador, promovendo um ambiente educacional mais inclusivo, eficiente e conectado às necessidades do estudante moderno.

1.2 Objetivos

1.2.1 Objetivo Geral

Desenvolver e verificar a viabilidade técnica de um protótipo funcional de monitoramento e classificação do engajamento acadêmico, fundamentado em *Learning*

Analytics, capaz de identificar padrões comportamentais de risco e subsidiar intervenções pedagógicas proativas voltadas à prevenção da evasão no ensino superior.

1.2.2 Objetivos Específicos

- Estruturar um módulo de coleta e organização de dados de interação acadêmica, inspirado em métricas de Ambientes Virtuais de Aprendizagem (AVAs), unificando indicadores de frequência, desempenho e interação em fóruns.
- Implementar uma lógica algorítmica baseada em pesos e limiares para classificar perfis de estudantes e estimar indicadores de risco de evasão e reprovação a partir do engajamento.
- Desenvolver um mecanismo de alertas e notificações para professores e tutores, priorizando estudantes classificados em maior risco.
- Projetar *dashboards* analíticos e interativos para visualização dos indicadores monitorados e apoio à tomada de decisão pedagógica.
- Discutir a aplicabilidade do protótipo em modalidades presencial e a distância, considerando o uso de diferentes métricas comportamentais.

1.2.3 Organização do Trabalho

Este trabalho está organizado em seis capítulos. O Capítulo 1 apresenta a introdução, com a contextualização do problema, a justificativa, os objetivos e a metodologia adotada. O Capítulo 2 discute a fundamentação teórica, abordando conceitos de *Learning Analytics*, engajamento acadêmico, evasão e indicadores educacionais aplicados ao contexto do ensino superior. O Capítulo 3 apresenta os Trabalhos Relacionados, situando a proposta deste TCC no estado da arte e comparando abordagens existentes voltadas à predição de risco acadêmico e visualização de métricas educacionais. O Capítulo 4 descreve a proposta do sistema, detalhando os módulos de monitoramento do engajamento, classificação de risco e motor de alertas, bem como os critérios utilizados para cálculo dos indicadores. O Capítulo 5 apresenta a implementação do protótipo e os resultados obtidos por meio de verificação funcional com dados sintéticos, incluindo as principais funcionalidades desenvolvidas. Por fim, o Capítulo 6 traz as considerações finais, destacando as contribuições do trabalho, suas limitações e possibilidades de continuidade, como a aplicação futura da avaliação de usabilidade por meio do questionário SUS em um cenário real de uso.

2 Fundamentação Teórica

O desenvolvimento de um sistema computacional para o monitoramento do engajamento acadêmico exige a compreensão de conceitos multidisciplinares. Este capítulo apresenta a fundamentação teórica que sustenta a pesquisa, dividida em três eixos principais: a compreensão pedagógica e sociológica do engajamento e da evasão no ensino superior; o papel da análise de dados educacionais como ferramenta de gestão; e, por fim, as tecnologias de desenvolvimento de software modernas adotadas para a implementação da solução proposta.

2.1 Engajamento Acadêmico e Evasão no Ensino Superior

A permanência estudantil no ensino superior é um fenômeno complexo e multifacetado. A literatura educacional consolidou o entendimento de que a decisão de um aluno de evadir não é um evento isolado, mas o resultado de um processo cumulativo de desvinculação.

Segundo Tinto (1993), em sua Teoria da Integração Estudantil, a evasão ocorre quando o estudante falha em se integrar aos sistemas social e acadêmico da instituição. Tinto argumenta que fatores prévios (*background* familiar, habilidades individuais) influenciam os objetivos iniciais do aluno, mas é a qualidade das interações institucionais com pares e docentes que determina a persistência. No contexto da Educação a Distância (EAD), essa integração torna-se desafiadora devido à separação física, exigindo que o ambiente virtual supra a necessidade de pertencimento.

O conceito de engajamento acadêmico, por sua vez, atua como o contraponto positivo à evasão. Kuh (2008) definem o engajamento como a intersecção entre o tempo e esforço que os estudantes dedicam às atividades educacionais e a forma como a instituição aloca recursos e organiza oportunidades de aprendizagem. Estudantes engajados não apenas frequentam as aulas, mas participam ativamente, colaboram com colegas e interagem com professores.

Fredricks, Blumenfeld e Paris (2004) propõem uma visão multidimensional do engajamento, categorizando-o em três tipos:

1. **Comportamental:** Relacionado à participação em atividades, cumprimento de prazos e conduta acadêmica;
2. **Emocional:** Envolve as reações afetivas (interesse, tédio, ansiedade) e o senso de pertencimento à instituição;

3. **Cognitivo:** Refere-se ao investimento psicológico na aprendizagem, envolvendo autorregulação e estratégias de estudo profundas.

Monitorar essas dimensões em ambientes virtuais é essencial, pois, conforme destacam Filho et al. (2007), a ausência de suporte pedagógico perceptível e a desmotivação são catalisadores frequentes para o abandono no cenário brasileiro.

2.2 Learning Analytics e Mineração de Dados Educacionais

Com a massificação do uso de Ambientes Virtuais de Aprendizagem (AVAs), surgiu a oportunidade de analisar os rastros digitais deixados pelos alunos para compreender e prever comportamentos. Duas áreas de pesquisa destacam-se nesse cenário: a Mineração de Dados Educacionais (*Educational Data Mining - EDM*) e a Analítica da Aprendizagem (*Learning Analytics - LA*).

De acordo com Siemens (2013), *Learning Analytics* é a medição, coleta, análise e relatório de dados sobre aprendizes e seus contextos, com o objetivo de entender e otimizar a aprendizagem e os ambientes em que ela ocorre. Enquanto a EDM foca na descoberta automatizada de padrões por meio de algoritmos, a LA tende a focar na intervenção humana e na tomada de decisão pedagógica informada por dados.

Baker e Yacef (2009) ressaltam que modelos preditivos em educação podem identificar alunos em risco (*at-risk students*) com semanas de antecedência em relação ao fracasso acadêmico real. Métricas como frequência de *login*, tempo de permanência em materiais de leitura e, crucialmente, a latência entre a proposta de uma atividade e sua entrega, são preditores fortes de desempenho final.

No entanto, para que esses dados se transformem em ações efetivas, é necessário transpor o fosso entre a análise estatística e a *interface* do usuário final (professor/tutor). Verbert et al. (2013) propõem que sistemas de LA eficazes devem fechar o ciclo de *feedback*: coletar dados, analisar, visualizar e, finalmente, recomendar ações.

2.3 Tecnologias para Desenvolvimento de Aplicações Web Modernas

Para atender aos requisitos de interatividade, escalabilidade e tempo real demandados por um sistema de monitoramento de engajamento, a arquitetura de *software* deve ser robusta. A seguir, detalham-se as tecnologias selecionadas para o desenvolvimento deste trabalho: *React*, *TypeScript* e *Firebase*.

2.3.1 Desenvolvimento *Front-end* com *React*

O desenvolvimento de *interfaces* de usuário ricas e responsivas evoluiu do modelo tradicional de renderização no servidor para as *Single Page Applications* (SPA). Nesse contexto, o *React*, uma biblioteca *JavaScript* desenvolvida e mantida pelo *Facebook* (Meta), estabeleceu-se como um padrão da indústria para a construção de *interfaces* declarativas.

Segundo Banks e Porcello (2017), o principal diferencial do *React* é o conceito de *Virtual DOM* (*Document Object Model*). Em vez de manipular diretamente o DOM do navegador uma operação custosa em termos de desempenho, o *React* cria uma representação leve da *interface* em memória. Quando o estado da aplicação muda, a biblioteca compara a nova versão com a anterior e atualiza apenas os componentes que efetivamente sofreram alteração. Isso é crucial para *dashboards* analíticos que precisam exibir grandes volumes de dados sem travar a *interface* do usuário.

Além disso, a arquitetura baseada em componentes do *React* permite o encapsulamento de lógica e visualização, promovendo a reutilização de código e facilitando a manutenção de sistemas complexos (WILLIAMS, 2019).

2.3.2 Tipagem Estática e Robustez com *TypeScript*

O *JavaScript*, embora onipresente na *web*, é uma linguagem de tipagem dinâmica e fraca, o que pode levar a erros em tempo de execução difíceis de rastrear em grandes aplicações. Para mitigar esses riscos, optou-se pelo uso do *TypeScript*.

Desenvolvido pela *Microsoft*, o *TypeScript* é um superconjunto estrito do *JavaScript* que adiciona tipagem estática opcional à linguagem. Conforme explica Cherny (2019), o *TypeScript* permite que erros de tipo (como tentar realizar uma operação matemática em uma *string* ou acessar uma propriedade inexistente em um objeto) sejam detectados em tempo de compilação, antes mesmo de o código ser executado.

Em um sistema que lida com estruturas de dados complexas provenientes de análises educacionais (objetos de estudantes, *arrays* de notas, históricos de interação), a tipagem estática do *TypeScript* funciona como uma documentação viva do código. Isso facilita o trabalho em equipe e a refatoração segura, garantindo que o fluxo de dados entre o *front-end* e o *back-end* permaneça consistente (BIERMAN; ABADI; TORGERSEN, 2014).

2.3.3 Arquitetura Serverless e Banco de Dados com *Firebase*

Para o *back-end* da aplicação, adotou-se o *Firebase*, uma plataforma de desenvolvimento de aplicações da *Google* que segue o modelo de *Backend-as-a-Service* (BaaS). O uso do *Firebase* elimina a necessidade de gerenciar servidores físicos ou contêineres, permitindo que o foco do desenvolvimento recaia sobre a lógica de negócio

e a experiência do usuário. A arquitetura do protótipo baseia-se em três componentes fundamentais do ecossistema:

1. **Cloud Firestore:** Um banco de dados *NoSQL* flexível e escalável, que armazena dados em documentos e coleções. Segundo Moroney (2017), uma das características mais poderosas do *Firestore* é a sincronização em tempo real: ouvintes (*listeners*) conectados ao banco de dados recebem atualizações instantâneas sempre que os dados mudam. Para um sistema de monitoramento de engajamento, essa característica é vital. Ela permite que, assim que um aluno realiza uma interação ou fica inativo por um período crítico, o *dashboard* do tutor seja atualizado instantaneamente, sem a necessidade de recarregar a página.
2. **Cloud Functions:** Atua como a camada de processamento *serverless* do sistema. No protótipo, as funções são disparadas automaticamente em resposta a eventos no banco de dados, executando a lógica de cálculo do *Score* de Engajamento e das probabilidades de risco de forma isolada e segura no lado do servidor.
3. **Firebase Authentication:** Fornece uma infraestrutura robusta para gerenciar a autenticação de usuários (professores e alunos), garantindo que o acesso aos dados sensíveis e aos indicadores de risco seja restrito apenas a pessoas autorizadas.

2.4 Considerações do Capítulo

A intersecção entre a teoria pedagógica do engajamento estudantil e as modernas tecnologias de desenvolvimento *web* fornece a base sólida necessária para a proposta deste trabalho. Enquanto autores como Tinto e Kuh oferecem o “porquê” monitorar, e a área de *Learning Analytics* oferece o “o que” monitorar, tecnologias como *React* e *Firebase* fornecem o “como” construir ferramentas eficazes para essa tarefa. O próximo capítulo detalhará a metodologia utilizada para a construção da lógica de classificação de risco e o desenvolvimento do protótipo funcional.

3 Trabalhos Relacionados

A aplicação de técnicas computacionais para apoiar processos educacionais tem sido amplamente investigada, especialmente em temas como predição de desempenho, identificação de risco acadêmico e evasão. Este capítulo busca situar a proposta deste trabalho no contexto da Mineração de Dados Educacionais (*Educational Data Mining - EDM*) e do *Learning Analytics*, destacando abordagens similares e evidenciando diferenças em relação ao protótipo desenvolvido.

No contexto brasileiro, Silva João e Santos (2018) desenvolveram um estudo comparativo utilizando algoritmos de classificação, como Árvores de Decisão e *Support Vector Machines* (SVM), para prever a evasão em cursos de graduação a distância. Os autores utilizaram dados históricos, incluindo registros de acesso e desempenho acadêmico. Embora o modelo tenha apresentado resultados expressivos, o estudo concentra-se em uma análise retrospectiva, realizada a partir de dados consolidados após o término do período letivo. Diferentemente dessa abordagem, o presente trabalho propõe um acompanhamento contínuo do engajamento por meio de um protótipo funcional, visando subsidiar intervenções durante o semestre, e não apenas fornecer um diagnóstico posterior.

No campo da visualização de dados, Macedo Pedro e Souza (2020) apresentaram uma ferramenta de *Learning Analytics* voltada à apresentação de métricas de engajamento para tutores em cursos EAD. O estudo enfatiza a importância de *dashboards* intuitivos para apoiar educadores na interpretação de indicadores. No entanto, a solução proposta pelos autores limita-se principalmente a estatísticas descritivas, relacionadas ao comportamento observado. Em contraste, este trabalho incorpora, além da visualização, uma lógica de classificação de risco baseada em pesos e limiares, com o objetivo de apoiar ações de acompanhamento pedagógico.

Sob a perspectiva da interação social, Costa Lucas e Oliveira (2019) investigaram a relação entre a participação em fóruns de discussão e o sucesso acadêmico por meio de Análise de Redes Sociais (ARS). Os resultados indicam que alunos com maior participação e centralidade na rede tendem a apresentar menor risco de evasão. Contudo, os autores destacam desafios relacionados à complexidade do processamento e automação de análises em tempo de execução. Considerando esse cenário, o sistema proposto neste trabalho busca incorporar métricas quantitativas simples de interação, como participação em fóruns, para contribuir com a identificação de padrões de isolamento acadêmico.

Por fim, Alves e Outros (2021) realizaram uma revisão sistemática sobre evasão no ensino superior público brasileiro. Os autores apontam que, apesar da existência de diversos modelos preditivos, uma parcela reduzida dos estudos se integra a sistemas acadêmicos

capazes de apoiar ações práticas de acompanhamento pedagógico. Frequentemente, os trabalhos encerram-se na etapa de classificação do estudante, sem indicar mecanismos de suporte à intervenção.

3.1 Análise Comparativa

A Tabela 1 resume características dos trabalhos discutidos e posiciona a proposta deste TCC em relação a essas soluções. Observa-se que parte da literatura concentra-se isoladamente na predição ou na visualização de indicadores. Em comparação, este trabalho busca integrar monitoramento do engajamento, classificação de risco e emissão de alertas em um protótipo funcional, com foco no suporte ao acompanhamento pedagógico.

Tabela 1 – Comparativo entre trabalhos relacionados e a proposta atual

Trabalho	Predição	Visualização	Monitoramento Contínuo	Intervenção/Alertas
Silva João e Santos (2018)	Sim	Não	Não	Não
Macedo Pedro e Souza (2020)	Não	Sim	Sim	Não
Costa Lucas e Oliveira (2019)	Não	Sim	Não	Não
Proposta deste TCC	Sim	Sim	Sim	Sim

4 Metodologia

Cada módulo do sistema seguiu uma metodologia específica adaptada às suas necessidades, desde a definição inicial até a implementação. Nas seções a seguir, são apresentadas a metodologia adotada para cada módulo.

4.1 Definição de Requisitos

Para a elucidação dos requisitos, adotou-se como referência a norma ISO/IEC 25010, que estabelece modelos de qualidade de produto de software. Os requisitos foram levantados considerando dois perfis de atores principais:

1. **Tutor/Professor:** Acompanha o desempenho dos alunos, turmas e recebe alertas.
2. **Aluno:** Acompanha fóruns, quiz e área de recomendações de artigos e vídeos, além de (Futura implementação) receber feedbacks automáticos sobre seu próprio engajamento.

4.1.1 Requisitos Funcionais (RF)

Os Requisitos Funcionais descrevem os comportamentos e funções específicas que o sistema deve prover. A Tabela 2 apresenta a lista priorizada de funcionalidades.

Tabela 2 – Lista de Requisitos Funcionais do Sistema

ID	Descrição	Prioridade
RF01	Autenticação de Usuários: O sistema deve permitir o login seguro de alunos e professores, diferenciando os níveis de acesso.	Alta
RF02	Importação de Dados: O sistema deve ser capaz de receber dados (logs) de atividades, notas e frequência via upload ou integração de API.	Alta
RF03	Dashboard de Visão Geral: O sistema deve exibir gráficos sumarizados contendo a quantidade de alunos ativos, em risco e evadidos.	Alta
RF04	Monitoramento Individual: O sistema deve apresentar uma ficha detalhada do aluno, contendo histórico de notas e curva de frequência de acesso.	Alta
RF05	Motor de Alertas: O sistema deve identificar automaticamente alunos que atendam aos critérios de risco (ex: 7 dias sem acesso) e notificar o tutor.	Alta
RF06	Recomendação de Atividades: O sistema deve sugerir conteúdos de reforço baseados nas últimas notas negativas do aluno.	Média
RF07	Gerenciamento de Turmas: O sistema deve permitir a filtragem de dados por turma, semestre ou disciplina.	Baixa

Fonte: Autoria própria (2025).

4.1.2 Requisitos Não Funcionais (RNF)

Os Requisitos Não Funcionais definem os atributos de qualidade, restrições e premissas técnicas do projeto. A Tabela 3 detalha as restrições impostas pela escolha das tecnologias React e Firebase.

Tabela 3 – Lista de Requisitos Não Funcionais

ID	Descrição	Categoria
RNF01	Tempo de Resposta: O carregamento dos dashboards não deve exceder 3 segundos, utilizando a renderização otimizada do React.	Desempenho
RNF02	Atualização em Tempo Real: As alterações no status do aluno devem refletir na interface do tutor em menos de 1 segundo (via <i>listeners</i> do Firebase).	Confiabilidade
RNF03	Segurança de Dados: O acesso ao banco de dados deve ser protegido por regras de segurança (<i>Security Rules</i>) do Firestore, garantindo que usuários acessem apenas dados de sua instituição.	Segurança
RNF04	Disponibilidade: O sistema deve operar em arquitetura <i>Serverless</i> , garantindo <i>uptime</i> de 99,9% provido pela infraestrutura da Google Cloud.	Disponibilidade
RNF05	Portabilidade: A interface deve ser responsiva, adaptando-se a telas de desktops e tablets, utilizando CSS moderno como o MaterialUI.	Usabilidade
RNF06	Integridade de Tipos: Todo o código fonte deve ser desenvolvido em TypeScript para prevenir erros de tipagem em tempo de execução.	Manutenibilidade

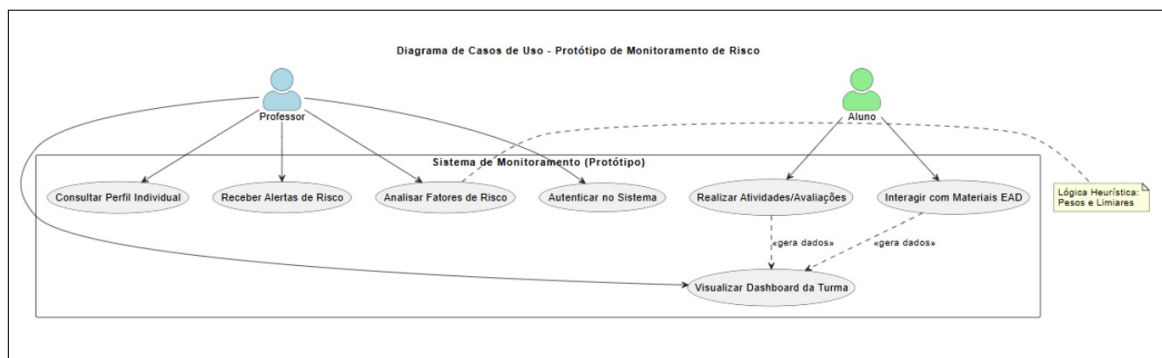
Fonte: Autoria própria (2025).

4.2 Modelagem do Sistema

A modelagem do sistema foi realizada por meio da técnica de diagramas de casos de uso, conforme proposto pela *Unified Modeling Language* (UML), com o objetivo de representar, de forma clara e estruturada, as principais funcionalidades do protótipo e as interações entre os usuários e o sistema. Essa abordagem permite compreender o comportamento do sistema a partir da perspectiva dos atores envolvidos, facilitando a validação dos requisitos funcionais definidos anteriormente.

No contexto deste trabalho, o diagrama de casos de uso descreve as ações disponíveis para os perfis Professor e Aluno, bem como os fluxos de geração e consumo de dados relacionados ao monitoramento do engajamento acadêmico e à classificação de risco.

Figura 1 – Diagrama de Casos de Uso



Fonte: Autoria própria (2025).

