

## LANSE-MIRA: Módulo de Intervenções para Retenção Acadêmica

Vinicius Ramos<sup>1</sup>, Cristian Cechinel<sup>2</sup>, Rafael Targino<sup>2</sup>, Tiago Primo<sup>3</sup>,  
Eduardo de Vila<sup>2</sup>, Thomas Michels Rodrigues<sup>2</sup>, Edvaldo Luiz Rando Junior<sup>1</sup>,  
Emanuel Marques Queiroga<sup>4</sup>

<sup>1</sup>Departamento de Engenharia do Conhecimento  
Universidade Federal de Santa Catarina (UFSC) – Florianópolis/SC

<sup>2</sup>Departamento de Tecnologias da Informação e Comunicação  
Universidade Federal de Santa Catarina (UFSC) – Araranguá/SC

<sup>3</sup>Centro de Desenvolvimento Tecnológico (CDTec)  
Universidade Federal de Pelotas (UFPel) – Pelotas/RS

<sup>4</sup>Instituto Federal Sul-rio-grandense (IFSUL)  
Pelotas/RS

{v.ramos, cristian.cechinel}@ufsc.br, ed.rando.jr@gmail.com

trp@inf.ufpel.edu.br, emanuelmqueiroga@gmail.com

**Abstract.** Higher education institutions globally face significant student retention challenges, with dropout rates reaching 66% in Brazil and 55% among part-time students in the USA. Learning Analytics has been used to predict at-risk students, but bridging the gap between prediction and actionable interventions remains critical. This paper introduces LANSE-MIRA, a module integrated into the LANSE platform, designed to automate personalized interventions via email and WhatsApp. The system segments students by risk factors and manages rule-based campaigns. Results from prior studies show that tailored messages can improve retention by up to 22%. LANSE-MIRA's architecture includes A/B testing for continuous optimization, aiming to transform LA from diagnostic tools into proactive retention mechanisms. Future work involves adaptive interventions and Explainable AI (XAI) for enhanced personalization.

**Resumo.** Instituições de ensino superior enfrentam altas taxas de evasão que giram em torno de 66% no Brasil e 55% nos Estados Unidos da América. A Analítica de Aprendizagem pode ser usada para identificar alunos em risco, mas a lacuna entre previsão e ação ainda persiste. Este artigo apresenta o LANSE-MIRA, um módulo da plataforma LANSE que automatiza intervenções personalizadas via e-mail e WhatsApp. O sistema segmenta alunos por fatores de risco e gerencia campanhas baseadas em regras. Estudos anteriores demonstram que mensagens direcionadas aumentam a retenção de estudantes em até 22%. A arquitetura do LANSE-MIRA inclui testes A/B para otimização contínua, visando transformar LA em uma ferramenta proativa. Trabalhos futuros focam em intervenções adaptativas e IA Explicável (XAI) para maior personalização.

## 1. Introdução

As instituições de Ensino Superior no mundo inteiro enfrentam problemas de retenção de estudantes. Ao considerarmos a evasão de um estudante do ensino superior, podemos afirmar que há perdas tanto para o indivíduo quanto para a sociedade. Essas perdas são, entre muitas outras, financeiras, sociais e até emocionais.

O Centro Nacional de Estatísticas Educacionais dos Estados Unidos publicou em seu relatório anual no ano de 2024 que, aproximadamente, 23% e 55% dos estudantes de graduação em tempo integral e em tempo parcial, respectivamente, não completam os seus estudos, muitas vezes por problemas financeiros, desafios relacionados à saúde mental e pressões sobre encontrar um equilíbrio entre o trabalho e os estudos [Irwin et al. 2024].

No Brasil, o Mapa do Ensino Superior Brasileiro, consolidado pelo Sindicato das Empresas Mantenedoras do Ensino Superior (SEMESP) com dados do Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira (INEP) [SEMESP 2025], aponta para um aumento de quase 10% no número de matrículas ao longo dos últimos 15 anos. Entretanto, esses dados se contrapõem ao percentual de evasão no ensino superior no último ano do recorte, em 2023, pois esse mesmo relatório descreve que esses números chegaram a mais de 66% em todas as instituições, sejam públicas (26,4%) ou privadas (40,1%).

