ÁREA TEMÁTICA: 15. Tecnologia, Inteligência Artificial e Transformação Digital em Administração.

CATEGORIA: ENANGRAD PLENO

INTELIGÊNCIA ARTIFICIAL COMO INFRAESTRUTURA DE DECISÃO NA GESTÃO DO BEM-ESTAR SOCIOEMOCIONAL DISCENTE

Resumo

As startups de tecnologia educacional (EdTechs) tornaram-se vetores de inovação nas escolas, mas a literatura sobre inteligência artificial (IA) na educação permanece concentrada em ensino, aprendizagem e automação. Paralelamente, as demandas de saúde mental escolar cresceram, e os comportamentos de retraimento e evitação, os mais preditivos de sofrimento psicológico, escapam tanto à observação docente quanto aos instrumentos estruturados, limitados em escala e frequência. O objetivo deste artigo é compreender como uma EdTech brasileira utiliza IA aplicada a textos livres para apoiar a identificação precoce de sinais socioemocionais em estudantes de escolas privadas. Adotou-se abordagem mista, qualitativa e quantitativa, na forma de estudo de caso único e longitudinal, organizado em três fases: i) viabilidade da coleta por texto livre em ambiente escolar real; ii) estruturação, coerência e auditabilidade dos sinais; e iii) acompanhamento de trajetórias individuais ao longo do tempo. A plataforma analisa produções textuais espontâneas em sete dimensões: ansiedade, depressão, isolamento, esgotamento acadêmico, bem-estar, autoestima e risco. Os resultados evidenciam a exequibilidade da coleta, com 69,2% de aproveitamento das submissões, padrões agregados coerentes, com associações em direções teoricamente plausíveis, e auditabilidade em 97,7% das análises, além da capacidade de captar trajetórias de melhora, estabilidade e deterioração com interpretação contextual. Conclui-se que a IA não resolve o problema da detecção socioemocional, mas o redefine, deslocando o gargalo da capacidade de identificar para a capacidade de acolher. O estudo contribui ao reposicionar a IA educacional de ferramenta pedagógica a infraestrutura de decisão gerencial e cuidado preventivo, condicionada à capacidade organizacional da escola.

Palavras-chave: Inovação digital; Inteligência artificial; Bem-estar socioemocional; EdTech; Gestão escolar.

Abstract

Educational technology startups (EdTechs) have become major drivers of innovation in schools, yet research on artificial intelligence (AI) in education remains focused on teaching, learning and automation. Meanwhile, mental health demands in schools have grown, and withdrawal and avoidance behaviours, which most strongly predict psychological distress, escape both teacher observation and structured instruments limited in scale and frequency. This article aims to understand how a Brazilian EdTech uses AI applied to free-text student writing to support the early identification of socioemotional signals in private school students. A mixed qualitative and quantitative approach was adopted through a single longitudinal case study organised in three phases: the feasibility of free-text collection in a real school setting; the structuring, coherence and auditability of the signals; and the longitudinal monitoring of individual trajectories. The platform analyses spontaneous student writing across seven dimensions: anxiety, depression, isolation, academic burnout, well-being, self-esteem and risk. Results show that collection is feasible, with 69.2% of

submissions yielding valid analyses, that aggregate patterns are coherent, with associations in theoretically plausible directions, and that textual evidence supported 97.7% of the analyses, while longitudinal reading captured trajectories of improvement, stability and deterioration with contextual interpretation. We conclude that AI does not solve the problem of socioemotional detection but redefines it, shifting the bottleneck from the capacity to identify towards the capacity to respond and care. The study repositions educational AI from a pedagogical tool to a managerial decision and preventive care infrastructure, conditioned on the organisational capacity of the school.

Keywords: Digital innovation; Artificial intelligence; Socioemotional well-being; EdTech; School management.

1 INTRODUÇÃO

A inovação promovida por startups de tecnologia educacional (*EdTechs*) tornou-se um dos principais vetores de transformação das instituições de ensino (Decuypere et al., 2025). A literatura que examina esse fenômeno consolidou-se em torno de três frentes principais: estudos sobre a expansão das *EdTechs* como agentes externos de inovação, que introduzem nas escolas novas formas de organização, coleta de dados e gestão (Komljenovic, 2022); a inteligência artificial (IA) aplicada à educação, chamada de *AI EdTech* (Shin et al., 2024), centrada na personalização da aprendizagem, na automação e na eficiência pedagógica por meio de tutores inteligentes, sistemas adaptativos e avaliação automatizada (Bhutoria, 2022; Cooper, 2023; Gulson & McDuie-Ra, 2026); e os trabalhos sobre liderança educacional como mediadora da inovação, responsável por converter o potencial tecnológico em capacidade organizacional efetiva (Campbell et al., 2026; Friesen et al., 2026). Em conjunto, essas frentes convergem para o entendimento de que a IA pode redefinir processos educacionais, contudo, a atenção da literatura permanece predominantemente concentrada no ensino e aprendizagem (Crawford et al., 2026).

Essa ênfase deixou sem resposta uma questão relevante: pode a capacidade analítica da IA ser reorientada do processo pedagógico para a gestão preventiva do bem-estar socioemocional dos estudantes? A questão é importante por três razões. Primeiro, as demandas de saúde mental no ambiente escolar cresceram de forma expressiva, com quadros de ansiedade, depressão, isolamento e *burnout* acadêmico tornando-se preocupações centrais da gestão educacional (Chong et al., 2025; Jagodics et al., 2023). Segundo, existe um problema estrutural de detecção: os comportamentos de evitação e retraimento social, que são os mais preditivos de problemas psicológicos, são sistematicamente subestimados pela observação docente, configurando um ponto cego no monitoramento escolar (Janschewski et al., 2024), enquanto os instrumentos estruturados disponíveis permanecem limitados em escala, frequência e capacidade de captar o sofrimento silencioso à medida que ele emerge (Algan & Huillery, 2025; Barrientos & Cruz, 2025). Terceiro, as literaturas capazes de gerar soluções para esse problema desenvolvem-se de forma paralela e pouco integrada: a pesquisa sobre IA educacional raramente trata do bem-estar socioemocional, e a pesquisa sobre saúde mental escolar raramente incorpora as possibilidades analíticas da IA (Crawford et al., 2026; Fullan et al., 2024; Fullan & Quinn, 2023), de modo que ainda se compreende pouco, empiricamente, como uma inovação dessa natureza opera e como se converte em valor para a gestão escolar.