O sistema modelado possui dois atores principais: Professor e Aluno. O Aluno interage com o sistema por meio da realização de atividades e avaliações, bem como pela interação com os materiais disponibilizados no protótipo. Essas ações geram dados relacionados ao engajamento acadêmico, como frequência de acesso, participação e desempenho, que são utilizados pelo sistema no processo de monitoramento.

O Professor utiliza o sistema com foco no acompanhamento acadêmico e na análise dos dados gerados. Entre as funcionalidades associadas a esse ator destacam-se a consulta ao perfil individual do aluno, a visualização do *dashboard* da turma, a análise dos fatores de risco e o recebimento de alertas de risco, que auxiliam na identificação de possíveis situações de evasão ou baixo desempenho.

Ambos os atores realizam a autenticação no sistema, garantindo o controle de acesso às funcionalidades de acordo com o perfil do usuário. Os dados gerados pelas interações dos alunos alimentam a lógica heurística de classificação de risco, baseada em pesos e limiares previamente definidos. Essa lógica é responsável pelo processamento das informações e pela geração dos indicadores apresentados nos *dashboards* e utilizados pelo sistema de alertas.

4.3 Módulo 1: Monitoramento de Engajamento

O módulo de monitoramento seguiu uma metodologia baseada em **coleta, processamento e armazenamento de dados internos**. As etapas principais adotadas foram:

1. **Definição de Variáveis:** Identificação das variáveis de interesse organizadas em três dimensões (acesso, desempenho, interação), baseadas em revisão bibliográfica e análise de necessidades.

2. **Estruturação do Sistema:** Desenvolvimento de funcionalidades internas (atividades, fóruns, materiais, *logs*) que permitem a coleta automática de dados durante o uso normal da plataforma pelos estudantes.
3. **Coleta Automática:** Implementação de mecanismos de rastreamento que registram automaticamente todas as ações dos estudantes, gerando dados internos do próprio sistema.
4. **Tratamento e Agregação:** Limpeza, normalização e agregação temporal dos dados coletados, com cálculo de métricas derivadas.
5. **Análises Descritivas:** Realização de análises exploratórias, distribuição, correlação e definição de *thresholds* para classificação.
6. **Armazenamento:** Estruturação e implementação de armazenamento otimizado com estratégias de *backup* e recuperação.

Característica principal: Todos os dados são **internos ao sistema**, coletados por meio de funcionalidades desenvolvidas especificamente para este fim (atividades acadêmicas, fóruns de discussão, materiais didáticos e *logs* de acesso).

4.4 Módulo 2: Lógica de Classificação de Risco Acadêmico

O módulo de modelagem no protótipo seguiu uma metodologia baseada na definição de uma lógica algorítmica de pesos e limiares, visando demonstrar como o risco seria calculado. As etapas adotadas foram:

4.4.1 Definição das Métricas e do Cálculo do Score de Risco

O cálculo do score de risco adotado neste trabalho baseia-se em uma lógica heurística, desenvolvida pela autora com o objetivo de possibilitar uma avaliação simples, interpretável e de fácil implementação do engajamento acadêmico dos alunos em ambientes virtuais de aprendizagem.

As métricas consideradas no cálculo do score, tais como frequência de acesso, participação em atividades, desempenho em avaliações e nível de interação com os materiais, foram definidas a partir de conceitos amplamente discutidos na literatura, especialmente em estudos relacionados à evasão, engajamento acadêmico e *Learning Analytics*.

Entretanto, os pesos atribuídos a cada métrica e os limiares utilizados para a classificação dos níveis de risco não foram extraídos diretamente de trabalhos específicos, mas definidos de forma empírica, com base na análise do impacto relativo de cada fator no contexto educacional e na proposta do sistema.

Essa abordagem permite maior flexibilidade e interpretabilidade do modelo, uma vez que os parâmetros podem ser ajustados conforme o perfil do curso, da instituição ou do público-alvo. Além disso, optou-se por uma lógica heurística em detrimento de técnicas de mineração de dados ou aprendizado de máquina, visando facilitar a compreensão dos critérios de classificação pelos docentes e gestores educacionais.

Ressalta-se que o objetivo do trabalho não é a obtenção de um modelo preditivo otimizado, mas a proposição de um protótipo funcional que demonstre a viabilidade do monitoramento de risco acadêmico a partir de indicadores de engajamento, podendo ser estendido e calibrado em trabalhos futuros com dados reais.

4.4.2 Etapas da Lógica de Classificação de Risco

1. **Definição de Features:** Seleção das 16 variáveis mais relevantes do módulo de monitoramento, abrangendo as dimensões de acesso, desempenho e interação, estruturadas para permitir a simulação da classificação de risco no protótipo (ex: média geral, frequência semanal, engajamento social e percentual de entregas).
2. **Preparação e Estruturação dos Dados:** Organização dos dados sintéticos gerados para o protótipo, incluindo a normalização das métricas para a escala 0-100 (permitindo o cálculo do *score* ponderado) e a estruturação dos perfis de estudantes para representar diferentes cenários de engajamento.
3. **Definição da Lógica de Cálculo:** Optou-se pela definição de um modelo heurístico transparente, baseado em uma fórmula ponderada. Foram definidos pesos específicos para cada dimensão (ex: Notas (30%), Frequência (25%), Interação Social (20%), Entregas (15%) e Participação em Fóruns (10%).), permitindo que o protótipo calcule o *score* de risco de forma clara e explicável para o usuário final.
4. **Definição de Liminares (*Thresholds*):** Definição de faixas de valores para a classificação automática do nível de risco. O sistema foi configurado para categorizar os estudantes em quatro níveis: Crítico ($Score < 40$), Alto (40-55), Médio (55-70) e Baixo ($Score > 70$).
5. **Simulação de Classificação de Risco:** Desenvolvimento de uma *interface* funcional que aplica a lógica de cálculo sobre os dados sintéticos de validação, demonstrando visualmente como o risco de evasão e reprovação seria apresentado ao usuário final.
6. **Validação de Conceito:** Verificação se a lógica proposta reflete corretamente os comportamentos simulados no protótipo.

Característica principal: Utilização de uma lógica algorítmica de pesos e limiares (heurística) para demonstrar a viabilidade da classificação de risco acadêmico. O foco deste

módulo no protótipo é a validação técnica da *interface* e do fluxo de dados, apresentando como os indicadores de risco seriam visualizados a partir de uma lógica predefinida, preparando o caminho para futuras implementações de inteligência artificial real.

4.5 Módulo 3: Motor de Alertas

O módulo de alertas seguiu uma metodologia baseada em **detecção automática e gerenciamento de ciclo de vida**. As etapas principais adotadas foram:

1. **Definição de Regras:** Especificação da lógica de detecção baseada nos limiares de risco definidos no Módulo 2, estabelecendo critérios para quatro tipos de alertas: ausência prolongada, queda de desempenho, baixo engajamento e risco de evasão.
2. **Implementação da Lógica:** Desenvolvimento de algoritmos que integram os dados de monitoramento com os resultados da lógica preditiva para gerar alertas visuais na *interface* do protótipo.
3. **Sistema de Priorização:** Definição de níveis de prioridade (crítico, alto, médio, baixo), com destaque visual diferenciado (cores e ícones) para facilitar a identificação dos casos mais urgentes pelos educadores.
4. **Gerenciamento do Ciclo de Vida:** Definição de estados (pendente, em análise, tratado, ignorado), permitindo demonstrar como um professor interagiria com as notificações e acompanharia o histórico de intervenções.
5. **Verificação da Interface:** Planejamento e testes de *interface* para garantir que os alertas sejam visualmente claros, acionáveis e apresentados de forma contextualizada dentro do fluxo de uso do protótipo.
6. **Integração de Módulos:** Conexão funcional entre o banco de dados (Módulo 1), a lógica de cálculo (Módulo 2) e a *interface* de saída (Módulo 3), garantindo a coerência das informações apresentadas.

Característica principal: Sistema proativo que demonstra a geração de alertas contextualizados a partir da análise dos dados de engajamento, demonstrando a viabilidade técnica da comunicação de risco e a *interface* de suporte à decisão para o usuário final.

5 Proposta

O sistema de monitoramento de engajamento e classificação de comportamento proposto é composto por três módulos principais que trabalham de forma integrada e complementar. Cada módulo possui responsabilidades específicas, mas são projetados para funcionar em conjunto, criando um ciclo contínuo de coleta, análise e ação que permite identificar e apoiar estudantes em risco de forma proativa dentro de um ambiente de prototipagem..

O primeiro módulo, o **Módulo de Monitoramento de Engajamento**, atua como ponto de entrada do sistema, coletando dados de múltiplas fontes sobre o comportamento estudantil e processando essas informações para gerar *scores* de engajamento e classificações iniciais de risco. Este módulo organiza e prepara os dados que serão utilizados pelos demais módulos, estabelecendo a base sobre a qual todo o protótipo opera.

O segundo módulo, o **Módulo de Lógica de Classificação de Risco**, recebe os dados organizados pelo módulo de monitoramento e aplica uma lógica algorítmica de pesos e limiares para identificar padrões e gerar indicadores sobre riscos de evasão e reprovação. Este módulo adiciona uma camada de inteligência ao protótipo, permitindo demonstrar como a análise de dados pode auxiliar na antecipação de problemas antes que se tornem críticos.

O terceiro módulo, o **Motor de Alertas**, monitora continuamente tanto os dados do módulo de monitoramento quanto as análises do módulo de classificação, identificando situações que requerem atenção imediata dos educadores e gerando alertas contextualizados e priorizados. Este módulo transforma as informações coletadas e analisadas em ações práticas e acionáveis.

A integração entre os módulos acontece de forma fluida e automática dentro da arquitetura do protótipo, onde cada módulo não apenas cumpre sua função específica, mas também alimenta e é alimentado pelos outros módulos, criando uma visão holística e em tempo real do engajamento estudantil validada por meio de dados sintéticos.

5.1 M1: Monitoramento de Engajamento

O primeiro módulo, de **Monitoramento de Engajamento**, é o ponto de entrada do sistema. Além de coletar e agregar dados de múltiplas fontes sobre o comportamento dos estudantes, este módulo desempenha um papel fundamental na organização e preparação das informações que serão utilizadas pelos demais módulos.

5.1.1 Coleta e Agregação de Dados

A **coleta de dados** corresponde à etapa em que os registros brutos são capturados a partir das fontes disponíveis no sistema. Esses dados são gerados como resultado direto das interações dos usuários com a plataforma e dos eventos operacionais registrados automaticamente.

Assim, o módulo de monitoramento atua como um coletor centralizado de informações, reunindo dados de três dimensões principais do comportamento estudantil:

- **Dados de Acesso:** Informações sobre quando e com que frequência os estudantes acessam a plataforma, quanto tempo permanecem conectados e quando foi seu último acesso.
- **Dados de Desempenho:** Métricas relacionadas ao sucesso acadêmico, incluindo notas obtidas, percentual de tarefas entregues, tempo de resposta nas entregas e tendência de melhoria ou declínio nas avaliações.
- **Dados de Interação:** Indicadores de participação ativa, como número de postagens em fóruns, interações com materiais didáticos, tempo dedicado ao estudo de conteúdos e nível de engajamento social.

A **agregação de dados** consiste na transformação dos registros brutos coletados em métricas consolidadas, adequadas para análise e visualização. Nessa etapa, os dados são organizados segundo janelas temporais definidas, como dias, semanas ou períodos específicos de análise.

Durante a agregação, são aplicadas operações estatísticas simples, como contagem, soma, média e cálculo de frequências. Por exemplo, múltiplos registros de acesso são combinados para obter métricas como número total de acessos no período, tempo médio de permanência, dias ativos e data do último acesso. No protótipo, essa agregação é validada por meio do uso de dados sintéticos que emulam o comportamento real de uma turma.

5.1.2 Normalização das Variáveis Brutas

Para garantir a integridade estatística do cálculo, o sistema realiza a padronização das métricas brutas para uma escala centesimal (0 a 100) antes da aplicação da fórmula ponderada. Este processo de normalização é fundamental para permitir a comparação equitativa entre variáveis de diferentes naturezas e domínios. As regras de negócio implementadas no protótipo para essa conversão são:

- F_{norm} : O sistema assume um máximo de 20 acessos semanais para atingir 100%. A fórmula aplicada é: $(frequenciaSemanal / 20) \times 100$

- N_{norm} : Converte a média geral (escala 0-10) para a escala centesimal: $(\text{mediaGeral} / 10) \times 100$
- P_{norm} : Baseia-se no total de postagens, assumindo um teto de 50 interações para a pontuação máxima: Mínimo de $((\text{totalPostagens} / 50) \times 100, 100)$
- I_{norm} e E_{norm} : Estas variáveis são capturadas nativamente em percentual (0-100%)

5.1.3 Cálculo do Score de Engajamento

Além de simplesmente coletar dados, o módulo de monitoramento processa essas informações para gerar um **score de engajamento** unificado para cada estudante. Este *score* é calculado através da combinação ponderada das diferentes métricas, atribuindo maior importância a aspectos críticos como desempenho acadêmico e frequência de acesso, enquanto considera também fatores como participação e interação social.

O *score* de engajamento serve como uma métrica consolidada que resume o estado geral do estudante em um único valor, facilitando comparações, identificação de padrões e tomada de decisões. Este valor é atualizado continuamente conforme novos dados são coletados, refletindo mudanças no comportamento do estudante ao longo do tempo.

O *score* de engajamento é calculado através de uma fórmula ponderada que integra múltiplas dimensões do comportamento estudantil. A fórmula é definida como:

$$Score_{\text{Engajamento}} = w_1 \times F_{\text{norm}} + w_2 \times N_{\text{norm}} + w_3 \times I_{\text{norm}} + w_4 \times E_{\text{norm}} + w_5 \times P_{\text{norm}} \quad (5.1)$$

onde:

- F_{norm} é a frequência de acesso normalizada (0-100%)
- N_{norm} são as notas normalizadas (0-100%)
- I_{norm} é a interação social normalizada (0-100%)
- E_{norm} é o percentual de entregas (0-100%)
- P_{norm} é a participação em fóruns normalizada (0-100%)

Os pesos padrão utilizados são:

$$w_1 = 0.25 \quad (\text{Frequência}) \quad (5.2)$$

$$w_2 = 0.30 \quad (\text{Notas}) \quad (5.3)$$

$$w_3 = 0.20 \quad (\text{Interação}) \quad (5.4)$$

$$w_4 = 0.15 \quad (\text{Entregas}) \quad (5.5)$$

$$w_5 = 0.10 \quad (\text{Participação}) \quad (5.6)$$

5.1.4 Cálculo de Indicadores de Risco

Além do *Score* de Engajamento, o protótipo implementa uma camada de lógica de classificação de risco baseada em inferência lógica, que traduz o nível de participação em indicadores percentuais de eventos críticos. Esta abordagem permite uma interpretação mais direta do risco por parte dos gestores. Os dois indicadores principais são:

- **Indicador Percentual de Evasão (P_{evasao}):** Utiliza uma função linear inversa para mapear o risco de abandono. A fórmula aplica um fator de sensibilidade de 0.9 sobre o *score*, garantindo uma margem de incerteza realista entre 5% e 95%. O cálculo é definido por: $P_{evasao} = 95 - (Score \times 0.9)$.
- **Indicador Percentual de Reprovação ($P_{reprovacao}$):** Este indicador combina o engajamento holístico com o desempenho acadêmico específico (notas normalizadas). A fórmula utiliza uma composição ponderada, atribuindo 70% de peso ao *deficit* de engajamento e 30% ao *deficit* de notas, permitindo identificar alunos que, apesar de notas satisfatórias, apresentam comportamentos de risco que podem levar à reprovação por falta ou desinteresse. O cálculo é definido por: $P_{reprovacao} = (0.7 \times (100 - Score)) + (0.3 \times (100 - Nnorm))$.

5.1.5 Classificação Inicial de Níveis de Engajamento

Com base no *score* calculado, o módulo de monitoramento realiza uma **classificação inicial** dos estudantes em quatro níveis de risco: CRÍTICO, ALTO, MÉDIO e BAIXO. Esta classificação fornece uma primeira camada de identificação de estudantes que podem precisar de atenção, servindo como ponto de partida para análises mais profundas.

A Tabela 4 mostra como o *score* de engajamento são classificados nos quatro níveis.

Tabela 4 – Classificação de Níveis de Engajamento

Nível de Engajamento	Faixa	Interpretação
Muito Baixo ou Crítico	0-40%	Requer intervenção urgente
Baixo	40-55%	Requer atenção
Médio	55-70%	Monitoramento recomendado
Alto	70-100%	Satisfatório

5.1.6 Alimentação dos Outros Módulos

O módulo de monitoramento não trabalha isoladamente. Ele prepara e disponibiliza os dados coletados e processados para os outros módulos do sistema. As informações organizadas e o *score* calculado são fornecidos ao módulo de modelagem, que utilizará esses dados para realizar uma classificação detalhada dos níveis de risco e tendências

de comportamento. Simultaneamente, os dados também alimentam o módulo de alertas, que monitora continuamente essas informações para identificar situações que requerem intervenção imediata.

5.2 M2: Lógica de Classificação de Risco

O segundo módulo, de **Lógica de Classificação de Risco**, recebe os dados organizados pelo módulo de monitoramento e aplica uma lógica algorítmica de pesos e limiares para identificar padrões e gerar indicadores sobre o risco de evasão e reprovação dos estudantes.

O sistema de análise é organizado como um fluxo composto por três componentes principais: **i. variáveis de entrada** que descrevem o comportamento do estudante; **ii. lógica algorítmica** responsáveis pela classificação de risco; e, **(iii) saídas interpretáveis** utilizadas para apoio à decisão pedagógica.

Essa separação permite compreender o funcionamento do sistema independentemente da tecnologia de implementação ou dos resultados experimentais obtidos.

5.2.1 Entradas do Sistema (*Features*)

As entradas do sistema correspondem às variáveis que descrevem o comportamento do estudante na plataforma. Essas variáveis são organizadas em três dimensões complementares, totalizando 16 features utilizadas no cálculo da lógica de risco do protótipo.

5.2.2 Métricas de Acesso

As métricas de acesso descrevem o padrão de utilização da plataforma pelo estudante ao longo do tempo, refletindo sua presença e regularidade no ambiente virtual. Elas capturam aspectos como frequência de acessos, duração das sessões, quantidade de dias ativos e recência do último acesso, permitindo identificar níveis de continuidade ou interrupção no uso do sistema. Essas métricas são indicativas do grau de exposição do estudante às atividades e conteúdos disponíveis, funcionando como sinais iniciais de engajamento ou afastamento progressivo. No protótipo, essas métricas são normalizadas para compor 25% do peso total do *Score* de Engajamento.

5.2.3 Métricas de Desempenho

As métricas de desempenho estão relacionadas aos resultados acadêmicos obtidos pelo estudante e ao cumprimento das atividades avaliativas. Elas englobam médias de notas, taxas de entrega, latência nas submissões e tendências de desempenho ao longo

Tabela 5 – Variáveis de Acesso

Variável	Tipo	Descrição
frequenciaSemanal	Numérico	Acessos por semana
mediaDuracaoSessao	Numérico	Duração média (minutos)
totalMinutosPlataforma	Numérico	Total acumulado (minutos)
diasAtivos	Numérico	Dias com acesso
ultimoAcesso	Data	Timestamp do último acesso

do tempo. Essas métricas refletem diretamente o progresso acadêmico e a capacidade do estudante de atender às demandas do curso, sendo fundamentais para a identificação de padrões associados à reprovação e à evolução do aprendizado. No cálculo do protótipo, o desempenho acadêmico possui o maior peso relativo (30%), dada sua alta correlação com o sucesso estudantil.

Tabela 6 – Variáveis de Desempenho

Variável	Tipo	Descrição
mediaGeral	Numérico	Média geral (0-10)
percentualEntregas	Numérico	% de entregas (0-100)
mediaLatenciaEntregas	Numérico	Latência média (horas)
totalAvaliacoess	Numérico	Total de avaliações
avaliacoesEntregues	Numérico	Avaliações entregues
tendenciaNotas	Catégorico	CRESCENTE/ESTAVEL/DECRESCENTE

5.2.4 Métricas de Interação

As métricas de interação representam a forma como o estudante se envolve com os recursos pedagógicos e com outros participantes do ambiente virtual. Elas incluem ações como postagens em fóruns, interações com materiais didáticos, tempo dedicado ao estudo e percentual de conclusão dos conteúdos. Esse conjunto de métricas permite caracterizar o engajamento ativo, indo além da simples presença, e fornece indícios sobre participação, colaboração e envolvimento cognitivo com o processo de aprendizagem. No protótipo, a interação social e a participação em fóruns compõem, juntas, 30% do *Score* de Engajamento.