Para tentar atacar o problema da evasão, pesquisadores têm apresentado inúmeros estudos com o uso de Analíticas de Aprendizagem (LA, do inglês *Learning Analytics*) usando dados de diversas fontes, incluindo sistemas acadêmicos e de ambientes virtuais de aprendizagem, como o Moodle [Rebelo Marcolino et al. 2025]. Entre os estudos, destacam-se os modelos de LA para predição de estudantes em risco de reprovação e evasão. Entretanto, ainda existe a lacuna entre a predição e a ação, ou seja, identificar os estudantes em risco tem muito mais valor quando você associa este serviço a uma intervenção efetiva.

Neste contexto, intervenções baseadas em mensagens de texto e e-mails mostram-se ações promissoras em aumentar as taxas de retenção de estudantes de graduação. Um estudo que usou LA preditiva para fazer intervenções motivacionais, enviando mensagens de texto e e-mails, apresentou resultados de retenção significativamente melhores para o grupo que recebeu as intervenções [Herodotou et al. 2020]. De maneira similar, um serviço de envio de mensagens automaticamente, chamado FLO, aumentou o sentimento de pertencimento dos estudantes e os ajudou a continuar no seu curso de graduação [Boath et al. 2016]. Ainda, pesquisadores mostraram que intervenções de envio de mensagens de texto de suporte ao estudante, durante um período de estresse, melhoraram as taxas de progresso desses estudantes, as médias das suas notas e presença nas aulas, de forma estatisticamente significativa, comparando-os com o grupo de controle [Deighton et al. 2019]. Essas pesquisas sugerem que intervenções através de mensagens de texto e de e-mail são efetivas e eficientes para aumentar a taxa de retenção de estudantes no ensino superior.

Neste sentido, este artigo descreve um Módulo de Intervenções para Retenção Acadêmica, para a ferramenta LANSE [Cechinel et al. 2024], que chamaremos de LANSE-MIRA. Um módulo integrado a um sistema de predição de estudantes em risco de evasão e vários *dashboards* para fechar o ciclo do problema da evasão. O LANSE-

MIRA estende as capacidades da ferramenta e o seu principal objetivo é automatizar um sistema de entrega de mensagens personalizadas e em tempo, ou *nudges* como colocam alguns autores, através de canais muito utilizados pelos estudantes: e-mails e mensagens no Whatsapp. Portanto, este módulo pretende operacionalizar alguns resultados científicos e educacionais que mostram que esses tipos de notificação, através de mensagens para os alunos, podem aumentar a retenção de potenciais estudantes em risco de evasão.

## 2. Trabalhos Relacionados

Os avanços recentes das LA e das intervenções comportamentais têm demonstrado o potencial de abordagens tecnológicas para aumentar a retenção de estudantes de graduação. Um número significativo de pesquisas explorando a efetividade de mensagens de texto e e-mails mostra ganhos de aproximadamente 20 pontos percentuais quando são feitas intervenções personalizadas, oportunas e interativas.

Nesse contexto, [Herodotou et al. 2020] examinaram como LAs preditivas combinadas com intervenções motivacionais poderiam melhorar a retenção de estudantes matriculados em cursos no regime de Educação a Distância (EAD). Esse método misto implementou alertas antecipados e personalizados para os estudantes. Os resultados mostraram um aumento de 22% na finalização dos cursos nos grupos de intervenção.

Complementarmente, [O'Hara et al. 2022] desenvolveram intervenções textuais baseadas em valores para estudantes de faculdades comunitárias em programas de saúde. Os pesquisadores enviaram mensagens quinzenais alinhando as tarefas acadêmicas com os valores pessoais e objetivos de carreira dos estudantes. Os resultados mostraram um aumento geral de 3% na rematrícula, com ganhos de 11% a 13% para estudantes do sexo masculino e negros. O estudo comprovou que mensagens culturalmente responsivas podem reduzir as disparidades de equidade. Os resultados enfatizam a possibilidade de conectar o meio acadêmico às identidades dos estudantes.