O objetivo deste artigo é compreender como uma *EdTech* brasileira utiliza IA aplicada a textos livres para apoiar a identificação precoce de sinais socioemocionais

em estudantes de escolas privadas. Para responder a essa questão, conduzimos um estudo de caso único e longitudinal (Yin, 2018), estruturado em três fases de desenvolvimento. Este estudo oferece três contribuições teóricas. Primeiro, reposiciona a *AI EdTech* de ferramenta pedagógica a infraestrutura de decisão gerencial e de cuidado preventivo, estendendo o conceito a um objeto pouco explorado e evidenciando que o valor da IA na educação pode residir na ampliação da capacidade decisória da escola (Fullan et al., 2024; Shin et al., 2024). Segundo, caracteriza um novo tipo de dado socioemocional: o texto livre analisado por IA, auditável e longitudinal, que complementa, sem substituir, a observação humana e os instrumentos estruturados já consagrados na literatura (Algan & Huillery, 2025; Janschewski et al., 2024). Terceiro, a comparação entre as escolas revela que essa capacidade técnica não se converte automaticamente em valor: enquanto uma escola transformou o alerta em ação, outra não estruturou resposta formal, evidenciando que a efetividade da inovação depende da capacidade organizacional de acolhimento (Campbell et al., 2026; Decuypere et al., 2025). Além desta introdução, o artigo apresenta o referencial teórico, a metodologia, os resultados e sua discussão, seguidos das conclusões, limitações e sugestões de pesquisas futuras.

2 REFERENCIAL TEÓRICO

2.1 Inovação digital, EdTechs e IA em organizações educacionais

A inovação tornou-se via para ampliar eficiência e competitividade diante de desafios crescentemente complexos em instituições educacionais (Friesen et al., 2026; Gulson & McDuie-Ra, 2026), articulando liderança, inovação e IA para preparar a educação para o futuro (Fullan et al., 2024). Nesse processo, a liderança escolar opera como alavanca crítica e mediadora da inovação (Campbell et al., 2026). Contudo, a liderança escolar opera sob demandas contraditórias: fomentar a transformação e integrar tecnologias digitais, ao mesmo tempo que preserva práticas tradicionais de ensino em meio a déficits de infraestrutura (Friesen et al., 2026). A IA amplia esse repertório ao viabilizar personalização da aprendizagem, eficiência, redução de custos e decisão informada por dados, mas sua implementação ainda é limitada entre as instituições (Gulson & McDuie-Ra, 2026). Essa assimetria é central ao argumento deste estudo: escolas ainda possuem baixa capacidade instalada de monitoramento preventivo e de decisão baseada em evidências. Essa lacuna abre espaço para agentes externos de inovação (Komljenovic, 2022).

É nesse espaço que atuam as *EdTechs*: companhias que ofertam ao setor produtos e serviços inovadores (Decuypere et al., 2025). As *EdTechs* não introduzem apenas ferramentas, mas novas formas de organização, coleta de dados e gestão educacional, deslocando parte da capacidade de inovação para fora das fronteiras da escola (Decuypere et al., 2025). O avanço da IA intensificou esse processo, dando origem ao fenômeno designado *AI EdTech* (Shin et al., 2024). Uma tecnologia com potencial para aprimorar aprendizagem, avaliação e administração educacional por meio de tutores inteligentes, chatbots, learning analytics, sistemas adaptativos e avaliação automatizada (Cooper, 2023; Gulson & McDuie-Ra, 2026). A IA pode absorver a carga mecânica do trabalho docente e oferecer suporte, liberando os docentes para interações de maior valor pedagógico (Fullan et al., 2024; Fullan & Quinn, 2023). É esse deslocamento que interessa ao presente estudo. Para além do papel de ferramenta de ensino-aprendizagem e personalização (Bhutoria, 2022; Cooper, 2023), a IA pode operar como infraestrutura de apoio à decisão gerencial, possibilidade ainda pouco explorada, e que articula a inovação das *EdTechs* e a

capacidade analítica da IA a uma finalidade específica: a identificação precoce de fenômenos que, como o bem-estar socioemocional discente examinado na seção seguinte, escapam aos instrumentos convencionais de monitoramento da escola.

2.2 Bem-estar socioemocional e gestão preventiva em contexto escolar

A transformação digital examinada na seção anterior não se restringe à dimensão pedagógica: argumentamos que a mesma capacidade de individualização mobilizada para personalizar percursos e antecipar dificuldades (Bhutoria, 2022; Gulson & McDuie-Ra, 2026) pode ser direcionada à promoção do bem-estar socioemocional dos estudantes, deslocamento que acompanha a expansão das próprias metas educacionais, que passaram a incorporar o desenvolvimento socioemocional e o bem-estar subjetivo ao lado do desempenho acadêmico (Eckert et al., 2025). Essa agenda ganha urgência com o aumento das demandas de saúde mental no ambiente escolar (Jagodics et al., 2023): quadros de ansiedade, sintomas depressivos, isolamento social, *burnout* acadêmico e dificuldades de pertencimento tornaram-se preocupações centrais da gestão educacional (Chong et al., 2025).

Na gestão socioemocional preventiva, os comportamentos de evitação escolar, retraimento social e dificuldades de socialização possuem o maior poder preditivo para problemas psicológicos, significativamente superior ao do desempenho acadêmico ou desengajamento (Janschewski et al., 2024). Persiste, porém, uma tensão entre a relevância desses problemas e os limites dos meios disponíveis para enfrentá-los nas escolas. De um lado, a literatura é enfática quanto ao reconhecimento precoce de sinais como a evitação escolar e o retraimento social (Janschewski et al., 2024; Pastore et al., 2025); de outro, os meios predominantes permanecem ancorados na observação humana, que subestima sistematicamente os quadros internalizantes, ou em formulários estruturados e instrumentos clínicos fechados (Algan & Huillery, 2025; Barrientos & Cruz, 2025): abordagens valiosas, porém limitadas em escala, frequência e capacidade de captar o sofrimento silencioso. É nessa lacuna que o presente estudo se posiciona. Existe pouca evidência sobre a IA como apoio à gestão preventiva do bem-estar socioemocional discente (Fullan et al., 2024; Gulson & McDuie-Ra, 2026).