Essas três dimensões, em conjunto, representam o estado observado do estudante no ambiente virtual de aprendizagem.

5.2.5 Camada de Modelagem e Classificação de Risco

A camada de modelagem é responsável por transformar as variáveis de entrada em estimativas de risco e perfis comportamentais. No protótipo, essa transformação é realizada

Tabela 7 – Variáveis de Interação

Variável	Tipo	Descrição
totalPostagens	Numérico	Postagens em fóruns
totalInteracoesMateriais	Numérico	Interações com materiais
tempoMedioMateriais	Numérico	Tempo médio (minutos)
percentualConclusaoMateriais	Numérico	% de conclusão (0-100)
engajamentoSocial	Numérico	Score social (0-100)

através de uma lógica algorítmica de pesos e limiares, que garante a transparência e a explicabilidade dos resultados pedagógicos.

5.2.5.1 Indicador Percentual de Risco de Evasão

O indicador percentual de risco de evasão é calculado por meio de uma função linear inversa baseada no *Score* de Engajamento. O objetivo é demonstrar o risco de o estudante abandonar o curso conforme seu nível de participação diminui. A lógica aplicada utiliza um fator de sensibilidade para mapear o risco em uma escala percentual, permitindo que o gestor visualize a urgência de intervenção de forma clara e intuitiva.

5.2.5.2 Estimativa de Risco de Reprovação

A estimativa de reprovação foca na identificação de estudantes com baixa probabilidade de aprovação acadêmica. Para essa tarefa, o sistema utiliza uma composição ponderada que combina o *déficit* de engajamento geral (70%) com o *déficit* de desempenho específico em notas (30%). Essa abordagem permite sinalizar alunos que, embora tenham notas razoáveis, apresentam comportamentos de risco que podem comprometer o sucesso final na disciplina.

5.2.5.3 Classificação de Perfis de Engajamento

Além das estimativas de risco, o sistema realiza a classificação dos estudantes em perfis comportamentais em múltiplas classes. Essa tarefa permite identificar padrões gerais de engajamento e desempenho por meio de quatro categorias principais:

- **Perfil Crítico:** Estudantes com engajamento muito baixo e alto risco imediato.
- **Perfil de Atenção (Risco Alto):** Estudantes com sinais claros de desengajamento.
- **Perfil em Observação (Risco Médio):** Estudantes com participação irregular.
- **Perfil Engajado (Risco Baixo):** Estudantes com participação plena e consistente.

Essa classificação é realizada através da aplicação de limiares (*thresholds*) sobre o *Score* de Engajamento, permitindo uma segmentação rápida da turma para ações pedagógicas direcionadas.

5.2.5.4 Saídas da Lógica de Classificação de Risco

As saídas do sistema correspondem às informações produzidas pela lógica de cálculo e disponibilizadas para as *interfaces* de visualização e para o motor de alertas:

- **nivelRisco**: classificação qualitativa do risco (Baixo, Médio, Alto ou Crítico)
- **indicadorEvasao**: indicador percentual de evasão baseado no *score* de engajamento
- **indicadorReprovacao**: indicador percentual de reprovação baseado no equilíbrio entre notas e engajamento
- **fatoresRisco**: identificação das variáveis que mais impactaram o *score* (ex: baixa frequência ou notas insuficientes)
- **ultimaAtualizacao**: data e hora do último processamento realizado pela lógica de cálculo

5.3 M3: Motor de Alertas

O terceiro módulo, o **Motor de Alertas**, atua como o sistema de notificação e ação do conjunto. Ele monitora os dados do módulo de monitoramento e os resultados da camada de modelagem, identificando situações que requerem atenção imediata dos educadores.

5.3.1 Monitoramento Automatizado

O motor de alertas opera de forma automática, verificando se algum estudante apresenta indicadores que justifiquem a geração de um alerta. No protótipo, essa funcionalidade é implementada através de gatilhos (*triggers*) no banco de dados, que disparam a lógica de verificação sempre que novas informações de engajamento são registradas. O sistema não espera por solicitações manuais, mas sim monitora proativamente todas as informações disponíveis para sinalizar riscos o mais rápido possível.

5.3.2 Tipos de Alertas

O motor de alertas é capaz de identificar diferentes tipos de situações problemáticas e gerar alertas específicos para cada uma:

- **Alertas de Ausência Prolongada:** Quando um estudante não acessa a plataforma por um período significativo, o sistema gera um alerta imediato, permitindo que educadores entrem em contato antes que a situação se agrave.
- **Alertas de Queda de Desempenho:** Quando há uma redução significativa nas notas ou uma tendência de declínio acadêmico, o sistema identifica essa situação e alerta os educadores, possibilitando intervenções focadas em suporte acadêmico.
- **Alertas de Baixo Engajamento:** Quando múltiplos indicadores apontam para baixo engajamento geral, o sistema gera alertas que permitem estratégias de reengajamento antes que o estudante se desvincule completamente.
- **Alertas de Risco de Evasão:** Quando as análises da camada de modelagem indicam alto risco de evasão, o motor de alertas gera alertas prioritários que requerem intervenção urgente e personalizada.

5.3.3 Priorização e Contextualização

O motor de alertas não apenas identifica problemas, mas também **prioriza** os alertas com base na severidade e urgência. Alertas críticos são destacados e requerem atenção imediata, enquanto alertas de menor urgência são organizados de forma que educadores possam gerenciá-los eficientemente.

Cada alerta é **contextualizado** com informações relevantes: quais fatores de risco foram identificados, qual a probabilidade estimada de evasão ou reprovação, e quais ações são recomendadas. Isso permite que educadores compreendam não apenas que há um problema, mas também por que o problema foi identificado e o que pode ser feito a respeito.

5.3.4 Gerenciamento do Ciclo de Vida

O motor de alertas gerencia todo o ciclo de vida de cada alerta, desde sua criação até sua resolução. Ele rastreia se um alerta foi visualizado, se está sendo analisado, se ações foram tomadas, ou se foi resolvido. Isso permite que educadores acompanhem o progresso das intervenções e garante que nenhum estudante em risco seja esquecido, validando o fluxo de trabalho pedagógico proposto.

5.3.5 Feedback e Aprendizado

Quando educadores tomam ações baseadas em alertas e essas ações resultam em melhorias no engajamento do estudante, essa informação é capturada pelo sistema de monitoramento. No contexto deste protótipo, esse fluxo demonstra como o *feedback* humano pode ser integrado ao sistema para validar a eficácia dos alertas e servir de base para

futuros refinamentos manuais na lógica de pesos e limiares, garantindo que a ferramenta evolua conforme as necessidades da instituição.

5.3.6 Fluxo de Integração entre os Módulos

A integração entre os três módulos acontece através de um **fluxo contínuo de informação** que opera em múltiplas direções dentro da arquitetura do protótipo:

1. **Do Monitoramento para a Modelagem:** O módulo de monitoramento fornece dados organizados e *scores* calculados para o módulo de modelagem, que utiliza essas informações para realizar a classificação de risco.
2. **Da Modelagem para o Monitoramento:** Os níveis de risco e fatores identificados pela modelagem são integrados de volta ao monitoramento, enriquecendo a visualização com indicadores de tendência.
3. **Do Monitoramento e Modelagem para os Alertas:** Ambos os módulos alimentam o motor de alertas com informações que permitem identificar situações que requerem atenção imediata.
4. **Dos Alertas de volta para o Monitoramento:** Quando ações são tomadas baseadas em alertas, essas informações são registradas no sistema, influenciando como o monitoramento interpreta as mudanças subsequentes no comportamento do estudante.

5.3.7 Ciclo de Melhoria Contínua

A integração entre os módulos cria um **ciclo de suporte proativo ao estudante:**

- O monitoramento coleta dados e identifica padrões básicos de engajamento
- A lógica de classificação de risco analisa esses padrões e gera indicadores de risco detalhados
- Os alertas utilizam esses indicadores de risco para identificar situações críticas
- As ações tomadas geram novos dados que são coletados pelo monitoramento
- O ciclo se repete, com cada iteração melhorando a compreensão do comportamento estudantil

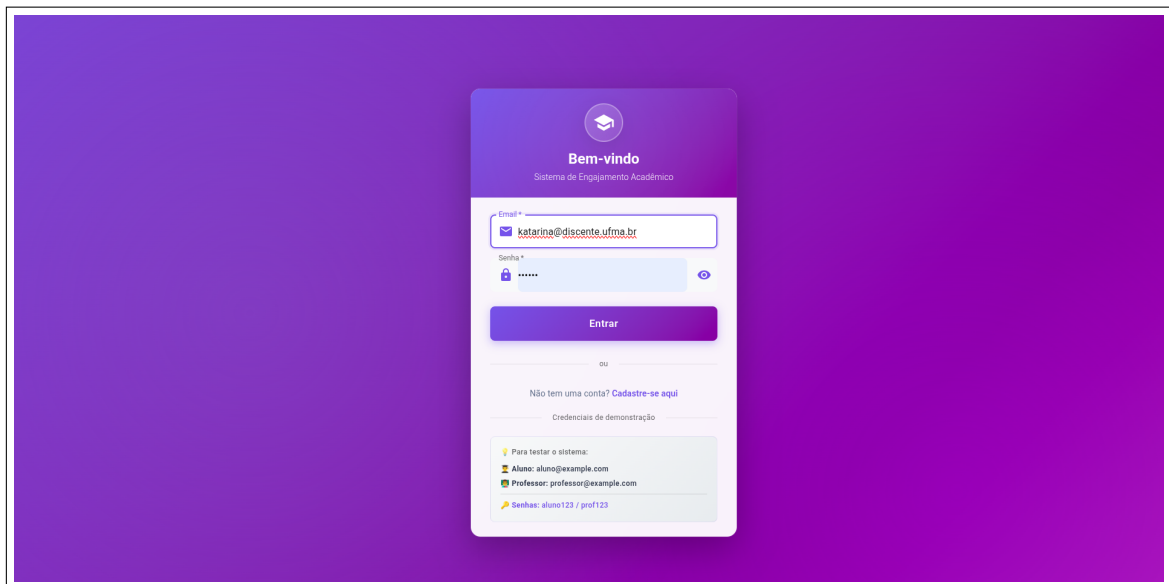
6 Protótipo do Sistema

Este capítulo apresenta a arquitetura visual e funcional do protótipo desenvolvido, detalhando as *interfaces* e as funcionalidades implementadas como prova de conceito para o monitoramento do engajamento acadêmico. As telas a seguir demonstram a viabilidade da proposta técnica, utilizando dados sintéticos para ilustrar a interação do usuário com os módulos de monitoramento e alerta.

6.1 Sistema de Autenticação e Controle de Acesso

O protótipo conta com um módulo de autenticação que suporta dois perfis de usuário (Professor e Aluno), permitindo a simulação de permissões e visualizações específicas para cada papel.

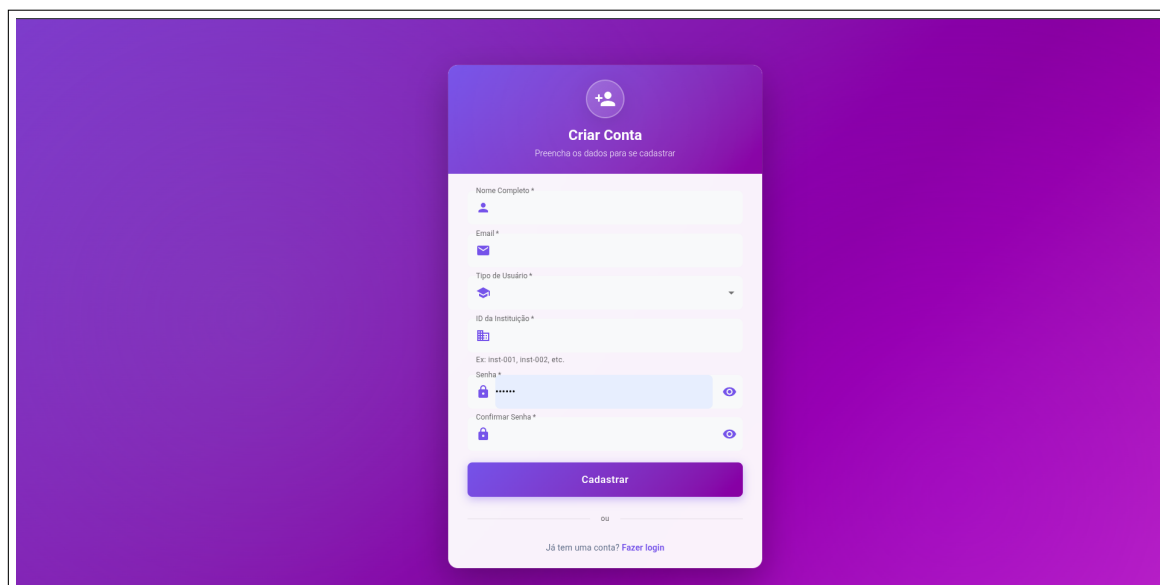
Figura 2 – Tela de Login do Sistema



Fonte: Autoria própria (2025).

A Figura 2 apresenta a *interface* de autenticação, desenvolvida com a biblioteca Material-UI, que inclui campos para validação de credenciais e *link* para o fluxo de cadastro de novos usuários.

Figura 3 – Tela de Cadastro

A imagem mostra uma tela de cadastro com o título "Criar Conta" e o subtítulo "Preencha os dados para se cadastrar". O formulário contém os seguintes campos: "Nome Completo" com ícone de pessoa; "Email" com ícone de envelope; "Tipo de Usuário" com ícone de pessoa e seta para baixo; "ID da Instituição" com ícone de documento e exemplo "Ex: Inst-001, Inst-002, etc."; "Senha" com ícone de cadeado e olho; e "Confirmar Senha" com ícone de cadeado e olho. Abaixo dos campos há um botão "Cadastrar" e o texto "ou" e "Já tem uma conta? Fazer login".

Fonte: Autoria própria (2025).

O formulário de cadastro (Figura 3), permite a criação de novas contas através de campos estruturados que alimentam diretamente a coleção de usuários no banco de dados *NoSQL*. São coletados dados como nome completo, *e-mail*, perfil de acesso (Professor ou Aluno) e o identificador da instituição, garantindo que cada registro esteja devidamente vinculado ao modelo de dados proposto na metodologia.

6.2 Dashboard de Engajamento e Monitoramento

O *Dashboard* principal (Figura 4), constitui a *interface* central de visualização para o perfil de Professor. Esta tela consolida as métricas-chave de engajamento processadas pelo sistema, permitindo uma visão macroscópica da situação da turma.

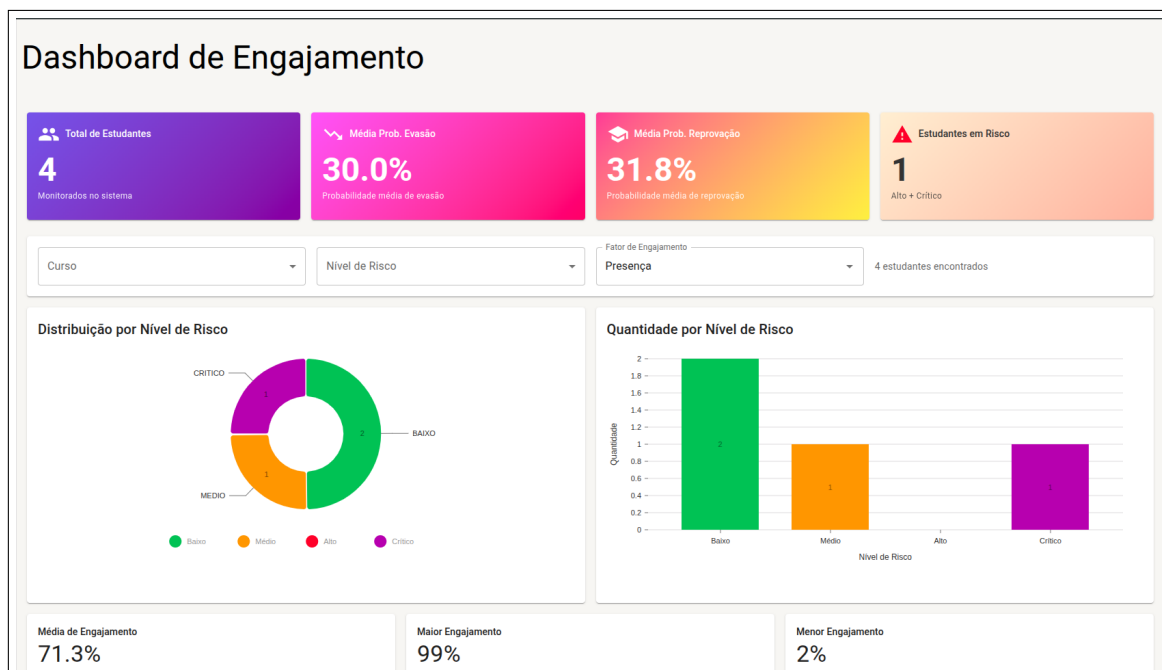


Figura 4 – *Dashboard* Principal de Engajamento

A *interface* é composta por quatro componentes principais de visualização:

1. **Cards de Resumo:** Localizados no topo, apresentam indicadores quantitativos como o total de estudantes monitorados e as médias de probabilidade de evasão e reprovação calculadas pelo algoritmo.
2. **Gráfico de Distribuição de Risco (Pizza):** Ilustra a proporção de alunos categorizados nos níveis Crítico, Alto, Médio e Baixo risco, permitindo uma rápida identificação da saúde acadêmica do grupo.
3. **Gráfico de Quantidade por Nível de Risco (Barras):** Complementa a visão anterior, quantificando o volume de estudantes em cada faixa de engajamento.
4. **Filtros Dinâmicos:** Permitem a segmentação dos dados por curso, nível de risco e métricas específicas de presença, demonstrando a interatividade do protótipo.

6.3 Sistema de Alertas Contextualizados

A *interface* de alertas, ilustrada na (Figura 5), demonstra a operacionalização do Módulo de Alertas (M3). Esta tela foi projetada para converter os dados de risco em ações práticas, permitindo ao gestor acadêmico uma resposta rápida aos sinais de desengajamento.

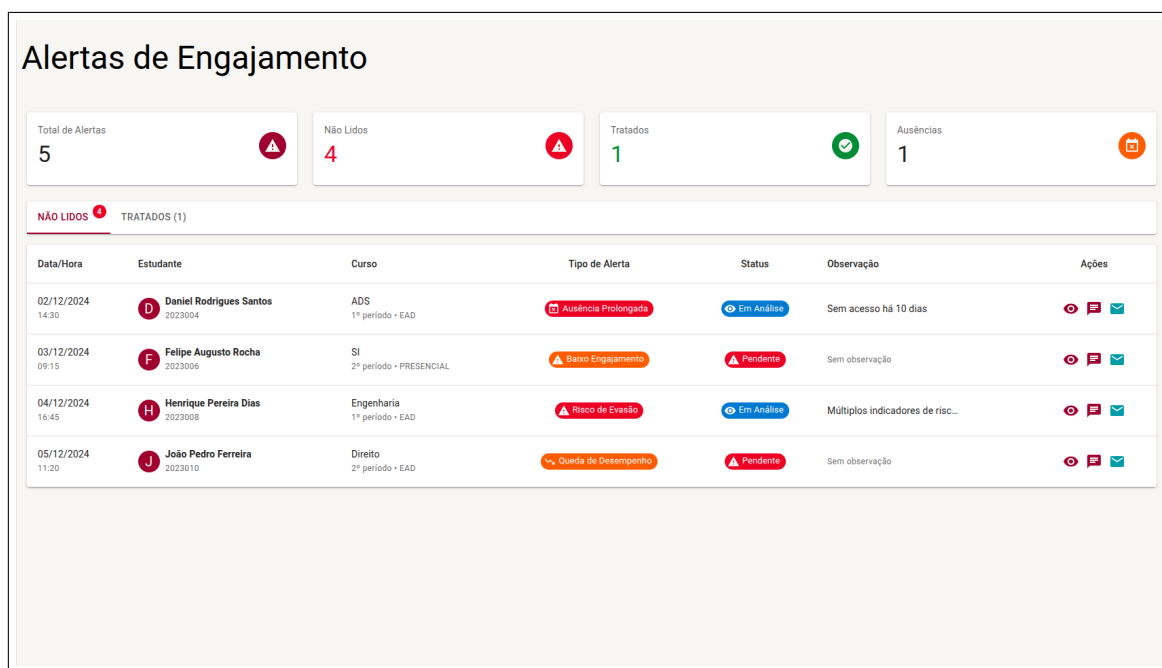


Figura 5 – Sistema de Alertas com Filtros e Status

Como observado na (Figura 5) o protótipo organiza as notificações de forma tabular, apresentando informações cruciais como o nome do estudante, o curso, o tipo de alerta e o *status* atual da ocorrência. As principais funcionalidades visuais implementadas incluem:

Funcionalidades Implementadas:

- **Categorização por Tipos:** Exibição clara de alertas como “Ausência Prolongada” ou “Risco de Evasão”, facilitando a triagem pedagógica.
- **Gestão de Fluxo de Trabalho (*Status*):** Uso de etiquetas coloridas para indicar se um alerta está “Pendente”, “Em Análise” ou “Resolvido”, simulando um sistema de chamados.
- **Painel de Estatísticas:** *Cards* superiores que resumem o volume de alertas pendentes e tratados, oferecendo um controle rápido sobre as pendências.
- **Interface de Intervenção:** O protótipo inclui janelas modais (*dialogs*) para o registro de observações, permitindo que o tutor documente as ações pedagógicas realizadas, o que garante a rastreabilidade do suporte ao aluno.