Por outro lado, [Zick et al. 2022] realizaram uma análise de custo-benefício de um programa de mensagens de texto para a persistência de estudantes na universidade. O estudo comparou os custos de implementação com os ganhos de retenção ao longo de três anos. Os resultados indicaram um custo favorável de US\$ 42 por aluno retido, demonstrando um forte retorno sobre o investimento (ROI). A pesquisa fornece importantes evidências empíricas sobre a relação custo-efetividade da intervenção.

De forma semelhante, [Deighton et al. 2019] examinaram como a inteligência emocional combinada com intervenções textuais impactou alunos do primeiro ano de graduação. O estudo constatou que o grupo de intervenção apresentou taxas de progresso 17% maiores, além de demonstrar relevância estatística na melhoria das médias das notas e sua presença nas aulas, comparando-os com o grupo de controle. Dados qualitativos também revelaram que os textos ajudaram os alunos a se sentirem apoiados durante as transições.

Ampliando a escala de aplicação, [Castleman and Meyer 2020] ampliaram pesquisas anteriores de incentivo por meio de uma iniciativa estadual de mensagens de texto para universidades. O estudo quase-experimental demonstrou melhora na acumulação de créditos e na persistência dos estudantes. Os efeitos foram mais fortes para alunos de universidades regionais em comparação com faculdades comunitárias. A pesquisa mos-

tra como escalar práticas baseadas em evidências de forma eficaz. O estudo fornece um modelo para intervenções de retenção em todo o sistema.

Nessa mesma linha de investigações em larga escala, o estudo de [Tippelts et al. 2022] avaliou a intervenção de mensagens de texto em larga escala, visando à retenção de alunos de graduação por meio de mensagens personalizadas e conduzidas por orientadores. Usando uma pesquisa randomizada, os autores descobriram que a comunicação bidirecional por texto aumentou a retenção de alunos de turmas mais baixas entre 3 e 6% (de 87% para 93%), com os efeitos mais fortes para alunos que se envolveram ativamente com as mensagens. A pesquisa destacou o papel crítico das mensagens relacionais (por exemplo, relacionamento orientador-aluno) em relação aos lembretes transacionais. As principais barreiras incluíram o baixo engajamento entre subgrupos de alto risco e os desafios institucionais em escalar o contato personalizado. O estudo destaca a necessidade de combinar tecnologia com design centrado no ser humano para maximizar os impactos na retenção.

Quando consideramos sistemas de alerta precoce (EWS, do acrônimo em inglês *Early Warning Systems*) no ensino superior que utilizam IA para identificar alunos em risco e fornecer suporte personalizado, há um grupo de pesquisadores que se destaca [Bañeres et al. 2019, Bañeres et al. 2020, Bañeres et al. 2021, Raffaghelli et al. 2022, Bañeres et al. 2023, Rodríguez-González et al. 2024]. Esses sistemas visam reduzir as taxas de evasão e melhorar o sucesso dos alunos, detectando possíveis problemas precocemente. Estas pesquisas mostram que os EWS podem ser precisos na identificação de alunos em risco em ambientes de educação online [Bañeres et al. 2020]. No entanto, a aceitação desses sistemas pelos alunos pode variar de estudo para estudo. Um estudo que aplicou o modelo UTAUT [Raffaghelli et al. 2022] encontrou um efeito de desconfermação entre as expectativas pré e pós-uso. As experiências dos alunos com os EWS são influenciadas por fatores como autoeficácia acadêmica, experiência anterior e disciplina de estudo, com alunos de ciência da computação mostrando maior confiança em sistemas de IA em comparação com alunos de economia [Rodríguez-González et al. 2024].