3 METODOLOGIA

Esta pesquisa é exploratória e descritiva, de natureza qualitativa-quantitativa (mista), conduzida sob a forma de um estudo de caso único e longitudinal (Yin, 2018) em uma *startup* brasileira de tecnologia educacional (*EdTech*) que desenvolveu uma plataforma de análise socioemocional assistida por inteligência artificial (IA) aplicada a textos livres produzidos por estudantes da educação básica. A operação da plataforma foi reconstituída em três fases de desenvolvimento e aplicação, cada uma correspondente a uma base de dados e a um período distinto de coleta. As fases não constituem replicações de um mesmo experimento, mas estágios evolutivos do desenvolvimento e de sua aplicação, com amostras parcialmente sobrepostas e crescentes e com instrumentação progressivamente mais rica.

3.1 Objeto de estudo: a plataforma de IA para análise socioemocional

A plataforma processa textos curtos redigidos por alunos em resposta a perguntas, sem atribuição de nota e com regra explícita de espaço seguro e de proibição de uso de IA pelo aluno na produção do texto. O motor analítico é baseado em modelo de linguagem de grande porte, configurado por meio de instruções estruturadas e critérios semânticos desenvolvidos pela *EdTech*. Cada texto submetido

é processado pelo motor de análise da plataforma que classifica a produção textual em sete dimensões socioemocionais, organizadas em três famílias funcionais: dimensões associadas a sinais de sofrimento socioemocional (ansiedade, depressão, isolamento e *burnout* acadêmico); dimensões protetivas, associadas a recursos psicológicos (bem-estar e autoestima); e uma dimensão crítica de sinalização de atenção imediata (risco).

A operacionalização das dimensões socioemocionais analisadas pela plataforma ancora-se em instrumentos consagrados e validados internacionalmente na literatura de saúde mental: o bem-estar subjetivo, a partir do WHO-5 Well-Being Index (Topp et al., 2015); a ansiedade, a partir da Generalized Anxiety Disorder Scale (GAD-7; Spitzer et al., 2006); a depressão, a partir do Patient Health Questionnaire (PHQ-9; Kroenke et al., 2001); a autoestima, a partir da Rosenberg Self-Esteem Scale (Rosenberg, 1965); o *burnout* acadêmico, a partir do Maslach Burnout Inventory — Student Survey (MBI-SS; Schaufeli et al., 2002); e o isolamento/solidão, a partir da UCLA Loneliness Scale em sua versão reduzida (UCLA-3; Hughes et al., 2004). A dimensão crítica de risco é tratada separadamente das seis dimensões contínuas, com critérios próprios de sinalização de atenção imediata incorporados às instruções do modelo. A forma como essas delimitações são operacionalizadas no motor de análise, incluindo instruções, critérios semânticos e regras de composição dos escores, constitui propriedade intelectual da organização e não é divulgada. O desenho preserva a aderência conceitual das dimensões a construtos científicos consolidados, mantendo a natureza não intrusiva da coleta por texto livre.

Para cada dimensão, a IA produz um nível ordinal em cinco categorias (mínimo, baixo, moderado, alto ou crítico), um escore numérico contínuo de 0 a 100 e um indicador interno de confiança. A análise consolidada de cada texto gera, adicionalmente, um nível de risco geral em quatro categorias (baixo, moderado, alto ou crítico), derivado do conjunto das dimensões e não do escore isolado da dimensão de risco; um escore global agregado de 0 a 100, em que valores maiores indicam maior necessidade de atenção; listas estruturadas de pontos de atenção e de fatores protetivos; e um resumo interpretativo em prosa destinado ao uso pedagógico. Para garantir transparência das classificações da IA para cada escore atribuído, o sistema seleciona trechos do próprio texto do aluno que sustentaram o julgamento e a produção daquele escore, permitindo auditoria humana caso a caso.

3.2 Contexto, participantes e procedimentos éticos

A *EdTech* constitui a unidade de análise, enquanto as escolas e as trajetórias individuais dos estudantes funcionam como unidades incorporadas de observação. O campo empírico compreendeu instituições privadas de educação básica situadas na capital paulista e no interior de Minas Gerais, envolvendo estudantes do Ensino Fundamental II e do Ensino Médio, com idades aproximadas entre 11 e 18 anos. As três bases correspondem a diferentes períodos de expansão da plataforma. Por essa razão, seus tamanhos foram analisados separadamente e não somados em um total único. A coleta original ocorreu mediante procedimentos de consentimento adotados pelas instituições junto aos responsáveis. Nessa pesquisa, foram utilizados exclusivamente dados secundários previamente desidentificados pela organização. Estudantes e instituições foram apresentadas por códigos, e localidades e demais informações contextuais foram generalizadas para reduzir o risco de reidentificação. O tratamento dos dados observou os princípios de finalidade, adequação, necessidade, segurança e prevenção previstos na Lei Geral de Proteção de Dados —

LGPD (Lei nº 13.709/2018), com atenção especial à proteção de crianças e adolescentes. Os escores e níveis produzidos foram analisados exclusivamente como instrumentos de triagem e apoio à escuta pedagógica, não constituindo diagnóstico nem substituindo avaliação clínica.

3.3 Procedimentos de coleta de dados

Os dados utilizados são de natureza secundária e provêm de duas fontes complementares: três bases de produção da plataforma, correspondentes às fases 1, 2 e 3, e documentação interna fornecida pela organização. As bases foram extraídas diretamente do ambiente de produção em modo somente leitura, sem alteração nos registros originais. Os documentos complementares incluíram relatórios técnicos das fases de desenvolvimento e aplicação, registros qualitativos de campo e indicadores operacionais e de aceitação institucional. A produção textual foi coletada por formulários eletrônicos com enunciados breves: quinzenalmente, em cinco ciclos, na Fase 1, e mensalmente nas Fases 2 e 3. A Tabela 1 sintetiza a volumetria de dados por fase.