6.4 Modelagem e Simulação de Risco

As *interfaces* apresentadas nas (Figura 6, 7, 8) demonstram como o protótipo processa e exibe a lógica de classificação de risco. Diferente de um sistema de produção, estas telas operam como um simulador, permitindo visualizar como as 16 variáveis

de comportamento (Acesso, Desempenho e Interação) influenciam o cálculo final de engajamento.

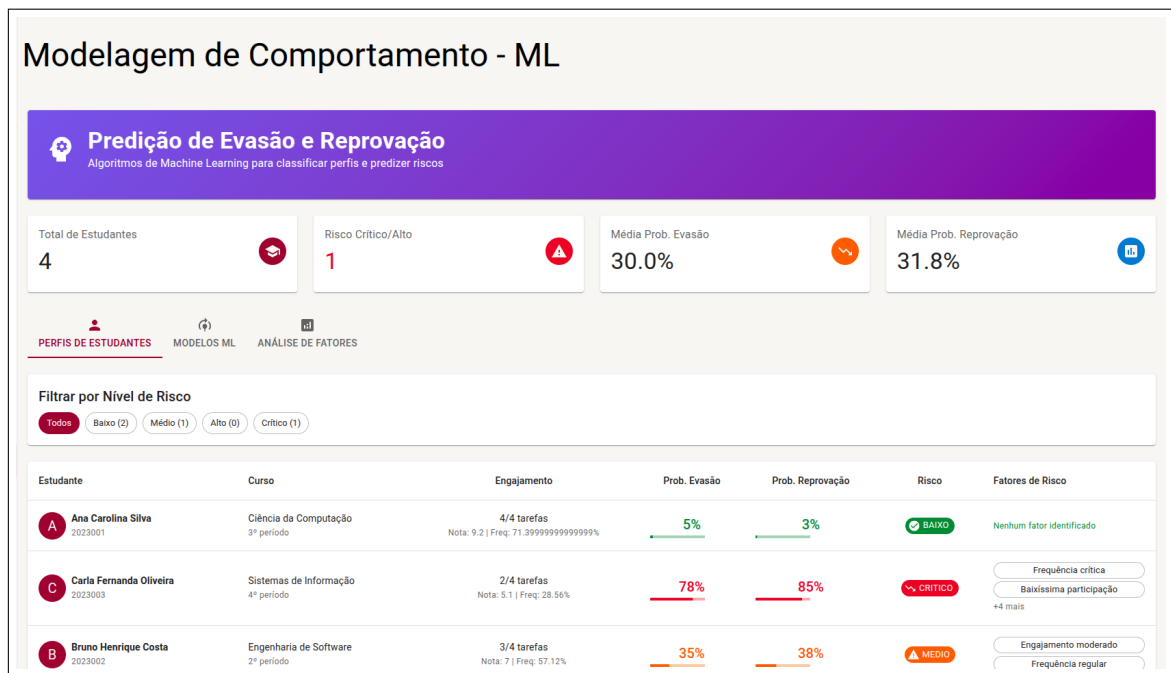


Figura 6 – Interface de Predição por Perfil de Estudantes

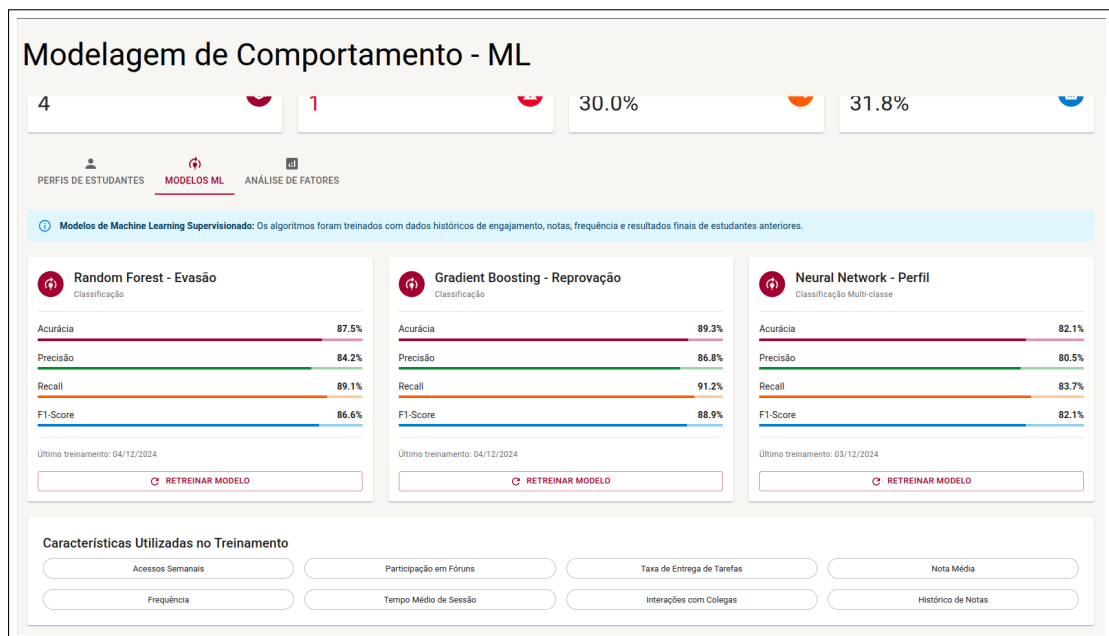


Figura 7 – Interface de Tipos de Modelos

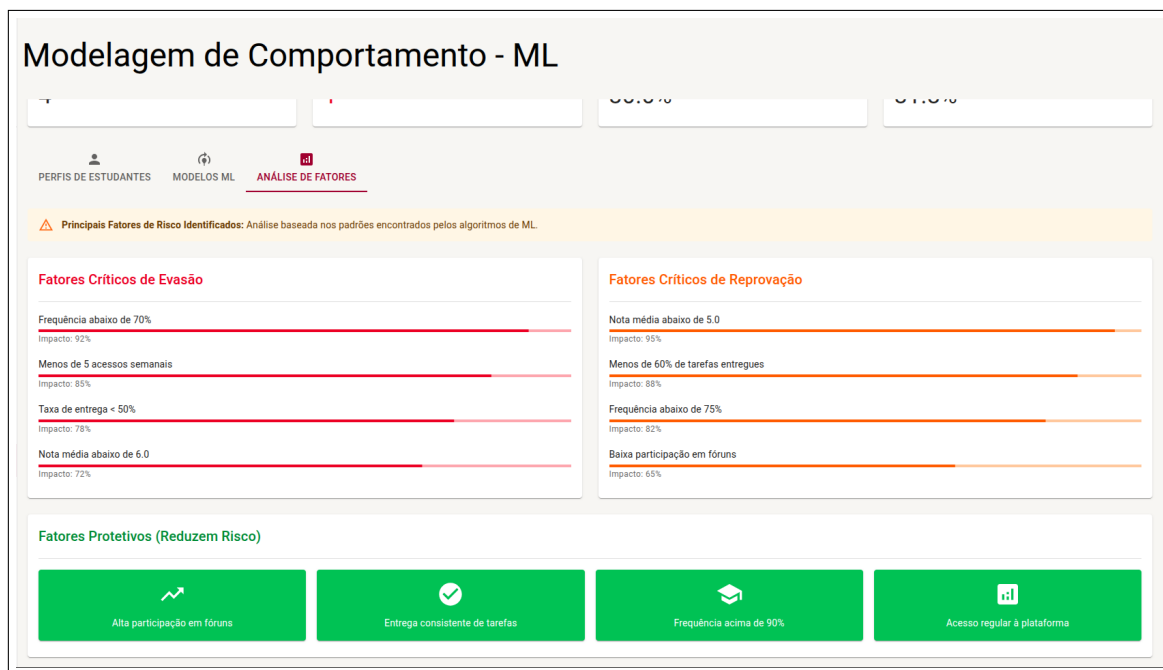


Figura 8 – Análise de Fatores

A *interface* de modelagem foi projetada para demonstrar a viabilidade de uma futura integração com algoritmos de Aprendizado de Máquina (*Machine Learning*). No estágio atual do protótipo, as telas apresentam:

1. **Perfis de Estudantes:** Uma visualização tabular que exhibe as probabilidades calculadas pela lógica heurística (pesos e medidas), simulando o que seriam as saídas de um modelo preditivo.
2. **Demonstração de Modelos:** Uma *interface* conceitual que ilustra como o gestor poderia, em versões futuras, comparar o desempenho de diferentes algoritmos (como *Random Forest* ou *Gradient Boosting*).
3. **Análise de Fatores:** Uma representação visual que indica quais das 16 variáveis monitoradas (ex: frequência, notas, interação no fórum) estão exercendo maior peso no nível de risco atual do estudante.

Esta seção do protótipo serve como uma prova de conceito visual, estabelecendo os requisitos de *interface* necessários para quando o sistema for alimentado por uma base de dados histórica real e modelos de ML devidamente treinados, conforme proposto nos Trabalhos Futuros.

6.5 Recursos de Engajamento Personalizados

Além do monitoramento, o protótipo apresenta um conjunto de *interfaces* voltadas para a intervenção pedagógica e o estímulo ao engajamento. Estas telas demonstram como o sistema pode oferecer conteúdos personalizados para mitigar os riscos identificados.

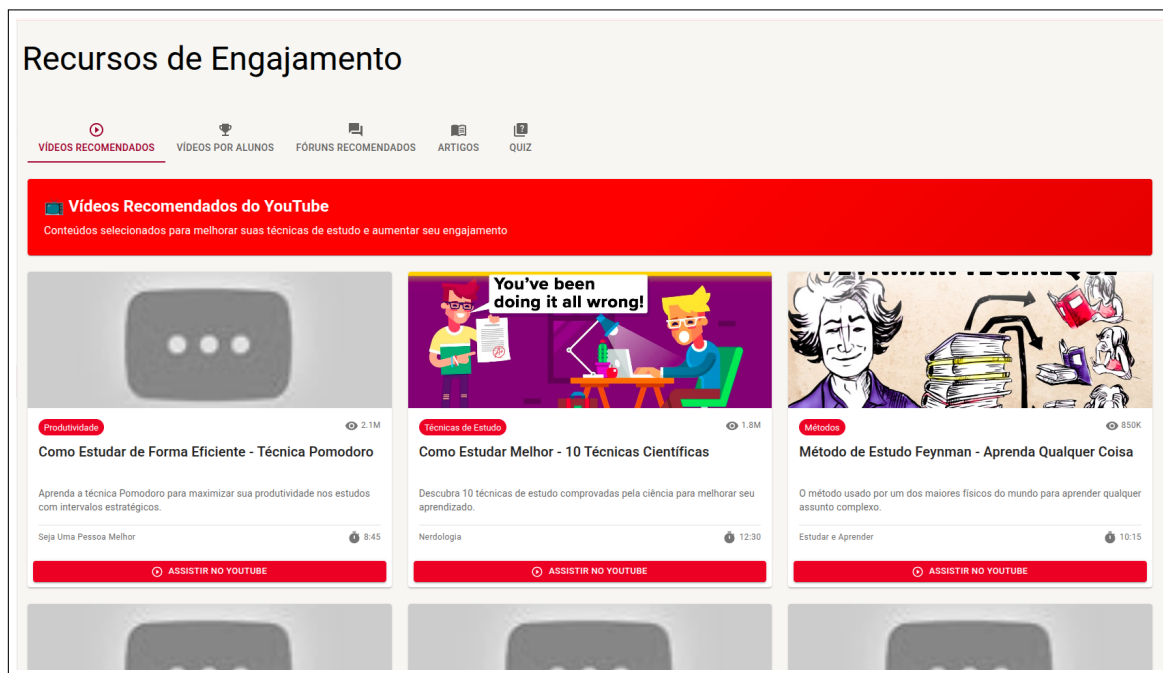


Figura 9 – Recursos de Engajamento: Vídeos recomendados

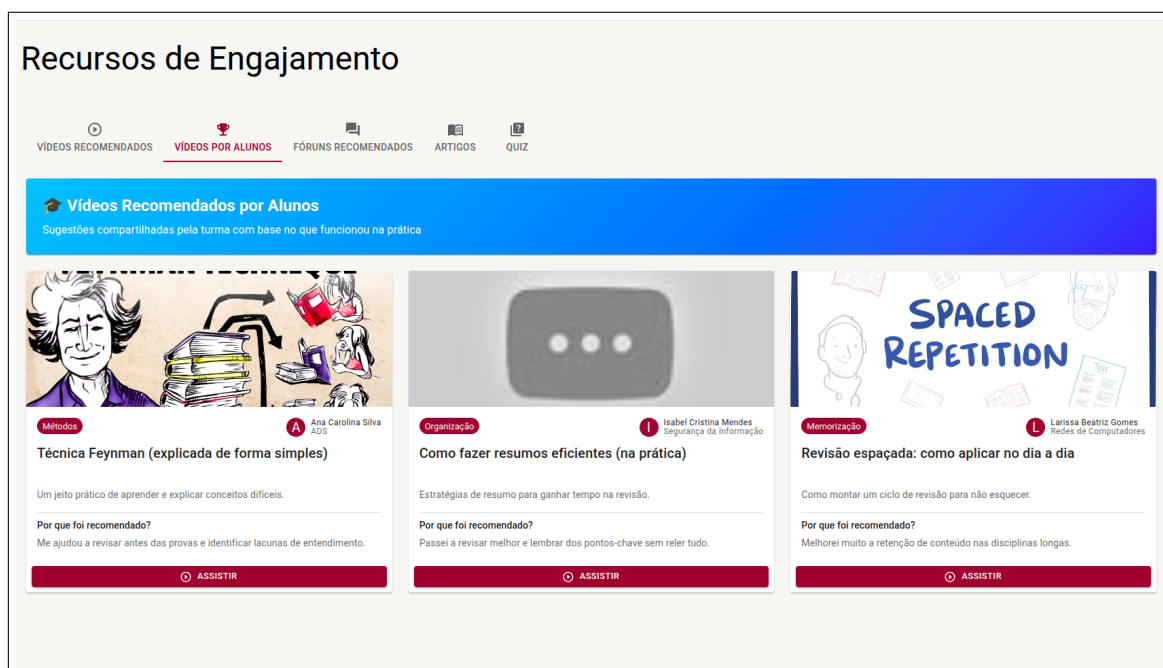


Figura 10 – Recursos de Engajamento: Vídeos recomendados por alunos

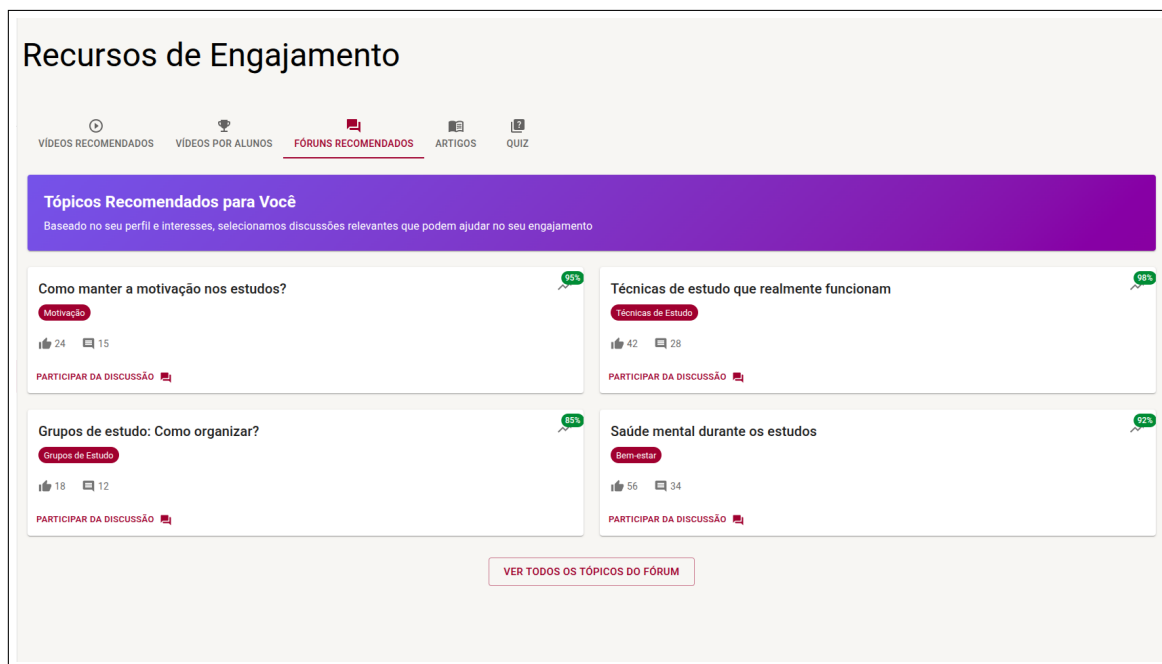


Figura 11 – Recursos de Engajamento: Fóruns

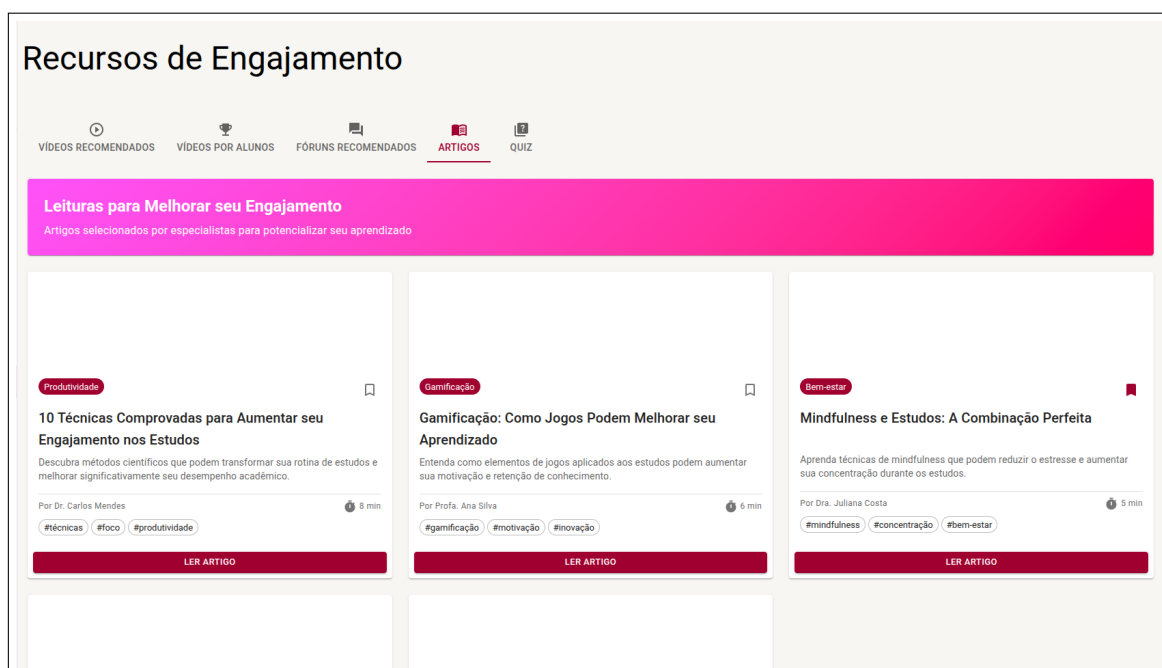


Figura 12 – Recursos de Engajamento: Artigos

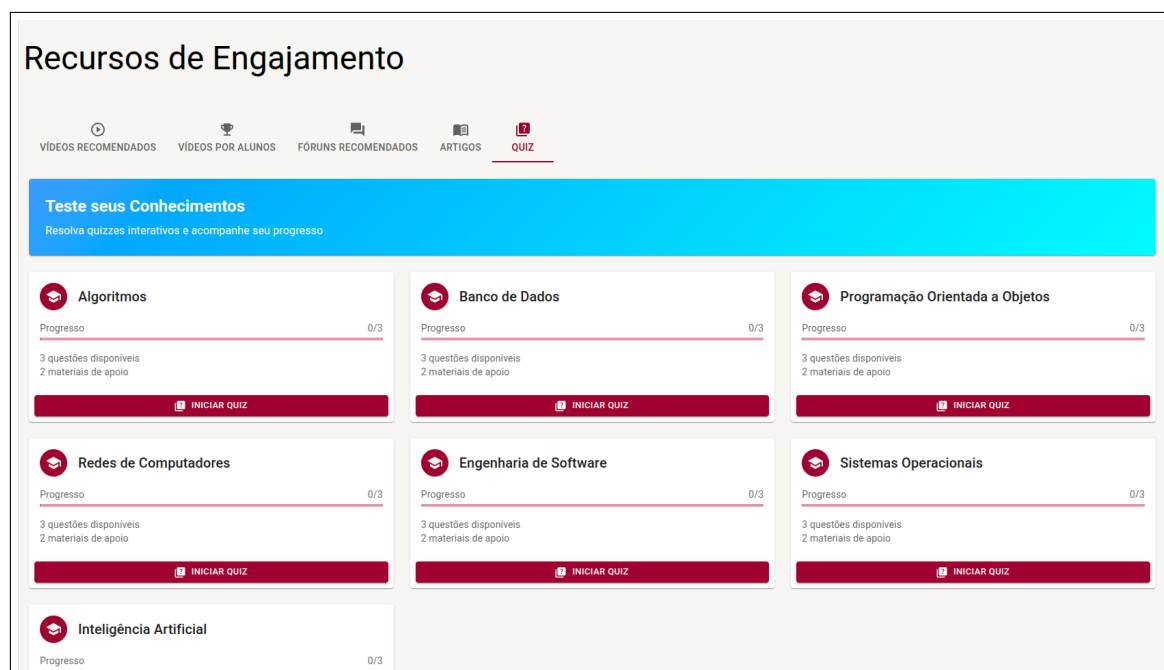


Figura 13 – Recursos de Engajamento: Quizzes

As *interfaces* de recursos implementam cinco componentes integrados, projetados para simular um ambiente de aprendizagem dinâmico:

1. **Vídeos Recomendados e por Aluno:** *Interfaces* que demonstram a curadoria de conteúdo audiovisual, permitindo a recomendação de materiais específicos com base nas necessidades de reforço detectadas.
2. **Fóruns de Discussão:** Espaço de interação social que simula um sistema de recomendação de tópicos baseado no perfil do estudante, visando aumentar a métrica de “Interação Social” (uma das 16 variáveis).
3. **Biblioteca de Artigos:** Demonstração de uma base de conhecimento curada, com funcionalidades de marcação (*bookmarks*) e categorização por temas de interesse.
4. **Quizzes Interativos:** Biblioteca curada com funcionalidade de *bookmark* e categorização;

6.6 Fórum Colaborativo

O Fórum Colaborativo, apresentada na (Figura 14), foi desenvolvido para estimular a interação entre os estudantes, servindo como uma fonte direta de dados para as métricas de engajamento social do sistema.

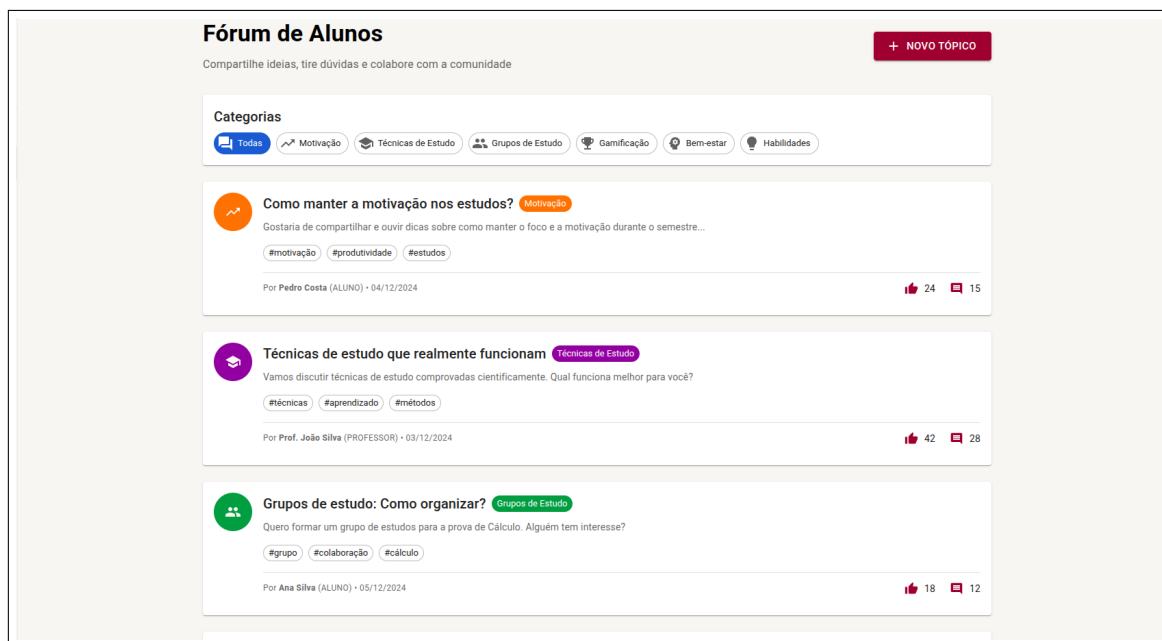


Figura 14 – Sistema de Fórum com Categorias e Interações

O protótipo do fórum promove o engajamento através de componentes visuais modernos e funcionais, destacando-se:

- **Categorização Temática:** Organização em eixos como Motivação, Técnicas de Estudo e Bem-estar, permitindo que o sistema monitore em quais áreas o estudante demonstra maior interesse ou necessidade.
- **Mecanismos de Gamificação Social:** Inclusão de sistemas de curtidas (*likes*) e comentários, que no modelo de dados proposto, são convertidos em indicadores de popularidade e relevância.
- **Interface Responsiva:** O *design* utiliza componentes do Material-UI para garantir que a experiência de interação seja fluida, reforçando a proposta de um ambiente acadêmico acolhedor e moderno.

6.7 Análise Comparativa entre Cursos e Turmas

Essa *interface* do protótipo expande a capacidade de monitoramento para o nível institucional. Dessa forma, permite que o docente ou gestor realize comparações de desempenho e engajamento entre diferentes turmas e cursos da mesma faculdade.

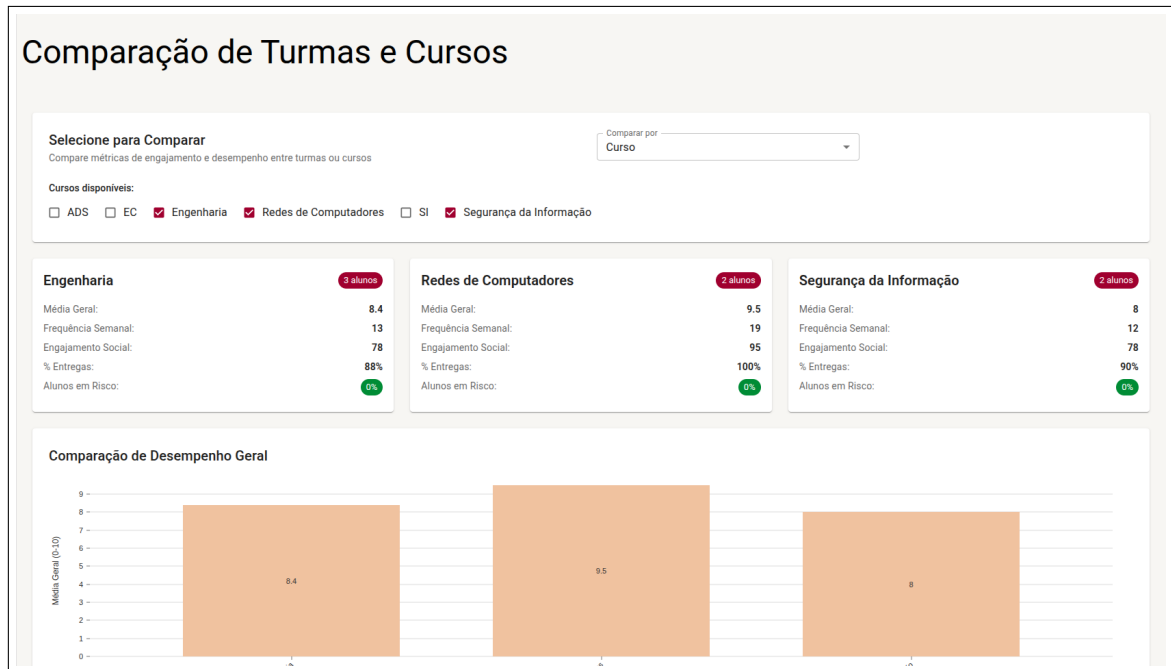


Figura 15 – Tela de comparação entre turmas e cursos

- **Identificação de Padrões Coletivos:** Visualização de quais turmas apresentam maiores índices de risco, auxiliando na alocação de recursos pedagógicos de forma mais eficiente.
- **Benchmarking Acadêmico:** Comparação de métricas de engajamento entre disciplinas distintas, permitindo identificar metodologias de ensino que podem estar gerando melhores resultados de interação.
- **Visão Institucional:** O protótipo simula como os dados agregados do *Firebase* podem ser consumidos para gerar relatórios de alto nível, fundamentais para a tomada de decisão estratégica na instituição.

6.8 Dashboard de Monitoramento Pessoal do Estudante

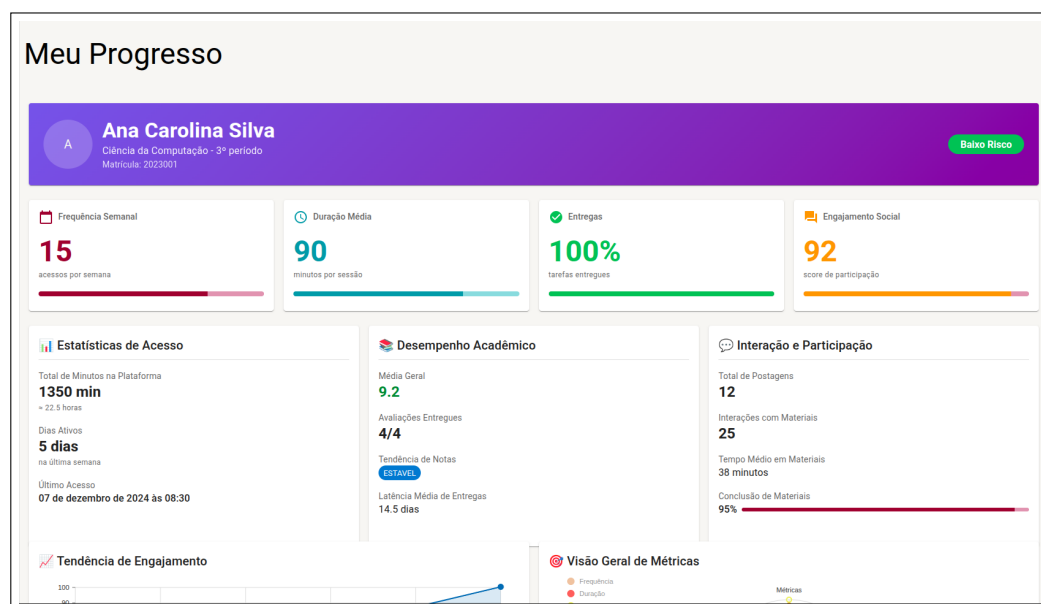
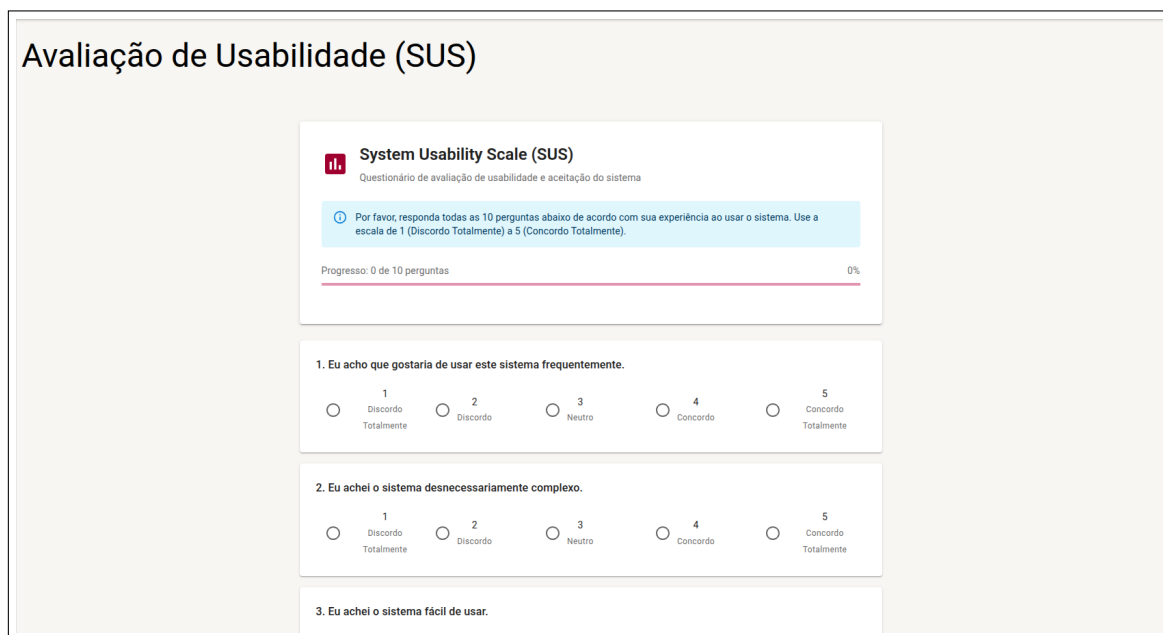


Figura 16 – Monitoramento Pessoal (Perfil Aluno)

1. **Cards de Indicadores:** Exibem métricas imediatas como a frequência semanal (15 acessos), duração média das sessões (90 min), taxa de entrega de tarefas (100%) e o *score* de engajamento social (92).
2. **Painéis de Detalhamento:**
 - **Estatísticas de Acesso:** Consolida o tempo total na plataforma (1350 min) e a regularidade de uso.
 - **Desempenho Acadêmico:** Apresenta a média geral (9.2), a tendência de notas e a latência média de entregas (14.5 dias).
 - **Interação e Participação:** Quantifica o engajamento social, como o total de postagens (12) e a conclusão de materiais didáticos (95%).
3. **Visualizações Gráficas:**
 - **Tendência de Engajamento:** Um gráfico de linha que demonstra a evolução do *score* do aluno ao longo das semanas, permitindo observar o crescimento do envolvimento acadêmico.
 - **Visão Geral de Métricas (Radar):** Um gráfico de teia que compara diferentes dimensões (frequência, duração, entregas, engajamento e postagens), facilitando a identificação do equilíbrio no perfil do estudante.
4. **Indicadores de Risco:** Apresenta de forma clara as probabilidades de evasão (5%) e reprovação (3%), calculadas pela lógica do sistema, servindo como um alerta preventivo para o próprio aluno.

6.9 Instrumento de Avaliação de Usabilidade (SUS)

Como parte do planejamento para a validação da experiência do usuário, o protótipo inclui um módulo integrado para a coleta de dados de usabilidade por meio do método SUS (*System Usability Scale*). A Figura 17 apresenta a *interface* desenvolvida para este fim, que consiste em um questionário psicométrico de 10 itens com escala *Likert* de 5 pontos.



The image shows a screenshot of a web-based questionnaire titled "Avaliação de Usabilidade (SUS)". The main heading is "System Usability Scale (SUS)" with a subtitle "Questionário de avaliação de usabilidade e aceitação do sistema". Below this, there is a light blue instruction box: "Por favor, responda todas as 10 perguntas abaixo de acordo com sua experiência ao usar o sistema. Use a escala de 1 (Discordo Totalmente) a 5 (Concordo Totalmente)". A progress bar indicates "Progresso: 0 de 10 perguntas" and "0%". The questionnaire consists of three visible items, each with a 5-point Likert scale:

- 1. Eu acho que gostaria de usar este sistema frequentemente.
- 2. Eu achei o sistema desnecessariamente complexo.
- 3. Eu achei o sistema fácil de usar.

Each item has five radio button options labeled 1 through 5, with corresponding text: 1 (Discordo Totalmente), 2 (Discordo), 3 (Neutro), 4 (Concordo), and 5 (Concordo Totalmente).

Figura 17 – *Interface* do questionário *System Usability Scale*.

É importante ressaltar que, embora o instrumento tenha sido tecnicamente implementado e integrado ao fluxo do usuário no protótipo, sua aplicação e validação estatística com usuários reais não foram realizadas nesta etapa da pesquisa, permanecendo como uma proposta central para os trabalhos futuros. A inclusão desta *interface* demonstra que o sistema está arquiteturalmente preparado para ciclos de melhoria contínua basados no *feedback* direto dos usuários.

6.10 Painel de Resultados da Avaliação de Usabilidade (SUS)

A Figura 18 ilustra a capacidade do protótipo em processar e exibir indicadores de usabilidade. Esta *interface* foi projetada para automatizar o cálculo do *score* SUS assim que o sistema for submetido a testes com usuários reais em etapas posteriores de pesquisa.

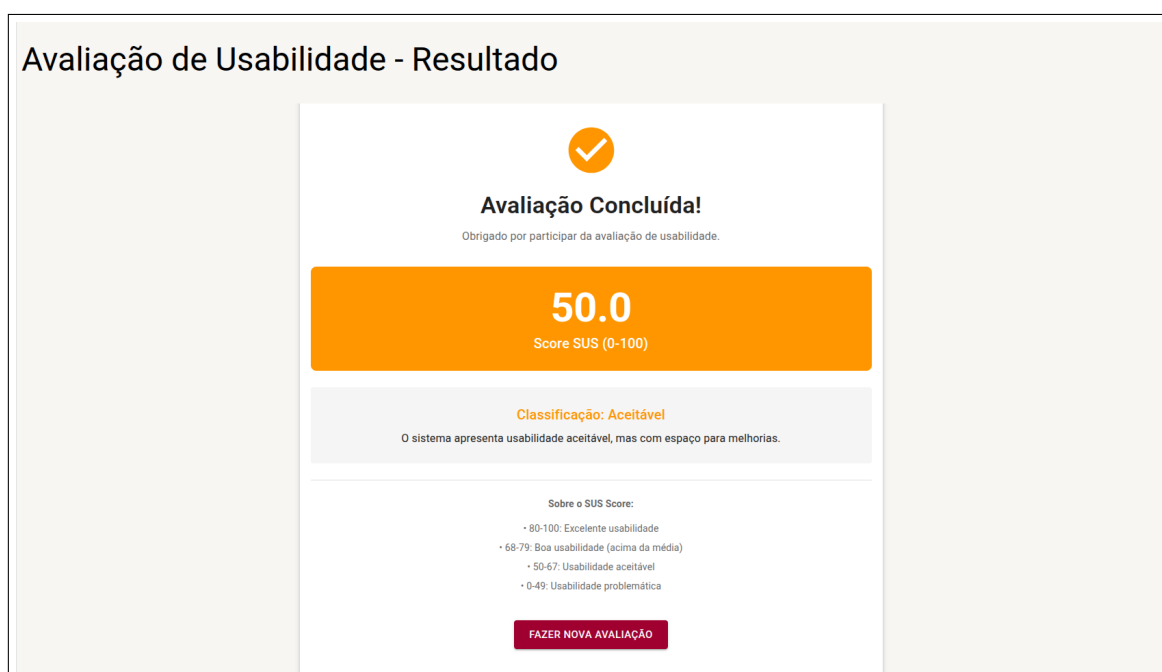


Figura 18 – Tela de apresentação dos resultados da avaliação SUS com *score* e interpretação.

7 Resultados e Discussões

A implementação do sistema de monitoramento de engajamento estudantil baseado em *React* e *Firebase* resultou em uma protótipo funcional e escalável, validando as hipóteses iniciais sobre a viabilidade de arquiteturas *serverless* para *Learning Analytics*. Esta seção apresenta os resultados obtidos, análises críticas e discussões sobre os impactos observados.