Tabela 1
Volumetria de dados por fase

Indicador	Fase 1	Fase 2	Fase 3
Período de coleta	set.–nov. 2025	fev.–abr. 2026	mar.–jun. 2026
Alunos com análise	52	99	155
Submissões textuais coletadas	169	482	801
Análises individuais produzidas	117	342	801
Casos de risco alto/crítico	2	20	23
Construtos avaliados por análise	7	7	7

Nota. Elaborado pelos autores a partir das bases fornecidas pela organização.

3.4 Procedimentos de tratamento e análise dos dados

Na Fase 1, realizou-se análise descritiva da viabilidade operacional e da qualidade dos textos, complementada por análise de conteúdo dos registros de campo sobre adesão, aceitação institucional e fontes de ruído. Na Fase 2, foram calculadas estatísticas descritivas dos escores das sete dimensões, examinadas as correlações de Pearson, a distribuição dos níveis de risco e a cobertura das evidências textuais. O indicador de confiança foi interpretado como medida da suficiência das evidências, e as correlações, de forma exploratória, sem pressupor independência entre observações. Na Fase 3, seis casos foram selecionados intencionalmente para representar diferentes faixas etárias e trajetórias de melhora, estabilidade e deterioração. Para cada caso, analisaram-se longitudinalmente os escores, os resumos interpretativos e as evidências textuais, buscando identificar padrões de mudança, permanência e interpretação contextual.

3.5 Critérios de qualidade e rigor da pesquisa

O rigor da investigação foi assegurado pela triangulação entre bases de produção, documentação interna, escores e resumos interpretativos (Yin, 2018). A

articulação entre a viabilidade operacional da Fase 1, os padrões quantitativos e a coerência interna da Fase 2 e a análise longitudinal da Fase 3 permitiu uma leitura complementar do fenômeno e reforçou a validade do estudo de caso. A validade de construto foi favorecida pela cadeia explícita entre dados e interpretações e pela inspeção dos trechos textuais associados às classificações da IA. A confiabilidade foi reforçada pela extração dos dados em modo somente leitura, pela preservação dos textos originais e pela documentação dos critérios de seleção e análise. A validade externa é analítica, e não estatística, e a ausência de validação clínica externa é reconhecida entre as limitações do estudo.

4 RESULTADOS

4.1 Fase 1 — Viabilidade operacional da coleta por texto livre

A primeira fase examinou a exequibilidade da coleta de produções textuais espontâneas em ambiente escolar real e a qualidade do material gerado para análise automatizada. O piloto envolveu duas escolas privadas, somando 52 alunos do 8º e 9º anos do Ensino Fundamental e 169 submissões textuais ao longo de cinco ciclos de coleta. Das 169 respostas coletadas, 117 (69,2%) resultaram em análise válida, enquanto 52 (30,8%) não puderam ser processadas por insuficiência ou inadequação do texto. Esse índice evidencia que a coleta por texto livre, embora exequível, é sensível à qualidade das respostas e requer mecanismos de controle da qualidade das entradas. As invalidações decorreram de textos insuficientemente desenvolvidos, preenchimentos inválidos e respostas fora do contexto da atividade. A Tabela 2 sintetiza o aproveitamento das submissões nas duas instituições participantes.

Tabela 2
Coleta e aproveitamento por escola na Fase 1 (piloto)

Escola	Alunos	Respostas	Análises válidas	Invalidações	Casos críticos
Escola A	34	151	99 (65,6%)	52 (34,4%)	1
Escola B	18	18	18 (100%)	0 (0%)	1
Total	52	169	117 (69,2%)	52 (30,8%)	2

Nota. Elaborado pelos autores a partir da base da Fase 1.

Os registros operacionais indicaram participação média de aproximadamente 60% dos alunos elegíveis por ciclo, com oscilação entre as rodadas e menor adesão às atividades de texto do que aos formulários estruturados. Assim, além da qualidade das entradas, a sustentação do engajamento ao longo do tempo emergiu como um dos principais desafios operacionais. A fase 1 também revelou que a Escola A, que já dispunha de uma cultura consolidada de cuidado com os alunos, considerou o instrumento rápido e intuitivo e adotou providências diante do caso crítico identificado. Em contraste, a Escola B manifestou apreensão ao receber uma sinalização de risco e não implementou plano de ação formal durante o período. Em síntese, a Fase 1 sustentou a exequibilidade da coleta por texto livre e revelou três desafios de implementação: qualidade heterogênea das entradas, adesão oscilante e capacidade institucional de resposta.

4.2 Fase 2 — Consolidação dos construtos e padrões quantitativos

A segunda fase constitui o núcleo quantitativo-descritivo do estudo. A base compreende 342 análises de 99 alunos de duas instituições: uma de Ensino Médio e outra de Ensino Fundamental II, além de 191 sumários mensais e 20 alertas de acompanhamento pedagógico. Esse volume permitiu consolidar três conjuntos de resultados quantitativos: a distribuição dos construtos socioemocionais (4.2.1), a distribuição dos níveis de risco por escola e série (4.2.2) e as associações entre as dimensões articuladas à auditabilidade das classificações (4.2.3).

4.2.1 Distribuição dos construtos socioemocionais

A Tabela 3 apresenta as estatísticas descritivas dos sete construtos sobre as 342 análises, incluindo média, desvio-padrão e confiança média dos escores, bem como a proporção de análises com escore igual ou superior a 50 e a 70.

Tabela 3
Distribuição dos escores por construto socioemocional

Construto	Média	Desvio-padrão	Confiança média	% escore ≥ 50	% escore ≥ 70
Ansiedade	21,8	17,0	31,1	9,9	0,9
Depressão	13,4	10,6	22,4	2,6	0,3
Isolamento	16,6	11,6	25,4	3,5	0,3
Bem-estar	52,8	19,4	58,2	65,5	17,8
Autoestima	53,2	14,8	58,1	68,7	7,6
Burnout	15,3	12,9	25,0	4,1	0,0
Risco	0,1	1,6	70,0	0,0	0,0

Nota. Elaborado pelos autores a partir da base da Fase 2.

As dimensões protetivas apresentam os maiores escores médios: bem-estar (52,8) e autoestima (53,2), com 65,5% e 68,7% das análises, respectivamente, acima de 50. As dimensões de sofrimento (ansiedade, depressão, isolamento e *burnout*) apresentaram médias inferiores, mas com uma cauda minoritária de escores elevados; a ansiedade, por exemplo, atingiu escore igual ou superior a 50 em 9,9% das análises. A dimensão de risco apresentou média próxima de zero (0,1) e confiança média elevada (70,0), padrão consistente com uma lógica restritiva de sinalização dessa dimensão crítica.

4.2.2 Distribuição de risco por escola e série

A estratificação dos níveis de risco por escola e série revela variação substancial entre os subgrupos, conforme a Tabela 4. O resultado mais expressivo é a maior proporção de análises classificadas como risco alto no grupo do 3º ano do Ensino Médio da Escola 1: 17 de 229 análises (7,4%), ante proporções entre 0% e 4% nos grupos do Ensino Fundamental da Escola 2. Como série e instituição não variam independentemente na base, o resultado deve ser interpretado como diferença entre subgrupos, e não como efeito isolado da etapa escolar.

Tabela 4
Distribuição dos níveis de risco por escola e série na Fase 2

Escola (segmento)	Série	n	Baixo	Moderado	Alto
Escola 1	3º EM	229	168 (73%)	44 (19%)	17 (7%)
Escola 2	6º ano	52	44 (85%)	6 (12%)	2 (4%)
Escola 2	7º ano	28	24 (86%)	3 (11%)	1 (4%)
Escola 2	8º ano	23	19 (83%)	4 (17%)	0 (0%)
Escola 2	9º ano	10	9 (90%)	1 (10%)	0 (0%)
Total	**—**	**342**	**264 (77%)**	**58 (17%)**	**20 (6%)**

Nota. Elaborado pelos autores a partir da base da Fase 2.

Esse resultado tem valor particular para a gestão escolar, pois evidencia que a análise textual assistida por IA pode agregar sinais individuais e tornar visíveis diferenças entre subgrupos. No caso examinado, a maior proporção de análises classificadas como risco alto ocorreu no grupo do 3º ano do Ensino Médio, o que pode ter relação com a pressão característica desse momento: proximidade do vestibular, decisões de carreira e separação iminente do grupo escolar. Embora a base não permita separar efeitos de série e instituição nem atribuir causas ao padrão observado, essa estratificação ilustra como a informação socioemocional pode subsidiar a priorização de atenção e de recursos de acolhimento.

4.2.3 Padrões de associação e auditabilidade das classificações

A Tabela 5 apresenta as correlações de Pearson entre as sete dimensões nas 342 análises. Como algumas observações pertencem ao mesmo estudante, os coeficientes são interpretados exclusivamente de forma descritiva e exploratória, e não como evidência de validação psicométrica.

Tabela 5
Matriz de correlações de Pearson entre as dimensões

	Ans.	Dep.	Isol.	B-estar	Autoest.	Burn.	Risco
Ansiedade	1,00	0,41	0,17	-0,28	-0,24	0,33	0,06
Depressão	0,41	1,00	0,58	-0,40	-0,37	0,30	0,24
Isolamento	0,17	0,58	1,00	-0,36	-0,31	0,18	0,08
Bem-estar	-0,28	-0,40	-0,36	1,00	0,82	-0,23	-0,12
Autoestima	-0,24	-0,37	-0,31	0,82	1,00	-0,12	-0,12
Burnout	0,33	0,30	0,18	-0,23	-0,12	1,00	-0,01
Risco	0,06	0,24	0,08	-0,12	-0,12	-0,01	1,00

Nota. Elaborado pelos autores a partir da base da Fase 2.

Três padrões merecem destaque. A associação mais forte ocorreu entre bem-estar e autoestima (r = 0,82), indicando elevada proximidade entre as duas dimensões protetivas. Entre as dimensões de sofrimento, as maiores correlações foram observadas entre depressão e isolamento (r = 0,58) e entre ansiedade e depressão (r = 0,41). As dimensões protetivas correlacionaram-se negativamente com as

dimensões de sofrimento. Em conjunto, as associações apresentam direções teoricamente plausíveis e fornecem evidências exploratórias de coerência interna.

A auditabilidade constitui uma segunda propriedade relevante da Fase 2. Foram extraídos 2.622 trechos dos textos dos estudantes ao longo das 342 análises, com evidência textual associada em 97,7% delas e média de 7,67 trechos por análise. Assim, na quase totalidade das análises, o sistema preserva fragmentos do texto que permitem ao usuário rastrear o fundamento textual das classificações produzidas e submetê-las à inspeção humana. Em síntese, a Fase 2 evidencia a passagem do piloto operacional para uma camada analítica capaz de estruturar os textos em dimensões comparáveis e revelar padrões agregados entre subgrupos. A Fase 3 aprofunda essa capacidade no nível individual e longitudinal.

4.3 Fase 3 — Trajetórias longitudinais e interpretação contextual da IA

A Fase 3 examina a utilidade interpretativa do sistema para o acompanhamento longitudinal. A base reuniu 801 análises de 155 alunos, das quais 87,0% foram classificadas como risco baixo, 10,1% como moderado, 2,7% como alto e 0,1% como crítico. Sobre essa base, foram selecionados intencionalmente seis casos que abrangem cinco faixas etárias e trajetórias de melhora, estabilidade e deterioração (Tabela 6). O objetivo desta seção não é narrar cada caso, mas extrair quatro padrões transversais que evidenciam o que a análise por texto livre assistida por IA torna possível no acompanhamento socioemocional.