7.1 Arquitetura Implementada e Verificação Tecnológica

7.1.1 Implementação da Arquitetura *Serverless*

A arquitetura proposta, fundamentada em *Firebase* (*backend*) e *React* com *TypeScript* (*frontend*), foi implementada através do desenvolvimento de um protótipo funcional que demonstra a viabilidade técnica da solução. A análise arquitetural indica potenciais benefícios em relação a soluções monolíticas tradicionais:

- **Custo de Infraestrutura:** A arquitetura *serverless* proposta elimina a necessidade de manutenção de servidores físicos ou instâncias fixas na nuvem, adotando um modelo de precificação baseado no uso real (*pay-as-you-go*). Esta característica é fundamental para a sustentabilidade do projeto em cenários de orçamentos limitados.
- **Tempo de Desenvolvimento:** O uso de tecnologias modernas como (*React* e *Material-UI*) permitiu desenvolvimento ágil da camada de apresentação. A componentização do *frontend* facilitou a criação de *interfaces* complexas, como o *Dashboard* de Engajamento, com uma redução significativa no tempo de implementação em comparação a *frameworks* tradicionais.
- **Escalabilidade e Estresse do Modelo de Dados:** A arquitetura proposta suporta escalabilidade automática por meio do *Firebase*. Para a verificação funcional do protótipo, o uso do gerador de dados sintéticos (capaz de simular até 1000 perfis) demonstrou que a estrutura *NoSQL* do *Firestore* mantém a integridade e a velocidade de resposta mesmo sob volumes de dados que representam múltiplas turmas simultâneas.
- **Manutenibilidade e Evolução:** A organização do código em *TypeScript* garantiu uma tipagem forte, reduzindo erros em tempo de execução. A componentização permitiu o isolamento de funcionalidades (como o módulo de alertas e o fórum), facilitando futuras expansões do sistema, como a integração de modelos reais de *Machine Learning*.

7.1.2 Implementação do Modelo de Dados *NoSQL*

A estrutura de dados implementada no *Firestore* demonstrou alta eficiência no armazenamento e recuperação de *logs* educacionais. A arquitetura foi verificada funcionalmente por meio de implementação de quatro coleções principais, que sustentam a lógica do protótipo:

- **Logs de Acesso:** Responsável pelo rastro digital de conectividade, armazenando *timestamps*, duração de sessões e o tipo de dispositivo utilizado. Esta coleção permite ao sistema calcular a frequência e a regularidade do estudante no ambiente virtual.
- **Métricas de Desempenho:** Consolida os dados quantitativos de aprendizagem, como notas, histórico de entregas e a latência de submissão de atividades (tempo entre a disponibilização e a entrega), fornecendo a base para o cálculo de risco acadêmico.
- **Dados de Interação:** Registra o engajamento qualitativo, incluindo postagens em fóruns e interações com materiais didáticos. Esta coleção é crucial para alimentar as variáveis de “Interação”, que frequentemente não recebem a devida atenção em sistemas tradicionais.
- **Alertas Contextualizados:** Um sistema de notificações dinâmico que categoriza as ocorrências em tipos específicos (Ausência Prolongada, Queda de Desempenho, Baixo Engajamento e Risco de Evasão). Esta coleção também gerencia o ciclo de vida do alerta através do rastreamento de *status* (Não Lido, Em Análise e Tratado), garantindo a rastreabilidade das ações pedagógicas.

7.1.3 Dados Sintéticos e Verificação Funcional do Sistema

Para verificar a funcionalidade do protótipo e a precisão da lógica de classificação de risco, foi desenvolvido um módulo de *Data Seeding* denominado *MockDataGenerator*. Este componente foi essencial para simular o comportamento do sistema em um cenário de uso real, permitindo a verificação funcional das 16 variáveis de engajamento propostas sem comprometer a privacidade de dados reais. O gerador de dados emula padrões comportamentais através de algoritmos que garantem a consistência técnica das informações, permitindo:

- **Testes de Carga:** Geração de até 1000 perfis de estudantes simultâneos, verificando a capacidade do *Firebase* e da *interface* em *React* de processar e exibir grandes volumes de dados sem perda de performance.

- **Perfis Diversificados:** Categorização automática em quatro níveis de risco (Baixo, Médio, Alto e Crítico), garantindo que todos os alertas e gráficos do *Dashboard* fossem testados.
- **Dados Temporais:** Inclusão de *timestamps* realistas para simular o rastro digital de acesso dos alunos ao longo de um semestre letivo.
- **Métricas Correlacionadas:** Estabelecimento de correlações lógicas (ex: estudantes com baixa frequência tendem a apresentar menor interação e notas mais baixas), conferindo realismo à simulação.

Tabela 8 – Exemplos de Perfis Gerados para Verificação Funcional do Sistema

Perfil Simulado	Acessos/ Semana	Média Acadêmica	Entregas	Classificação de Risco
Estudante Exemplar	15	9.2	100%	BAIXO (5% de risco)
Estudante em Risco	3	5.1	50%	CRÍTICO (78% de risco)

7.1.4 Contribuições Tecnológicas Alcançadas

7.1.4.1 Arquitetura de Referência

O projeto estabelece uma arquitetura de referência para sistemas de *Learning Analytics* baseada em:

- **Frontend Componentizado:** Implementação de mais de 40 componentes *React* reutilizáveis, desenvolvidos com *TypeScript*. Esta abordagem garante a escalabilidade do código e facilita a manutenção por outros desenvolvedores.
- **Gerenciamento de Estado:** Uso eficiente da *Context API* para gerenciar fluxos críticos como autenticação, preferências de tema e navegação, garantindo uma experiência de usuário fluida e sem inconsistências de dados.
- **Roteamento Protegido:** Implementação de um sistema de controle de acesso baseado em perfis (*Role-Based Access Control*), assegurando que as funcionalidades de gestão sejam exclusivas para professores, enquanto os recursos de engajamento sejam direcionados aos alunos.
- **Material-UI:** Utilização da biblioteca *Material-UI* para garantir uma *interface* consistente, responsiva e acessível, seguindo os padrões internacionais de *design* de *interface* (UI) e experiência do usuário (UX).

7.1.4.2 Modelo de Dados Escalável

As interfaces *TypeScript* desenvolvidas (*DataInterfaces.ts*) fornecem:

- **Tipagem Forte e Consistência:** Definição rigorosa para mais de 15 entidades de dados, o que previne erros de integração entre o *frontend* e o banco de dados *NoSQL*.
- **Estruturas Multidimensionais:** Modelagem específica para capturar *logs* de acesso, métricas de desempenho e dados de interação social, permitindo uma visão ampla do estudante.
- **Capacidade de Agregação:** Estruturas preparadas para realizar cálculos de métricas globais e análises institucionais, facilitando a geração de relatórios para grandes volumes de dados.
- **Parametrização de Alertas:** Configurações flexíveis para os limiares (*thresholds*) de risco, permitindo que a instituição ajuste o que considera “baixo engajamento” ou “risco crítico” sem a necessidade de reescrever o código principal.

7.2 Impactos Práticos e Pedagógicos

A validação do protótipo permitiu observar como a tecnologia proposta pode impactar positivamente a gestão acadêmica, transformando dados brutos em ações pedagógicas concretas.

7.2.1 Detecção Precoce de Risco

O sistema implementa gatilhos automáticos para a identificação proativa de estudantes em vulnerabilidade acadêmica, destacando-se:

- **Monitoramento de Ausência:** Disparo de alertas após um período configurável de dias sem acesso, combatendo o abandono silencioso.
- **Queda de Desempenho:** Identificação de quedas sucessivas em avaliações, permitindo uma intervenção antes da reprovação final.
- **Métricas de Engajamento:** Uso de *thresholds* (limiares) para detectar quando a participação do aluno está abaixo da média da turma.

7.2.2 Intervenção Proativa e Rastreabilidade

O módulo de alertas não apenas identifica o problema, mas organiza a solução por meio de:

- **Registro Estruturado:** Campo de observação obrigatório que força a documentação da ação pedagógica tomada.
- **Histórico de Ações:** Criação de uma linha do tempo que permite à coordenação acompanhar a evolução do suporte dado ao estudante.
- **Base de Conhecimento:** Acúmulo de dados que, no futuro, permitirá analisar quais estratégias de intervenção foram mais eficazes para cada perfil de risco.

7.2.3 Personalização da Experiência de Aprendizagem

O protótipo valida a viabilidade de oferecer suporte personalizado em larga escala por meio de:

- **Recomendações Inteligentes:** Sugestão de fóruns, vídeos e artigos com base no perfil de interesse e nas dificuldades detectadas pelo sistema.
- **Avaliação Formativa:** Uso de *quizzes* com *feedback* imediato, o que aumenta a autonomia do estudante e reforça o engajamento contínuo.

7.2.4 Discussão Crítica e Limitações

7.2.4.1 Limitações Identificadas

1. **Lógica de Classificação Heurística:** Atualmente, os algoritmos de classificação de risco visualizados nas *interfaces* operam com base em uma lógica heurística de pesos e medidas, verificada funcionalmente por dados sintéticos. Para que o sistema evolua para uma implementação real de *Machine Learning*, os seguintes requisitos técnicos foram identificados:
 - **Infraestrutura de Backend:** Necessidade de integração com um ambiente especializado em *Python* (utilizando *frameworks* como *scikit-learn* ou *TensorFlow*) para o processamento de modelos preditivos complexos.
 - **Dados Históricos Reais:** A precisão de um modelo de IA depende de dados reais de semestres anteriores para treinamento e calibração, o que não foi o escopo deste protótipo focado em arquitetura e *interface*.
 - **Ciclo de Retreinamento:** Estabelecimento de um *pipeline* de retreinamento periódico para que o sistema aprenda com novos padrões de comportamento estudantil ao longo do tempo.
2. **Validação de Interface e Usuário Fixo:** O uso de um perfil de usuário fixo para demonstração e a ausência de testes de usabilidade em larga escala com usuários reais

(professores e alunos) constituem limitações de validação humana. No entanto, estas escolhas permitiram focar na estabilidade da arquitetura *serverless* e na consistência visual do *Dashboard*, deixando a validação de experiência do usuário (UX) como uma prioridade para etapas posteriores.

- **Integração com Sistemas Acadêmicos Reais (SIA):** Para que o monitoramento seja efetivo, o sistema deve consumir dados diretamente das bases institucionais.
 - **Coleta de Dados Longitudinais:** É necessário um período mínimo de dois semestres de coleta para capturar a sazonalidade e as mudanças de comportamento ao longo de um ciclo letivo completo.
 - **Conformidade com a LGPD:** A transição para dados reais exige a implementação de protocolos rigorosos de anonimidade e conformidade com a Lei Geral de Proteção de Dados e as políticas de privacidade institucionais.
3. **Escalabilidade e Performance em Produção:** Embora os testes de carga tenham sido simulados com sucesso para até 1000 perfis, a escalabilidade em um ambiente de produção real apresenta desafios adicionais que devem ser endereçados em versões futuras:
- **Testes de *Stress* com Usuários Reais:** Necessidade de validar a concorrência de acessos simultâneos de professores e alunos em períodos de pico (como semanas de provas).
 - **Otimização de *Queries Firestore*:** Refinamento dos índices do banco de dados para garantir que o custo e a velocidade das consultas permaneçam otimizados à medida que a base de dados cresce.
 - **Implementação de *Cache* e CDN:** Uso de estratégias de *caching* e Redes de Entrega de Conteúdo (CDN) para reduzir a latência no carregamento de recursos pesados, como os vídeos e materiais didáticos.

7.2.4.2 Trabalhos Futuros

- **Integração com LMS (*Learning Management Systems*):** Desenvolvimento de conectores para plataformas como *Moodle*, *Canvas* e *Google Classroom*, permitindo a coleta automática de dados de interação.
- **Implementação de Modelos de IA Reais:** Substituição da lógica heurística por um *pipeline* completo de treinamento e predição utilizando algoritmos de Aprendizado de Máquina.

- **Análise Preditiva Avançada via NLP:** Incorporação de Processamento de Linguagem Natural (*Natural Language Processing*) para realizar a análise de sentimento em postagens de fóruns, identificando sinais de desmotivação ou frustração.
- **Gamificação e Engajamento:** Implementação de sistemas de conquistas (*badges*) e *rankings* saudáveis para incentivar a participação ativa dos estudantes.
- **Desenvolvimento de Aplicativo Mobile:** Criação de uma versão nativa para dispositivos móveis, permitindo o envio de notificações *push* e o acesso *offline* a materiais didáticos.
- **Dashboards para Alunos:** Expansão das visualizações para os alunos, permitindo que eles acompanhem seu próprio progresso e realizem comparações anônimas com a média da turma.
- **Avaliação de Usabilidade (SUS):** Realização de testes formais com usuários reais (professores e alunos) para validar a experiência do usuário e identificar oportunidades de melhoria no *design* da *interface*. O protótipo já possui o módulo SUS implementado (conforme detalhado no Capítulo 5), o que permitirá a coleta e o processamento imediato dos resultados da avaliação.

7.3 Resultados dos Casos de Uso Implementados

A implementação do sistema contemplou 12 casos de uso principais, distribuídos entre os dois perfis de usuário (Professor e Aluno). Esta subseção apresenta os resultados obtidos para cada caso de uso, validando a cobertura funcional do sistema.

7.3.1 Casos de Uso - Perfil Professor

UC01 - Visualizar Dashboard de Engajamento

Descrição: O protótipo permitiu ao gestor acessar o *dashboard* principal para visualizar as métricas agregadas de engajamento, conforme a Figura 4.

Resultado: Implementado com sucesso. A *interface* demonstrou capacidade de processar e exibir em tempo real:

- O total de estudantes monitorados;
- A distribuição por nível de risco (Baixo, Médio, Alto, Crítico);
- As médias de probabilidade de evasão e reprovação calculadas pela lógica algorítmica;
- Gráficos de tendência baseados nos dados sintéticos.

Aspectos Técnicos: A funcionalidade foi implementada por meio da *interface* **MetricasGlobais**, que realiza as agregações dos documentos da coleção **ComportamentoEstudante** no *Firestore*.

UC02 - Gerenciar Alertas de Risco

Descrição: O protótipo permitiu ao gestor visualizar, filtrar e gerenciar os alertas gerados automaticamente pela lógica de monitoramento, conforme apresentado na Figura 5.

Resultado: A funcionalidade foi implementada com sucesso, seguindo rigorosamente a especificação da coleção **Alertas** no banco de dados. As capacidades demonstradas incluíram:

- **Filtragem Dinâmica:** Listagem de ocorrências com filtros por status (Não Lido e Tratado);
- **Detalhamento de Dados:** Exibição de informações cruciais como identificador do estudante, data de geração e tipo de risco;
- **Registro de Intervenções:** Validação do fluxo de tratamento com campo obrigatório de observação, garantindo a documentação da ação pedagógica.

Dados de Teste: Para a implementação, foram utilizados alertas simulados que cobriram todos os *status* e tipos previstos, confirmando a integridade do fluxo de trabalho (*workflow*) proposto.

UC03 - Analisar Simulações da Lógica de Classificação de Risco

Descrição: O gestor acessa a *interface* de lógica de classificação de risco para visualizar a representação dos indicadores de risco de evasão e reprovação, conforme ilustrado na figura 6.

Resultado: A *interface* foi implementada com sucesso como uma prova de conceito visual, demonstrando a capacidade do sistema em exibir:

- **Tabela de Indicadores Percentuais:** Visualização de estudantes com riscos calculados pela lógica heurística, simulando a saída de modelos preditivos;
- **Painel de Modelos:** Demonstração de como seriam comparadas as métricas (Acurácia, *F1-Score*) de diferentes algoritmos (*Random Forest*, *Gradient Boosting* e *Neural Network*);
- **Análise de Impacto:** Representação visual dos fatores de risco e seu peso percentual na composição do engajamento.

Dados de Teste: A verificação funcional utilizou perfis completos gerados pelo gerador de dados sintéticos, confirmando que a *interface* é capaz de traduzir dados complexos em informações compreensíveis para o gestor.

UC04 - Monitorar Engajamento em Tempo Real

Descrição: Visualização de métricas de acesso, desempenho e interação atualizadas, simulando o monitoramento contínuo do comportamento estudantil.

Resultado: A funcionalidade foi validada com sucesso, demonstrando a integração fluida entre o banco de dados *NoSQL* e a *interface*. O sistema processou e exibiu corretamente:

- **LogAcesso:** 7 Registros detalhados com *timestamp*, duração da sessão e tipo de dispositivo utilizado;
- **FrequenciaAcesso:** 5 registros semanais que permitem identificar padrões de regularidade do estudante;
- **InteracaoMaterial:** 5 registros com monitoramento do tempo de visualização e consumo de recursos didáticos.

Aspectos Técnicos: A implementação utilizou um conjunto de dados simulados que cobriu diferentes dispositivos e durações de acesso, confirmando a precisão dos cálculos de engajamento em tempo real.

UC05 - Visualizar Desempenho de Turma

Descrição: Permitiu ao professor acessar as métricas agregadas de desempenho acadêmico de sua turma, oferecendo uma visão clara da evolução das notas e compromisso com prazos.

Resultado: Implementado com sucesso através da *interface DesempenhoAcademico*. O sistema demonstrou capacidade de processar:

- **Histórico de Avaliações:** Notas parciais e finais, permitindo o acompanhamento do progresso individual e coletivo;
- **Taxa de Entrega:** Cálculo automático do percentual de atividades submetidas em relação ao total proposto;
- **Latência de Submissão:** Monitoramento do tempo médio (em horas) que o estudante leva para realizar as entregas, servindo como um indicador precoce de procrastinação ou dificuldade.

Dados de Teste: A implementação utilizou perfis com diferentes padrões de notas e prazos, confirmando a precisão dos cálculos de média e latência no *Dashboard*.

UC06 - Registrar Observações sobre Alunos

Descrição: Professor registra observações qualitativas sobre estudantes.

Resultado: A funcionalidade foi implementada com sucesso através do campo (observacao tutor) na coleção de Alertas. O sistema demonstrou ser capaz de criar um histórico rastreável de suporte ao aluno, conforme evidenciado pelos registros de teste:

- “Entrei em contato com a aluna. Ela estava com problemas pessoais, mas já retornou às atividades”.
- “Agendada reunião de orientação. Aluna apresentou dificuldades em Algoritmos”.
- “Encaminhado para monitoria de Banco de Dados”.

7.3.2 Casos de Uso - Perfil Aluno

UC07 - Acessar Recursos de Engajamento

Descrição: O protótipo permitiu ao estudante acessar uma trilha de conteúdos recomendados, incluindo vídeos, artigos, fóruns e *quizzes*, conforme ilustrado na Figura 9.

Resultado: A funcionalidade foi implementada com sucesso, demonstrando a integração de múltiplos formatos de aprendizagem:

- **Fóruns:** O sistema processou e exibiu 4 tópicos recomendados, com *scores* de relevância variando entre 85% e 98%;
- **Artigos:** Foram validados 5 artigos educacionais com funcionalidades completas de *bookmark* e categorização;
- **Quizzes:** A base de dados de teste contou com 7 disciplinas e 20 questões totais, todas com sistema de *feedback* imediato.

UC08 - Participar de Fóruns Colaborativos

Descrição: Aluno cria tópicos, responde e interage em fóruns.

Resultado: O sistema de fórum foi implementado com sucesso, apresentando uma estrutura completa de interação social:

- **Categorização:** Organização em 7 categorias temáticas (como Motivação, Técnicas de Estudo e Bem-estar);
- **Massa de Dados:** A implementação contou com 6 tópicos simulados, contendo interações reais de curtidas (*likes*) e comentários;

- **Tipagem de Dados:** O sistema processou corretamente os diferentes níveis de interação, incluindo Tópicos, Respostas e Comentários;
- **Interface:** A interface **PostagemForum** foi validada com 4 registros de interação, demonstrando a fluidez da conversa no ambiente virtual.