Tabela 6

Síntese dos seis casos longitudinais analisados na Fase 3

Caso	Idade	Análises	Trajetória observada	Padrão analítico ilustrado
A	17–18 anos	8	Risco alto, com ansiedade e isolamento para risco baixo, com bem-estar elevado	Mudança longitudinal de risco alto para baixo.
B	13–14 anos	8	Estresse familiar persistente para sinais de bem-estar e curiosidade intelectual	Interpretação contextual para além de palavras isoladas.
C	14–15 anos	8	Ansiedade de rejeição e isolamento para contentamento e autonomia	Contextualização do retraimento sem escalada automática do risco.
D	11–12 anos	4	Supressão do medo em contexto de saúde para indicadores protetivos	Interpretação contextual de supressão emocional.
E	12–13 anos	8	Baixo risco estável, com ansiedade leve no início	Estabilidade longitudinal com manutenção de baixo risco.
F	17–18 anos	6	Bem-estar elevado para sinal moderado de depressão e idealização do passado	Deterioração longitudinal e interpretação contextual.

Nota. Elaborado pelos autores a partir da base da Fase 3.

A leitura longitudinal dos resultados permite verificar a evolução do aluno ao longo do tempo e considerar a sequência de análises, e não apenas submissões isoladas. O Caso A ilustra esse ponto de forma clara: a primeira submissão apresentou risco alto, com escore global 49, ansiedade e isolamento elevados, expressos por uma metáfora de aprisionamento e ruminação; ao longo de três meses o quadro oscilou,

inclusive com um novo pico de isolamento em um momento intermediário, e estabilizou-se em bem-estar alto, com escore global 17, na última coleta. O Caso F percorre o sentido inverso: parte de uma das análises com maior escore de bem-estar (bem-estar 74) e encerra o período com sinal de depressão moderada. Em ambos, uma triagem baseada em uma única submissão teria produzido leitura parcial da trajetória. A organização longitudinal das análises permite à escola visualizar a direção do movimento: melhora, estabilidade ou deterioração.

Os casos também evidenciam uma distinção: um texto sem palavras negativas não é automaticamente tratado como evidência de saúde emocional. O sistema diferencia a ausência de sinal de sofrimento da presença efetiva de recursos protetivos. Essa propriedade manifesta-se de duas formas nos dados. Na primeira, quando o aluno produz um texto positivo e substantivo, o sistema reconhece elementos textuais compatíveis com fatores protetivos como pertencimento, valores pró-sociais e engajamento, em vez de simplesmente zerar os indicadores por ausência de termos de risco; foi o que ocorreu na última coleta do Caso A, em que o texto sobre uma disciplina idealizada foi interpretado pelo sistema como indicativo de bem-estar, e não como redação neutra. Na segunda, conforme já evidenciado na Fase 2, a confiança da classificação tende a ser baixa justamente quando o texto é curto ou pouco revelador, sinalizando ausência de informação suficiente e não bem-estar consolidado. Essa distinção é importante para o uso pedagógico: evita que o silêncio do aluno seja interpretado, por omissão, como sinal de que está bem.

4.3.1 A interpretação vai além de palavras-chave isoladas

Um padrão distintivo observado nos casos é a consideração do contexto semântico para além da ocorrência de palavras isoladas. Alguns casos sintetizam essa capacidade. No Caso B, a repetição enfática da palavra “milhares”, que um sistema baseado apenas em padrões lexicais poderia confundir com agitação ansiosa, foi interpretada como expressão de maravilhamento e entusiasmo intelectual, a partir do contexto narrativo do texto. No Caso F, a idealização do passado, descrita sem nenhuma palavra de risco explícita, foi lida como sinal de atenção (depressão moderada), porque o sistema interpretou o trecho como compatível com sinais de desesperança leve e ausência de referências positivas ao presente, e não um termo de alerta isolado. O Caso D acrescenta uma camada: mais do que registrar o medo nomeado diante de um tratamento de saúde, o sistema identificou o padrão de supressão emocional, a criança esconde o próprio medo para não preocupar os outros, exatamente o tipo de sinal que tende a passar despercebido em observação direta de sala de aula. Esses exemplos indicam um raciocínio que opera sobre o sentido do texto, e não apenas sobre sua superfície lexical.

4.3.2 Manifestações isoladas não produzem escalada automática do risco

O quarto padrão diz respeito ao equilíbrio entre detectar sofrimento e evitar o excesso de alarmes. É relevante analisar manifestações comuns da adolescência, como cansaço, timidez ou oscilação de humor, para não gerar sinalização indevida de risco. O Caso E foi incluído para contraste: trata-se de um aluno com perfil saudável do início ao fim, em que o sistema manteve o risco baixo e não transformou a timidez declarada pelo próprio estudante em alarme. No Caso C, a inibição social associada a histórico de *bullying* foi lida como isolamento autoprotetor, com indicação de necessidade de ambientes seguros de expressão, sem o disparo de um alerta de risco que não se justificaria. Esse comportamento é coerente com a postura conservadora

na sinalização de risco crítico observada quantitativamente na Fase 2 e é condição prática de viabilidade: uma ferramenta que gerasse alertas excessivos ou potencialmente indevidos seria rapidamente inviabilizada no uso escolar.

5 DISCUSSÃO

A principal contribuição teórica deste estudo consiste em aproximar dois corpos de literatura que vinham se desenvolvendo de forma pouco integrada. De um lado, a literatura sobre *EdTechs* e IA educacional consolidou-se em torno da personalização da aprendizagem, da automação e da eficiência pedagógica (Bhutoria, 2022; Cooper, 2023; Gulson & McDuie-Ra, 2026); de outro, a literatura sobre saúde mental e bem-estar escolar enfatizou a identificação precoce do sofrimento, mas permaneceu ancorada na observação humana e em instrumentos estruturados (Janschewski et al., 2024; Algan & Huillery, 2025). Ao examinar uma *EdTech* que aplica IA a textos livres para fins de gestão preventiva do bem-estar, o estudo constitui um ponto de articulação entre essas duas agendas, oferecendo evidências empíricas de que a capacidade analítica frequentemente associada à IA pode ser reorientada para a triagem socioemocional. Dessa articulação derivam três contribuições centrais.

A primeira contribuição consiste no reposicionamento funcional da IA no ambiente escolar: de ferramenta pedagógica a infraestrutura de decisão gerencial e de cuidado preventivo. A literatura posiciona a IA como recurso voltado ao processo de ensino-aprendizagem (Cooper, 2023; Shin et al., 2024). Os resultados sustentam um deslocamento desse papel: a IA opera, no caso estudado, como uma infraestrutura de apoio à decisão gerencial, que converte produções textuais espontâneas em sinais organizados e acionáveis pela gestão, operando como camada informacional que amplia a capacidade de leitura e de decisão dos atores escolares. Esse resultado estende a noção de *AI EdTech* (Shin et al., 2024) a um objeto pouco explorado, que é a gestão do bem-estar socioemocional do discente, e dá conteúdo empírico ao argumento de Fullan et al. (2024) de que o valor da IA na educação pode residir menos na substituição de tarefas pedagógicas e mais na ampliação da capacidade decisória da escola. Esse estudo também conecta a agenda do bem-estar socioemocional à teoria da inovação na gestão educacional (Campbell et al., 2026; Friesen et al., 2026), ao tratar a informação socioemocional como insumo para a decisão organizacional, e não apenas como objeto da relação pedagógica. A inovação, aqui, não é a personalização do ensino, mas a personalização do cuidado. Enquanto a literatura trata o bem-estar socioemocional no nível individual e da relação professor-aluno (Pastore et al., 2025), os resultados mostram que a IA aplicada a texto livre pode ajudar a identificar e mapear fatores socioemocionais.

A segunda contribuição refere-se ao uso do texto livre analisado por IA, cujas propriedades combinadas o distinguem tanto da observação humana quanto dos instrumentos fechados de avaliação. A análise computacional de linguagem aplicada a estados psicológicos não é, em si, inédita: a tradição inaugurada por abordagens lexicais como o LIWC demonstrou associações consistentes entre padrões de uso de palavras e condições emocionais (Tausczik & Pennebaker, 2010). Essas abordagens, contudo, operam sobre vocabulários fechados. Os modelos de linguagem de grande porte deslocam essa fronteira ao interpretar o sentido do texto para além da ocorrência de termos isolados. Ao operar sobre a escrita espontânea, e não sobre a percepção do observador ou sobre escalas predefinidas (Algan & Huillery, 2025; Barrientos & Cruz, 2025), o método dá visibilidade justamente a esse sofrimento silencioso: o reconhecimento da supressão emocional em um aluno que esconde o próprio medo

para não preocupar terceiros, ou a detecção de sinais de atenção em textos sem qualquer vocabulário explícito de risco, ilustram uma sensibilidade a manifestações que escapam tanto à observação cotidiana quanto ao formulário fechado, oferecendo ao aluno que não verbaliza seu estado um canal de expressão de baixa exposição social. Isso responde à lacuna formulada na seção 2.2, sobre o ponto cego dos quadros internalizantes (Janschewski et al., 2024). Uma segunda propriedade é a auditabilidade. Ao preservar trechos do próprio texto como evidência para os escores atribuídos, a abordagem permite que a interpretação produzida pela IA seja submetida à verificação humana. A terceira propriedade é a comparabilidade longitudinal: em vez de produzir apenas fotografias isoladas, a repetição das coletas permite organizar os sinais em trajetórias de melhora, estabilidade ou deterioração.

A terceira contribuição parte da literatura crítica sobre *EdTechs*, que adverte que essas organizações deslocam parte da capacidade de inovação, e do controle sobre os meios de gestão educacional, para fora das fronteiras da escola (Decuypere et al., 2025). Os resultados acrescentam a essa discussão uma evidência importante: a capacidade técnica dos modelos de IA em identificar sinais precocemente não se traduz automaticamente em valor. O contraste entre uma instituição que converteu o alerta em ação e outra que não o fez indica que a eficácia da identificação precoce depende da existência, na escola, de uma capacidade organizacional de acolhimento. Esse achado reconecta o estudo ao argumento inicial do referencial, segundo o qual a liderança educacional atua como mediadora indispensável da inovação (Campbell et al., 2026; Friesen et al., 2026): a inovação trazida pela *EdTech* sozinha não foi suficiente para a gestão preventiva do bem-estar. A contribuição teórica do estudo, portanto, não é a de afirmar que a IA resolve o problema da detecção socioemocional, mas a de demonstrar que ela o redefine, deslocando o gargalo da capacidade de identificar para a capacidade de acolher, e situando a tecnologia como um elemento cuja efetividade se decide na organização escolar.

6 CONCLUSÕES

Este estudo investigou como uma *EdTech* brasileira utiliza IA aplicada a textos livres para apoiar a identificação precoce de sinais socioemocionais em estudantes de escolas privadas. O objetivo foi atendido por meio de um estudo de caso único e longitudinal, estruturado em três fases, cujos resultados sugerem uma progressão da viabilidade técnica à utilidade gerencial: a coleta por texto livre mostrou-se exequível em ambiente escolar real (Fase 1), os sinais produzidos revelaram-se estruturados, coerentes e interpretáveis (Fase 2) e o acompanhamento de trajetórias individuais evidenciou o potencial de dar visibilidade a sofrimentos que poderiam escapar à observação docente e aos instrumentos fechados (Fase 3). Ao estruturar o sinal, a plataforma permite que as escolas identifiquem padrões de atenção que não seriam visíveis em produções textuais isoladas; ao torná-lo auditável, viabiliza a verificação humana caso a caso, requisito central para o uso responsável de IA em contexto sensível; e ao torná-lo longitudinalmente comparável, possibilita acompanhar trajetórias e priorizar ações de escuta pedagógica para os alunos, grupos e momentos que delas mais necessitam. Em termos práticos, a adoção da solução exige responsáveis pelos alertas, protocolos de acolhimento, fluxos de encaminhamento e integração dos sinais às rotinas escolares. A resposta ao problema de pesquisa, contudo, não se esgota na dimensão técnica: o estudo sugere que a IA redefine o problema da detecção socioemocional, deslocando o gargalo da capacidade de identificar para a capacidade de acolher, e que o valor da tecnologia se realiza apenas

quando o sinal estruturado, auditável e longitudinalmente comparável encontra, na escola, uma capacidade organizacional que o converta em ação de cuidado.