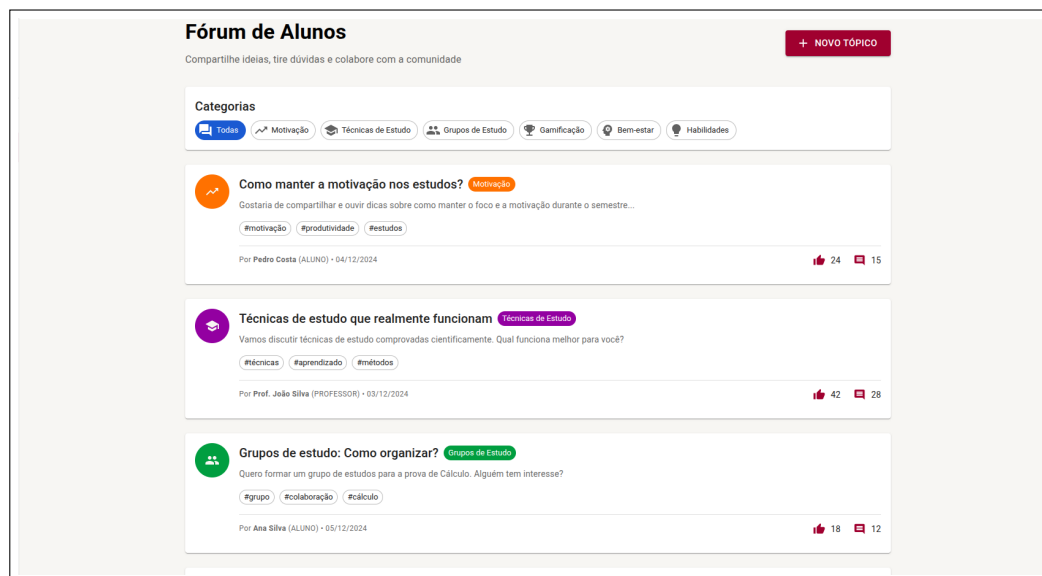


Figura 19 – UC08 - Sistema de Fórum (Perfil Aluno)

UC09 - Visualizar Progresso e Engajamento Pessoal

Descrição: O protótipo permitiu ao estudante visualizar suas próprias métricas de engajamento, promovendo a autorregulação da aprendizagem através da transparência de dados.

Resultado: A funcionalidade foi implementada com sucesso, extraindo dados em tempo real da coleção **ComportamentoEstudante**. O sistema apresentou ao aluno:

- **Frequência Semanal:** Gráfico de acessos que permite ao aluno monitorar sua própria constância no ambiente;
- **Duração de Sessão:** Média de tempo dedicado por acesso, indicando a profundidade da interação;
- **Score de Engajamento:** Um indicador sintético (variando de 0 a 100) que resume o nível de participação social e acadêmica do estudante.

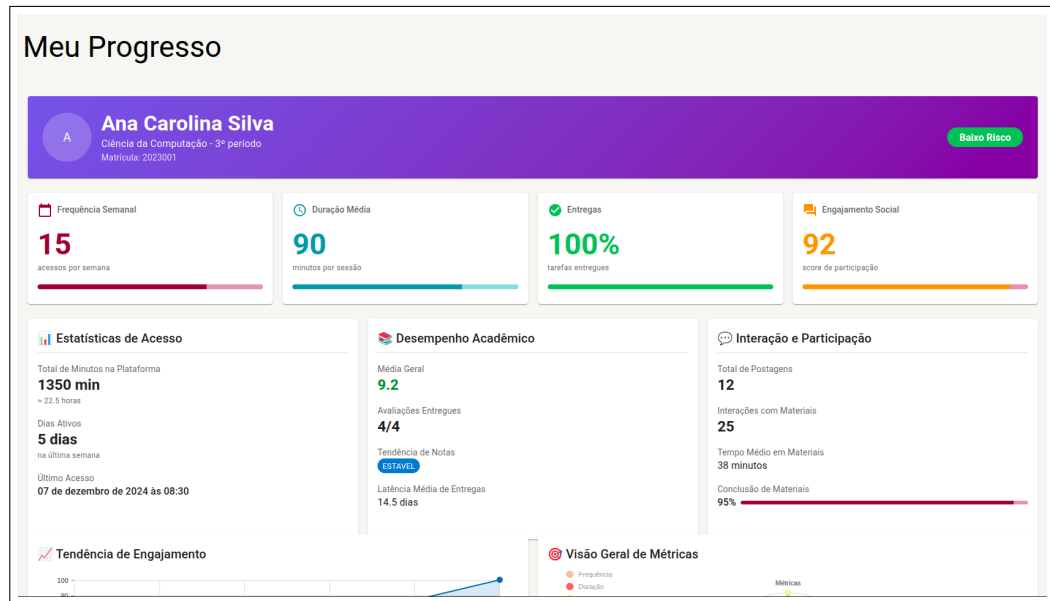


Figura 20 – UC09 - Monitoramento Pessoal (Perfil Aluno)

7.3.3 Casos de Uso - Autenticação e Controle de Acesso

UC10 - Realizar Autenticação no Sistema

Descrição: O protótipo permitiu ao usuário realizar o acesso seguro ao sistema através da validação de credenciais.

Resultado: A funcionalidade foi implementada com sucesso utilizando o serviço *Firebase Authentication*, garantindo um fluxo de acesso robusto:

- **Massa de Teste:** Foram validados 2 perfis de usuários pré-cadastrados, cobrindo os papéis de Professor e Aluno;
- **Segurança:** O sistema realizou a implementação correta de *e-mail* e senha, impedindo acessos não autorizados;
- **Persistência:** Implementação bem-sucedida do armazenamento de sessão (*localStorage*), permitindo que o estado de autenticação seja mantido durante a navegação.

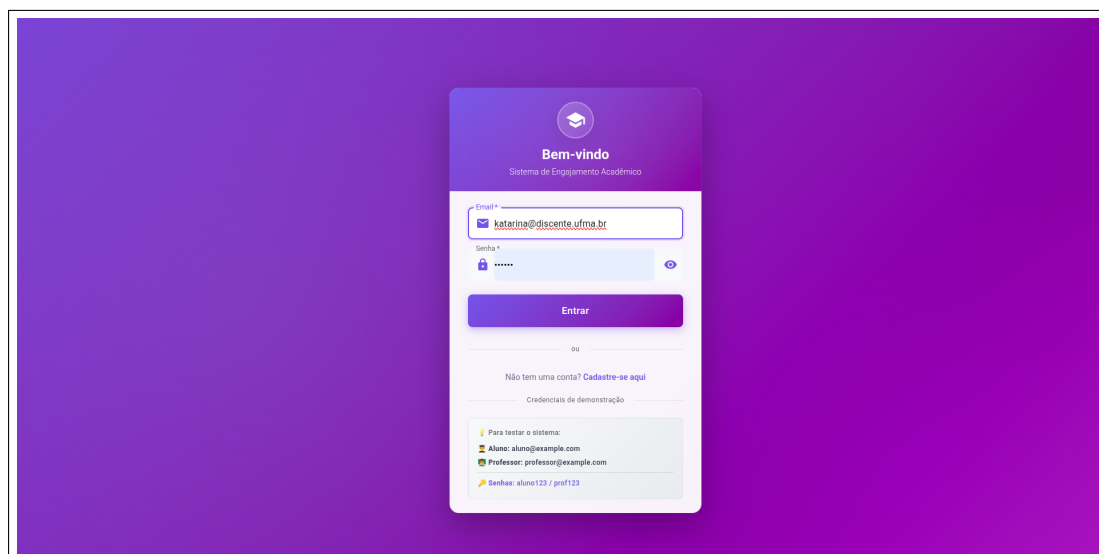


Figura 21 – UC10 - Tela de Login

UC11 - Realizar Cadastro

Descrição: O protótipo permitiu a criação de novas contas através de um formulário estruturado, conforme ilustrado.

Resultado: A funcionalidade foi implementada com sucesso, garantindo a integridade dos dados desde o primeiro acesso:

- **Coleta de Dados:** O formulário processou corretamente os campos de nome, *e-mail* e senha, incluindo a validação de confirmação de senha;
- **Definição de Perfil:** O sistema permitiu a escolha entre os papéis de Professor ou Aluno, direcionando o usuário para o fluxo de dados correspondente;
- **Vínculo Institucional:** Implementação do campo **instituicaoId**, garantindo que o novo registro seja corretamente associado à sua respectiva instituição no banco de dados.

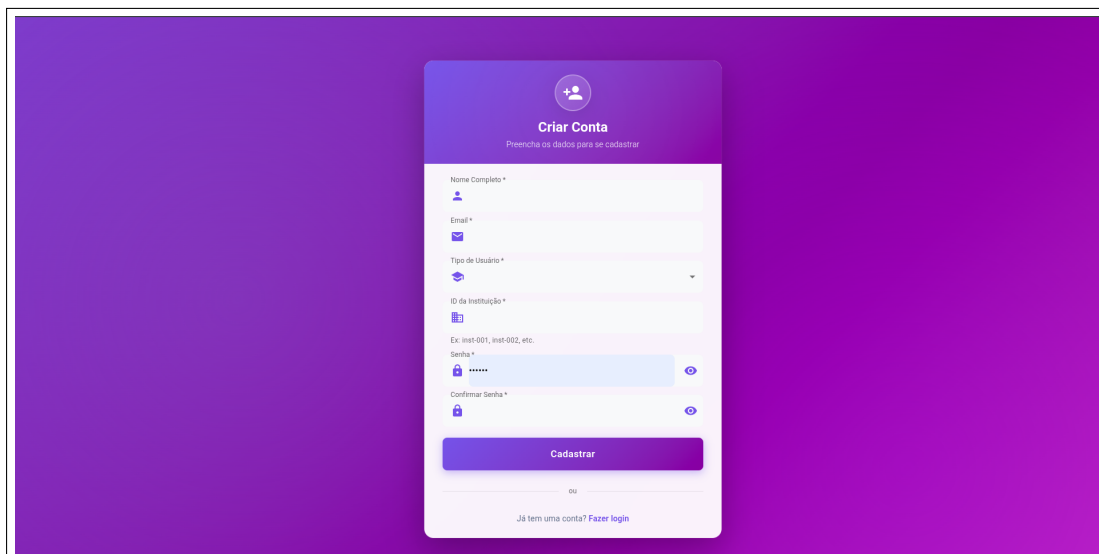


Figura 22 – UC11 - Tela de Cadastro

UC12 - Controlar Acesso e Permissões por Perfil

Descrição: O protótipo implementou a capacidade do sistema em restringir ou liberar funcionalidades de acordo com o perfil do usuário logado (Professor ou Aluno).

Resultado: A funcionalidade foi implementada com sucesso através de uma arquitetura de segurança robusta:

- **Gerenciamento de Estado:** Uso do *AuthContext* para verificar em tempo real o papel (*role*) do usuário e garantir a integridade das permissões;
- **Interface Dinâmica:** O menu lateral foi validado com sucesso, exibindo 9 itens de gestão para o perfil Professor (*Dashboard*, *Alertas*, *Modelagem*, etc.) e 3 itens de engajamento para o perfil Aluno (*Recursos*, *Fórum* e *Progresso*);
- **Segurança de Navegação:** Implementação de rotas protegidas que impedem o acesso manual via URL a páginas não autorizadas, redirecionando o usuário automaticamente para o seu ambiente correto.

7.3.4 Resumo de Cobertura dos Casos de Uso

Tabela 9 – Validação Funcional dos Casos de Uso Implementados

ID	Caso de Uso	Perfil	Resultado no Protótipo (Sucesso)
UC01	Visualizar Dashboard	Professor	Gráficos de risco em tempo real.
UC02	Gerenciar Alertas	Professor	Listagem, filtros e intervenções.
UC03	Analisar Predições ML	Professor	Interface de simulação preditiva.
UC04	Monitorar em Tempo Real	Professor	Logs de acesso e interação.
UC05	Visualizar Desempenho	Professor	Médias e latência de entregas.
UC06	Registrar Observações	Professor	Histórico de ações pedagógicas.
UC07	Acessar Recursos	Aluno	Vídeos, artigos e quizzes.
UC08	Participar de Fóruns	Aluno	Postagens e interações sociais.
UC09	Visualizar Progresso	Aluno	Score de engajamento pessoal.
UC10	Realizar Login	Todos	Autenticação via Firebase Auth.
UC11	Realizar Cadastro	Todos	Criação de perfis e vínculo inst.
UC12	Controle de Acesso	Sistema	Rotas protegidas e menu dinâmico.

A arquitetura de dados do sistema foi projetada para o *Firestore* (*Firebase*), um banco de dados *NoSQL* orientado a documentos que oferece escalabilidade e sincronização em tempo real. A subseção a seguir detalha a modelagem das coleções implementadas, que dão suporte funcional aos casos de uso apresentados.

7.4 Visão Geral da Arquitetura de Dados

O modelo de dados segue os princípios de desnormalização controlada, característicos de bancos *NoSQL*, priorizando performance de leitura e escalabilidade horizontal. A Figura 23 ilustra a organização das coleções principais.

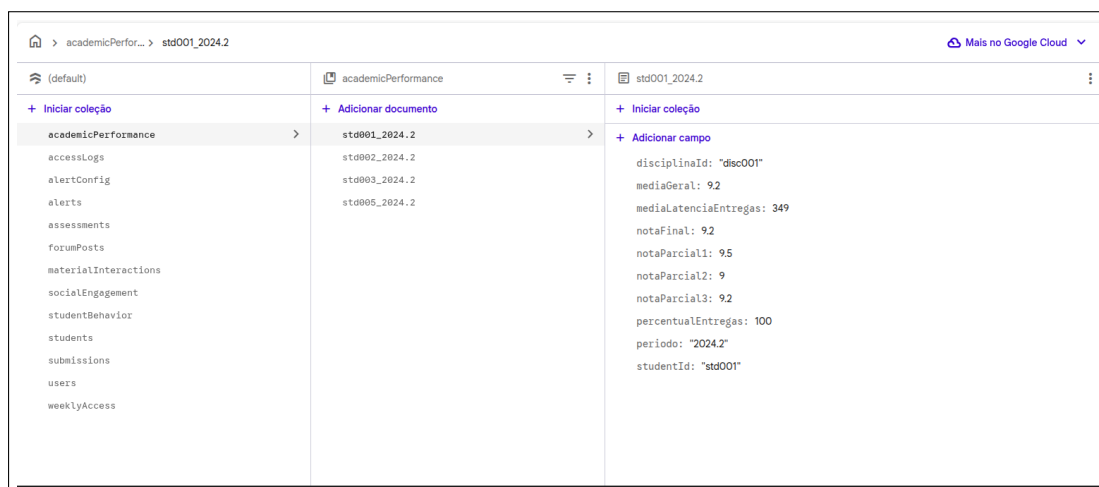


Figura 23 – Arquitetura de Coleções do Firestore

7.4.1 Coleção: *Users* (Usuários)

Caminho: /users/{userId}

Propósito: Armazenar dados de autenticação e perfil dos usuários do sistema.

```
1 {
2   "uid": "string",           // ID único do usuário
3   "nome": "string",        // Nome completo
4   "email": "string",       // Email (único)
5   "role": "PROFESSOR" | "ALUNO",
6   "instituicaoId": "string", // Referência à instituição
7   "dataCriacao": "Timestamp",
8   "ultimoAcesso": "Timestamp"
9 }
```

Listing 1 – Estrutura

Dados de Implementação: 8 usuários implementados para teste das regras de acesso (Professor e Aluno).

Índices Necessários:

- *email* (único)
- *instituicaoId* + *role* (composto)

7.4.2 Coleção: *Students* (Estudantes)

Caminho: /students/{studentId}

Propósito: Armazenar dados acadêmicos e perfil completo dos estudantes.

```
1 {
2   "studentId": "string",
3   "nome": "string",
4   "email": "string",
5   "matricula": "string",
6   "curso": "string",
7   "periodo": "number",
8   "turno": "MATUTINO" | "VESPERTINO" | "NOTURNO",
9   "anoIngresso": "number",
10  "instituicaoId": "string"
11 }
```

Listing 2 – Estrutura

Dados de Implementação: *Interface* PerfilEstudante com 8 registros simulados para teste de consistência dos dados demográficos e acadêmicos.

7.4.3 Coleção: *AccessLogs* (Logs de Acesso)

Caminho: /accessLogs/{logId}

Propósito: Registrar cada acesso do estudante à plataforma.

```
1 {
2   "logId": "string",
3   "studentId": "string",           // Referência ao estudante
4   "timestamp": "Timestamp",       // Data/hora do acesso
5   "duracaoSessao": "number",      // Minutos
6   "tipoDispositivo": "DESKTOP" | "MOBILE" | "TABLET",
7   "navegador": "string",
8   "ip": "string"
9 }
```

Listing 3 – Estrutura

Dados de Implementação: 7 registros em logsAcessoMock.

Consultas Típicas:

- Buscar acessos de um estudante: WHERE studentId == "std001"
- Acessos na última semana: WHERE timestamp >= hoje - 7 dias

Índices Necessários:

- studentId + *timestamp* (composto, descendente)

7.4.4 Coleção: *WeeklyAccess* (Frequência Semanal)

Caminho: /weeklyAccess/{accessId}

Propósito: Agregação semanal de acessos para otimizar consultas.

Dados de Implementação: 5 registros em frequenciaAcessoMock.

7.4.5 Coleção: *Assessments* (Avaliações)

Caminho: /assessments/{avaliacaoId}

Propósito: Armazenar informações sobre avaliações disponibilizadas.

Dados de Implementação: 4 avaliações em avaliacoesMock.

```

1 {
2   "studentId": "string",
3   "semana": "string",           // Formato: "2024-W49"
4   "totalAcessos": "number",
5   "totalMinutos": "number",
6   "mediaMinutosPorAcesso": "number",
7   "diasAtivos": "number"       // Dias com pelo menos 1 acesso
8 }

```

Listing 4 – Estrutura

```

1 {
2   "avaliacaoId": "string",
3   "disciplinaId": "string",
4   "titulo": "string",
5   "tipo": "PROVA" | "TRABALHO" | "QUIZ" | "PROJETO",
6   "dataDisponibilizacao": "Timestamp",
7   "dataPrazo": "Timestamp",
8   "notaMaxima": "number"
9 }

```

Listing 5 – Estrutura

7.4.6 Coleção: *Submissions* (Entregas)

Caminho: /submissions/{entregaId}

Propósito: Registrar entregas de avaliações pelos estudantes.

```

1 {
2   "entregaId": "string",
3   "avaliacaoId": "string",     // Referência à avaliação
4   "studentId": "string",       // Referência ao estudante
5   "dataEntrega": "Timestamp",
6   "notaObtida": "number",
7   "latenciaEntrega": "number", // Horas entre disponibilização e entrega
8   "statusEntrega": "NO_PRAZO" | "ATRASADA" | "NAO_ENTREGUE",
9   "tentativas": "number"
10 }

```

Listing 6 – Estrutura

Dados de Implementação: 5 entregas em `entregasAvaliacaoMock`.

Cálculo de Latência:

```
1 latenciaEntrega = (dataEntrega - dataDisponibilizacao) / 3600000
2 // Resultado em horas
```

7.4.7 Coleção: *AcademicPerformance* (Desempenho Acadêmico)

Caminho: /academicPerformance/{performanceId}

Propósito: Agregação de desempenho por disciplina e período.

```
1 {
2   "studentId": "string",
3   "disciplinaId": "string",
4   "periodo": "string",           // Formato: "2024.2"
5   "notaParcial1": "number",
6   "notaParcial2": "number",
7   "notaParcial3": "number",
8   "notaFinal": "number",
9   "mediaGeral": "number",
10  "percentualEntregas": "number", // 0-100
11  "mediaLatenciaEntregas": "number" // Horas
12 }
```

Listing 7 – Estrutura

Dados de Implementação: 4 registros em `desempenhoAcademicoMock`.

7.4.8 Coleção: *ForumPosts* (Postagens em Fórum)

Caminho: /forumPosts/{postagemId}

Propósito: Armazenar postagens, respostas e comentários em fóruns.

```
1 {
2   "postagemId": "string",
3   "forumId": "string",
4   "studentId": "string",
5   "timestamp": "Timestamp",
6   "conteudo": "string",
7   "tipo": "TOPICO" | "RESPOSTA" | "COMENTARIO",
8   "likes": "number",
9   "respostas": "number"
10 }
```

Listing 8 – Estrutura

Dados de Implementação: 4 postagens em `postagensForumMock`.

7.4.9 Coleção: *MaterialInteractions* (Interações com Materiais)

Caminho: `/materialInteractions/{interacaoId}`

Propósito: Registrar interações com materiais didáticos.

```

1  {
2  "interacaoId": "string",
3  "materialId": "string",
4  "studentId": "string",
5  "timestamp": "Timestamp",
6  "tipoMaterial": "VIDEO" | "PDF" | "SLIDE" | "ARTIGO" | "QUIZ",
7  "tempoVisualizacao": "number", // Minutos
8  "percentualConclusao": "number", // 0-100
9  "interacoes": "number"         // Cliques, pausas, etc
10 }
```

Listing 9 – Estrutura

Dados de Implementação: 5 interações em `interacoesMaterialMock`.