Esse estudo tem limitações: a investigação examinou uma única *EdTech* e um número reduzido de escolas privadas brasileiras, o que restringe a generalização dos resultados (Yin, 2018); os sinais produzidos pela plataforma não foram confrontados com avaliação clínica independente, permanecendo no plano da triagem; uma terceira limitação decorre da natureza voluntária da participação, com adesão média de aproximadamente 60% dos alunos. Entre as sugestões de pesquisas futuras, destacamos: estudos de validação convergente entre os sinais textuais e escalas consagradas de bem-estar socioemocional; replicações em escolas públicas e em contextos socioeconômicos distintos; e desenhos longitudinais mais extensos, capazes de estimar o efeito da identificação precoce sobre trajetórias acadêmicas e de bem-estar socioemocional. Ao percorrer esse caminho, pesquisas futuras poderão consolidar o que este estudo sugere: que o encontro entre IA e gestão escolar tem, no cuidado preventivo, uma de suas fronteiras mais promissoras.

REFERÊNCIAS

Algan, Y., & Huillery, E. (2025). Socio-emotional skills and the future of education. Annual Review of Economics, 17.

Barrientos, P. L. M., & Cruz, C. J. B. C. D. (2025). Socio-Emotional Competence and Academic Grit Among Grade Ten Students of the Largest Comprehensive High School. International Journal of Research and Innovation in Social Science.

Bhutoria, A. (2022). Personalized education and artificial intelligence in the United States, China, and India: A systematic review using a human-in-the-loop model. Computers and Education: Artificial Intelligence, 3, 100068.

Campbell, P., MacGregor, S., Sum, N., Friesen, S., Sawalhi, R., Conway, J., ... & Kam, Y. C. (2026). Conceptualising innovation in education: a scoping review of implications for school leadership and change. School Leadership & Management, 46(1), 6-30.

Chong, L. Z., Foo, L. K., & Chua, S. L. (2025). Student burnout: A review on factors contributing to burnout across different student populations. Behavioral Sciences, 15(2), 170.

Cooper, G. (2023). Examining science education in ChatGPT: An exploratory study of generative artificial intelligence. Journal of science education and technology, 32(3), 444-452.

Crawford, J., Fitzgerald, R., & Taylor, L. (2026). The essay and multiple choice questionnaires are not dead, but no longer enough: Generative AI and assurance of learning. Journal of University Teaching and Learning Practice, 23(1), 1-13.

Decuypere, M., Hartong, S., Brandau, N., Joecks, L., Loft-Akhoondi, A., Ortegón, C., & Vanermen, L. (2025). Maneuvering constellations of valuation: a critical investigation of the edtech startup sector. Critical Studies in Education, 66(3), 429-448.

Eckert, H., Steinmayr, R., & Wirthwein, L. (2025). Socioemotional and sociodemographic determinants of subjective well-being in school during childhood and adolescence. European Journal of Psychology of Education, 40(2), 54.

Friesen, S., Sum, N., Sawalhi, R., MacGregor, S., Campbell, P., Conway, J., ... &

Penner, A. (2026). The leadership of innovation in education: findings from an environmental scan. School Leadership & Management, 46(1), 31-63.
Fullan, M., & Quinn, J. (2023). The drivers: Transforming learning for students, schools, and systems. Corwin Press.
Fullan, M., Azorín, C., Harris, A., & Jones, M. (2024). Artificial intelligence and school leadership: challenges, opportunities and implications. School Leadership & Management, 44(4), 339-346.
Gulson, K. N., & McDuie-Ra, D. (2026). The multiple geographies of race, artificial intelligence and EdTech. In Handbook on Geographies of Education (pp. 359-371). Edward Elgar Publishing.
Hughes, M. E., Waite, L. J., Hawkley, L. C., & Cacioppo, J. T. (2004). A short scale for measuring loneliness in large surveys: Results from two population-based studies. Research on Aging, 26(6), 655–672.
Jagodics, B., Nagy, K., Szenasi, S., Varga, R., & Szabo, E. (2023). School demands and resources as predictors of student burnout among high school students. School Mental Health, 15(1), 90-104.
Janschewski, J., Kappler, C., & Berens, P. (2024). School predictors of mental health problems in children and adolescents based on a survey of students in hospital and regular schools. Zeitschrift Fur Padagogische Psychologie, 38(4), 227-243.
Komljenovic, J. (2022). The future of value in digitalised higher education: why data privacy should not be our biggest concern. Higher Education, 83(1), 119-135.
Kroenke, K., Spitzer, R. L., & Williams, J. B. W. (2001). The PHQ-9: Validity of a brief depression severity measure. Journal of General Internal Medicine, 16(9), 606–613.
Pastore, G., Kassis, W., Kunz, A., & Luder, R. (2025). Patterns of student socio-emotional development and teacher-student-relationship-quality for high-school students with and without special educational needs. In Frontiers in Education (Vol. 10, p. 1617527). Frontiers Media SA.
Rosenberg, M. (1965). Society and the adolescent self-image. Princeton University Press.
Schaufeli, W. B., Martínez, I. M., Marques Pinto, A., Salanova, M., & Bakker, A. B. (2002). Burnout and engagement in university students: A cross-national study. Journal of Cross-Cultural Psychology, 33(5), 464–481.
Shin, C., Seo, D. G., Jin, S., Lee, S. H., & Park, H. J. (2024). Educational technology in the university: A comprehensive look at the role of a professor and artificial intelligence. IEEE Access, 12, 116727-116739.
Spitzer, R. L., Kroenke, K., Williams, J. B. W., & Löwe, B. (2006). A brief measure for assessing generalized anxiety disorder: The GAD-7. Archives of Internal Medicine, 166(10), 1092–1097.
Tausczik, Y. R., & Pennebaker, J. W. (2010). The psychological meaning of words: LIWC and computerized text analysis methods. Journal of language and social psychology, 29(1), 24-54.
Topp, C. W., Østergaard, S. D., Søndergaard, S., & Bech, P. (2015). The WHO-5 Well-Being Index: A systematic review of the literature. Psychotherapy and Psychosomatics, 84(3), 167–176. https://doi.org/10.1159/000376585
Yin, R. K. (2018). Case study research and applications (Vol. 6). Thousand Oaks, CA: Sage.