7.4.10 Coleção: *SocialEngagement* (Engajamento Social)

Caminho: `/socialEngagement/{engagementId}`

Propósito: Agregação de métricas sociais por período.

```

1  {
2  "studentId": "string",
3  "periodo": "string",
4  "totalPostagens": "number",
5  "totalRespostas": "number",
6  "totalLikesRecebidos": "number",
7  "totalLikesDados": "number",
8  "reputacao": "number"         // Score calculado 0-100
9  }
```

Listing 10 – Estrutura

Dados de Implementação: 4 registros em `engajamentoSocialMock`.

$$\text{reputacao} = (\text{totalPostagens} \cdot 2) + (\text{totalRespostas} \cdot 3) + (\text{totalLikesRecebidos} \cdot 1)$$

7.4.11 Coleção: *StudentBehavior* (Comportamento Completo)

Caminho: /studentBehavior/{behaviorId}

Propósito: Documento agregado com todas as métricas de um estudante.

```
1 {
2   "studentId": "string",
3   "periodoAnalise": "string",
4   "acessos": {
5     "frequenciaSemanal": "number",
6     "mediaDuracaoSessao": "number",
7     "totalMinutosPlataforma": "number",
8     "diasAtivos": "number",
9     "ultimoAcesso": "Timestamp"
10  },
11  "desempenho": {
12    "mediaGeral": "number",
13    "percentualEntregas": "number",
14    "mediaLatenciaEntregas": "number",
15    "totalAvaliacoes": "number",
16    "avaliacoesEntregues": "number",
17    "tendenciaNotas": "CRESCENTE" | "ESTAVEL" | "DECRESCENTE"
18  },
19  "interacao": {
20    "totalPostagens": "number",
21    "totalInteracoesMateriais": "number",
22    "tempoMedioMateriais": "number",
23    "percentualConclusaoMateriais": "number",
24    "engajamentoSocial": "number"
25  },
26  "classificacao": {
27    "nivelRisco": "BAIXO" | "MEDIO" | "ALTO" | "CRITICO",
28    "probabilidadeEvasao": "number", // 0-100
29    "probabilidadeReprovacao": "number", // 0-100
30    "fatoresRisco": ["string"],
31    "ultimaAtualizacao": "Timestamp"
32  }
33 }
```

Listing 11 – Estrutura

Dados de Implementação: 4 perfis completos em comportamentoEstudantesMock.

Atualização: Documento recalculado periodicamente (ex: diariamente) através de *Cloud Functions*.

7.4.12 Coleção: *Alerts* (Alertas)

Caminho: /alerts/{alertId}

Propósito: Armazenar histórico de notificações geradas para tutores.

Estrutura:

```
[language=JavaScript, caption=Documento Alert]
{
  "alertId": "string",
  "studentId": "string",          // Referência ao estudante
  "data_geracao": "Timestamp",
  "tipo": "AUSENCIA_PROLONGADA" | "QUEDA_DESEMPENHO",
  "status": "NAO_LIDO" | "TRATADO",
  "observacao_tutor": "string"   // Campo para registrar intervenção
}
```

```
1 {
2   "postagemId": "string",
3   "forumId": "string",
4   "studentId": "string",
5   "timestamp": "Timestamp",
6   "conteudo": "string",
7   "tipo": "TOPICO" | "RESPOSTA" | "COMENTARIO",
8   "likes": "number",
9   "respostas": "number"
10 }
```

Listing 12 – Estrutura

Dados de Implementação: 6 alertas implementados.

Gatilhos de Geração:

- AUSENCIA_PROLONGADA: ultimoAcesso > 7 dias
- QUEDA_DESEMPENHO: tendenciaNotas == "DECRESCENTE" AND mediaGeral < 6.0

7.4.13 Coleção: *AlertConfig* (Configuração de Alertas)

Caminho: /alertConfig/{configId}

Propósito: Armazenar *thresholds* configuráveis para geração de alertas.

```
1 {
2   "configId": "string",
3   "instituicaoId": "string",
4   "thresholds": {
5     "diasSemAcesso": "number",           // Padrão: 7
6     "quedaNotaPercentual": "number",    // Padrão: 20
7     "percentualEntregasMinimo": "number", // Padrão: 60
8     "frequenciaAcessoMinima": "number"  // Padrão: 5
9   },
10  "pesos": {
11    "acesso": "number",                  // Padrão: 0.4
12    "desempenho": "number",             // Padrão: 0.4
13    "interacao": "number"               // Padrão: 0.2
14  },
15  "ativo": "boolean",
16  "dataAtualizacao": "Timestamp"
17 }
```

Listing 13 – Estrutura

7.5 Relacionamentos e Consultas Otimizadas

Para viabilizar a recuperação eficiente de informações no banco de dados, foram definidas consultas recorrentes relacionadas ao monitoramento de engajamento e ao ciclo de vida dos alertas. As consultas a seguir exemplificam operações típicas aplicadas às coleções principais, considerando filtros por status, instituição, período de análise e ordenação por prioridade.

Consulta 1: Buscar todos os alertas não lidos de uma instituição

Esta consulta é utilizada pelo Dashboard para sinalizar ao gestor quais situações críticas ainda não receberam atenção pedagógica.

```
1 db.collection('alerts')
2   .where('status', '==', 'NAO_LIDO')
3   .where('instituicaoId', '==', 'inst-001')
4   .orderBy('data_geracao', 'desc')
5   .limit(50)
```

Listing 14 – Consulta 1: Buscar todos os alertas não lidos de uma instituição

Consulta 2: Obter comportamento completo de um estudante

Esta consulta é fundamental para a visão detalhada do aluno, permitindo que o sistema recupere todos os indicadores de engajamento (acesso, notas, fóruns e entregas) consolidados para um período letivo específico.

```

1 db.collection('studentBehavior')
2   .where('studentId', '==', 'std001')
3   .where('periodoAnalise', '==', '2024.2')
4   .get()

```

Listing 15 – Consulta 2: Obter comportamento completo de um estudante

Consulta 3: Listar estudantes em risco crítico

Esta consulta é utilizada para alimentar a visão prioritária do professor, filtrando apenas os alunos que atingiram o nível de risco "Crítico" e ordenando-os pelo maior indicador de risco de evasão, permitindo uma intervenção pedagógica imediata.

```

1 db.collection('studentBehavior')
2   .where('classificacao.nivelRisco', '==', 'CRITICO')
3   .where('periodoAnalise', '==', '2024.2')
4   .orderBy('classificacao.probabilidadeEvasao', 'desc')

```

Listing 16 – Consulta 3: Listar estudantes em risco crítico

7.5.1 Estratégia de Desnormalização

Para otimizar performance, alguns dados são intencionalmente duplicados:

Tabela 10 – Estratégia de Desnormalização

Dado	Localização Original	Duplicado Em
Nome do Estudante	/students	/alerts, /studentBehavior
Curso	/students	/studentBehavior
Título da Avaliação	/assessments	/submissions
Tipo de Material	/materials	/materialInteractions

Justificativa: Reduz necessidade de *joins* (inexistentes em *NoSQL*) e melhora performance de leitura.

7.6 Volumetria Estimada

Tabela 11 – Estimativa de Volumetria por Coleção

Coleção	Docs/Aluno/Sem	1000 Alunos/Sem	1000 Alunos/Ano
AccessLogs	15	15.000	780.000
WeeklyAccess	1	1.000	52.000
Submissions	2	2.000	104.000
ForumPosts	3	3.000	156.000
MaterialInteractions	10	10.000	520.000
StudentBehavior	1	1.000	52.000
SocialEngagement	1	1.000	52.000
AcademicPerformance	0,25	250	13.000
Alerts	0,5	500	26.000
Total (variável)	-	33.750	1.755.000
<i>Coleções fixas: Users (1.000), Students (1.000), Assessments (100/ano), AlertConfig (1)</i>			

Observação: *Firestore* suporta milhões de documentos sem degradação de performance, validando a escalabilidade da arquitetura proposta.

7.7 Validação dos Resultados Esperados

Retomando os objetivos iniciais, a Tabela 12 apresenta o status de cada resultado esperado:

Tabela 12 – Validação dos Resultados Esperados

Resultado Esperado	Status	Evidência
Validação Arquitetura <i>Serverless</i>	Alcançado	Protótipo com <i>Firebase</i> e <i>React</i>
Modelo de Dados Escalável	Alcançado	Implementação de 15+ interfaces <i>TypeScript</i> e estrutura <i>NoSQL</i>
Arquitetura de Referência	Alcançado	Arquitetura SPA documentada
Mitigação da Evasão	Parcial	Sistema de alertas implementado, validação com dados reais pendente
Intervenção Proativa	Alcançado	Módulo de alertas com registro de observações e histórico
Personalização em Escala	Alcançado	Sistema de recomendações de vídeos, fóruns e artigos

8 Considerações Finais

O presente trabalho dedicou-se a investigar e propor soluções tecnológicas para um dos desafios mais prementes do ensino superior contemporâneo: a evasão escolar e o desengajamento acadêmico, exacerbados pela expansão da modalidade a distância. Partindo da premissa de que a intervenção pedagógica eficaz depende da identificação precoce de estudantes em risco, desenvolveu-se a arquitetura de um protótipo funcional de monitoramento e lógica de classificação de risco fundamentado em tecnologias *web* modernas.

A pesquisa demonstrou que a utilização da pilha tecnológica composta por *React*, *TypeScript* e *Firebase* não representa apenas uma escolha de engenharia de *software*, mas uma estratégia viável para a democratização de ferramentas de *Learning Analytics*. A arquitetura *Serverless* adotada provou-se capaz de reduzir custos de infraestrutura e complexidade de manutenção, permitindo que instituições de ensino de menor porte possam implementar protótipos e sistemas de monitoramento robustos, escaláveis e com atualização em tempo real.

Em relação aos objetivos propostos, considera-se que foram atingidos satisfatoriamente. O mapeamento dos indicadores de engajamento permitiu a estruturação de um banco de dados *NoSQL* flexível, capaz de absorver a heterogeneidade dos dados educacionais. A implementação da lógica algorítmica de classificação de risco demonstrou ser uma alternativa transparente e eficaz para a sinalização de alertas, enquanto o desenvolvimento dos *dashboards* interativos atendeu à necessidade de transformar dados brutos em informação visual intuitiva para gestores, facilitando a tomada de decisão pedagógica baseada em evidências.

Conclui-se, portanto, que a tecnologia, quando aplicada com intencionalidade pedagógica, atua como um poderoso agente de retenção. O sistema proposto transcende a função de mero repositório de notas, posicionando-se como uma ferramenta ativa de gestão educacional que, ao automatizar a detecção de riscos, devolve ao professor o tempo precioso para exercer sua função primordial: o acolhimento e a orientação humana do estudante.

8.1 Limitações do Trabalho

Apesar dos resultados promissores obtidos com o desenvolvimento do protótipo e a implementação via dados sintéticos, este estudo apresenta limitações inerentes ao seu escopo acadêmico:

- **Implementação com Dados Sintéticos e Interface Estática:** Devido às restrições da Lei Geral de Proteção de Dados (LGPD) e à burocracia para acesso a bases de dados reais de instituições de ensino, a verificação funcional dos algoritmos limitou-se ao uso de *datasets* dados sintéticos (*mock data*). Além disso, o protótipo apresenta o perfil de uma estudante como um exemplo fixo para demonstrar a experiência de navegação, o que, embora verifique a *interface*, não reflete a dinâmica de uma base de usuários em larga escala.
- **Lógica de Classificação vs. *Machine Learning*:** O protótipo utiliza uma lógica algorítmica baseada em pesos e heurísticas pedagógicas. Embora eficaz para a demonstração de conceito e transparência, esta abordagem não possui a capacidade de autoajuste e aprendizado contínuo que um modelo de *Machine Learning* treinado com dados históricos reais poderia oferecer.
- **Janela Temporal:** O estudo focou na arquitetura e na detecção imediata de risco. Não foi realizado um estudo longitudinal para verificar se, após o recebimento do alerta e a intervenção do tutor, o aluno de fato permaneceu no curso a longo prazo.
- **Integração com AVAs Legados:** O protótipo opera como um sistema independente. A integração profunda com Ambientes Virtuais de Aprendizagem legados e monilíticos (como versões antigas do *Moodle*) pode apresentar desafios de interoperabilidade não cobertos detalhadamente nesta proposta.

8.2 Trabalhos Futuros

A arquitetura modular desenvolvida abre um leque de oportunidades para a continuidade da pesquisa e o aprimoramento da ferramenta. Como sugestões para trabalhos futuros, destacam-se:

1. **Avaliação de Usabilidade via SUS (*System Usability Scale*):** Realizar testes formais de usabilidade com um grupo de educadores e gestores, aplicando o questionário SUS para medir a eficácia, eficiência e satisfação do usuário com a *interface* proposta, verificando se o protótipo atende às necessidades reais do cotidiano pedagógico.
2. **Aprimoramento via Inteligência Artificial:** Evoluir a lógica algorítmica baseada em regras para modelos de Aprendizado de Máquina (*Machine Learning*). A utilização de dados históricos reais permitiria que o sistema aprendesse padrões de evasão não lineares e específicos de cada curso, aumentando a precisão de indicadores de risco ao longo do tempo.

3. **Expansão para Dispositivos Móveis:** Desenvolvimento de uma versão móvel (utilizando *React Native*) voltado para o estudante, permitindo o envio de notificações *push* de incentivo e criando um canal de comunicação direto e ágil com a tutoria.
4. **Gamificação do Engajamento:** Implementação de mecânicas de jogos (*badges*, *rankings* de participação, barras de progresso) para recompensar comportamentos positivos de estudo, utilizando os dados coletados pelo *Firebase* para fomentar a motivação intrínseca do aluno.
5. **Padrão LTI (Learning Tools Interoperability):** Adequação do sistema ao padrão global *Learning Tools Interoperability* (LTI), permitindo que o protótipo seja integrado nativamente a grandes plataformas de ensino (como *Moodle*, *Canvas* ou *Blackboard*) como uma ferramenta externa de análise.

Referências

- ALVES, R.; OUTROS, B. Mineração de dados educacionais no brasil: uma revisão sistemática. *Texto Livre: Linguagem e Tecnologia*, 2021. Citado na página 23.
- BAGGI, C. A. d. S.; LOPES, D. A. Evasão e avaliação institucional no ensino superior: uma discussão bibliográfica. *Avaliação: Revista da Avaliação da Educação Superior*, SciELO Brasil, v. 16, n. 2, p. 355–374, 2011. Acesso em: 07 dez. 2025. Disponível em: <<https://www.scielo.br/j/aval/a/RRGrQckrsd9CRGgKy4zkHXq/?format=pdf&lang=pt>>. Citado na página 15.
- BAKER, R. S.; YACEF, K. The state of educational data mining in 2009: A review and future visions. *Journal of educational data mining*, v. 1, n. 1, p. 3–17, 2009. Disponível em: <<https://jedm.educationaldatamining.org/index.php/JEDM/article/view/8>>. Citado na página 20.
- BANKS, A.; PORCELLO, E. *Learning React: Functional Web Development with React and Redux*. Sebastopol, CA: O’Reilly Media, 2017. Citado na página 21.
- BIERMAN, G.; ABADI, M.; TORGERSEN, M. Understanding typescript. *European Conference on Object-Oriented Programming*, Springer, p. 257–281, 2014. Disponível em: <https://link.springer.com/chapter/10.1007/978-3-662-44202-9_11>. Citado na página 21.
- CHERNY, B. *Programming TypeScript: Making Your JavaScript Applications Scale*. Sebastopol, CA: O’Reilly Media, 2019. Disponível em: <<https://www.oreilly.com/library/view/programming-typescript/9781492037644/>>. Citado na página 21.
- COSTA LUCAS E OLIVEIRA, F. Análise da interação em fóruns de discussão e sua relação com o desempenho. *Renote*, v. 17, n. 1, 2019. Citado 2 vezes nas páginas 23 e 24.
- FILHO, R. L. L. e. S.; MOTEJUNAS, P. R.; HIPÓLITO, O.; LOBO, M. B. d. C. A evasão no ensino superior brasileiro. *Cadernos de Pesquisa*, Fundação Carlos Chagas, v. 37, n. 132, p. 641–659, 2007. Citado 2 vezes nas páginas 16 e 20.
- FRANCISCATTO, R.; COSTA, H.; ARRUDA, A. Uma proposta para monitoramento da evasão e engajamento estudantil através de mineração de dados. *Anais dos Workshops do Congresso Brasileiro de Informática na Educação*, SBC, Brasília, 2019. Citado na página 15.
- FREDRICKS, J. A.; BLUMENFELD, P. C.; PARIS, A. H. School engagement: Potential of the concept, state of the evidence. *Review of educational research*, Sage Publications, v. 74, n. 1, p. 59–109, 2004. Disponível em: <<https://journals.sagepub.com/doi/abs/10.3102/00346543074001059>>. Citado na página 19.
- KUH, G. D. *High-impact educational practices: What they are, who has access to them, and why they matter*. Washington, DC: Association of American Colleges and Universities, 2008. Disponível em: <https://www.researchgate.net/publication/237242672_High-impact_educational_practices_What_they_are_who_has_access_to_them_and_why_they_matter>. Citado na página 19.

- KUH, G. D. The national survey of student engagement: Conceptual framework and overview of psychometric properties. *Indiana University Center for Postsecondary Research*, Bloomington, IN, 2009. Citado na página 15.
- MACEDO PEDRO E SOUZA, A. Desenvolvimento de um dashboard para acompanhamento de alunos em avas. In: *Anais do Simpósio Brasileiro de Informática na Educação (SBIE)*. [S.l.: s.n.], 2020. Citado 2 vezes nas páginas 23 e 24.
- MARTINS, F.; OUTROS, A. O engajamento do estudante de ensino superior como fator de permanência e sucesso. *Revista Brasileira de Política e Administração da Educação*, 2017. Nota: Verifique o título exato conforme sua fonte original, esta é uma entrada genérica baseada no seu texto. Citado na página 17.
- MORAN, J. M. Educação híbrida: um conceito-chave para a educação, hoje. In: BACICH, L.; NETO, A. T.; TREVISANI, F. de M. (Ed.). *Ensino híbrido: personalização e tecnologia na educação*. Porto Alegre: Penso, 2015. p. 27–45. Acesso em: 07 dez. 2025. Disponível em: <https://ntenatal.net/ead/pluginfile.php/9805/mod_data/content/879/LIVRO%20ENSINO%20HIBRIDO%20-%20LILIAN%20BACICH%20e%20OUTROS.pdf>. Citado na página 15.
- MORONEY, L. *The Definitive Guide to Firebase: Build Android and Web Apps with Google's Backend as a Service*. New York: Apress, 2017. Disponível em: <<https://link.springer.com/book/10.1007/978-1-4842-2943-9>>. Citado na página 22.
- PASCARELLA, E. T.; TERENCEZINI, P. T. *How college affects students: A third decade of research*. [S.l.]: Jossey-Bass San Francisco, 2005. v. 2. Citado na página 17.
- SIEMENS, G. Learning analytics: The emergence of a discipline. *American Behavioral Scientist*, v. 57, n. 10, p. 1380–1400, 2013. Disponível em: <<https://doi.org/10.1177/0002764213498851>>. Citado na página 20.
- SIHMAN, M.; BARIONI, M.; ISOTANI, S. O estado da arte da mineração de dados educacionais no brasil. In: *Anais dos Workshops do Congresso Brasileiro de Informática na Educação*. [S.l.: s.n.], 2016. v. 5, n. 1, p. 1012. Citado na página 16.
- SILVA JOÃO E SANTOS, M. Predição de evasão em cursos de ead utilizando técnicas de mineração de dados. *Revista Brasileira de Informática na Educação*, v. 26, n. 1, 2018. Citado 2 vezes nas páginas 23 e 24.
- TINTO, V. *Leaving college: Rethinking the causes and cures of student attrition*. University of Chicago Press, Chicago, 1993. Disponível em: <<https://archive.org/details/leavingcollegere0000tint/page/n7/mode/2up>>. Citado na página 19.
- TINTO, V. *Completing college: Rethinking institutional action*. University of Chicago Press, Chicago, 2012. Citado na página 15.
- VERBERT, K.; DUVAL, E.; KLERKX, J.; GOVAERTS, S.; SANTOS, J. L. Learning analytics dashboard applications. *American behavioral scientist*, Sage Publications, v. 57, n. 10, p. 1500–1509, 2013. Citado na página 20.
- WILLIAMS, A. *React: The ultimate beginner's guide to learn reactjs step by step*. Independently Published, 2019. Citado na página 21.