### **3. LANSE-MIRA: Módulo de Intervenções para Re却是ão Acadêmica**

Este módulo da LANSE é uma estrutura de software abrangente, projetada para operacionalizar os resultados de intervenções textuais encontrados na literatura e otimizados para e-mails e WhatsApp. Esta seção detalha a arquitetura do sistema e os componentes funcionais que constituem o núcleo desta contribuição de pesquisa.

#### **3.1. Arquitetura do Sistema**

A arquitetura integra o MIRA ao mecanismo principal de LA da LANSE. O fluxo de trabalho começa com a Camada de Ingestão de Dados, que coleta dados de fontes institucionais (Moodle/LMS). Esses dados alimentam o Mecanismo de Análise de Aprendizagem, que calcula pontuações de risco e identifica fatores de risco específicos para cada aluno. A saída desse mecanismo é, então, passada para o MIRA, responsável pelo ciclo de vida da gestão da intervenção.

O módulo em questão é composto por quatro componentes interconectados e projetados para melhorar o desempenho do sistema a partir de experimentos anteriores,

sendo eles: 1) Mecanismo de Segmentação de Alunos, 2) Gerenciador de Campanhas de Intervenção, 3) Mecanismo de Protocolo de Comunicação e 4) Mecanismo de Testes A/B e Análise.

### **3.1.1. Mecanismo de Segmentação de Alunos**

O primeiro componente, que chamaremos de Mecanismo de Segmentação de Alunos, busca generalizar os estudantes em segmentos específicos, fugindo de apenas uma única pontuação de risco monolítica. Ele recebe tanto a probabilidade de risco quanto os fatores de risco específicos que contribuem para o risco (por exemplo, "pouco acesso", "não entrega de atividades", "notas baixas") do mecanismo de LA. Isso permite uma segmentação mais detalhada, permitindo que as intervenções sejam adaptadas ao motivo específico da dificuldade do estudante. Esta escolha de design está baseada na literatura explorada na Seção 2 que enfatiza o suporte direcionado, em vez de genérico.

### **3.1.2. Gerenciador de Campanhas de Intervenção**

O segundo componente, que chamamos de Gerenciador de Campanhas de Intervenção, é o centro de controle administrativo do sistema. Ele permite que os profissionais criem campanhas de retenção usando um mecanismo baseado em regras. Um administrador pode definir uma regra como: SE Estudante == 'Alto Risco - Engajamento' E Dias-antes-do-meio-do-período <= 14 ENTÃO acionar 'Estimulação Motivacional de Meio de Período'. O sistema deve possuir uma biblioteca de modelos de mensagens com mensagens pré-criadas e categorizadas (Informativas, Motivacionais, de Apoio, etc.) que suportam tokens de personalização (por exemplo, nome\_do\_aluno, nome\_do\_curso, nome\_do\_orientador). Isso implementa diretamente os fatores de sucesso de personalização e tempo, também respaldados por pesquisas acadêmicas.

### **3.1.3. Mecanismo de Protocolo de Comunicação**

O terceiro componente é chamado de Mecanismo de Protocolo de Comunicação. Este componente gerencia a lógica técnica de entrega. Ele interage via API com um Gateway de Comunicação (por exemplo, Twilio para WhatsApp, SMTP para e-mail). Ele pode ser configurado para priorizar o WhatsApp e usar o e-mail como fallback, refletindo as preferências de comunicação modernas. Fundamentalmente, ele foi projetado para gerenciar a comunicação bidirecional, encaminhando as respostas dos alunos para um painel dedicado ao tutor/professor/gerente/administrador, permitindo assim que o suporte interativo demonstrado na literatura seja também eficaz.

### **3.1.4. Mecanismo de Testes A/B e Análise**

O quarto e último componente é o Mecanismo de Testes A/B e Análise. Para garantir a melhoria contínua e fechar o ciclo de feedback analítico, este mecanismo é considerado muito importante para todo o LANSE-MIRA. Ele permite que os administradores configurem e executem facilmente testes A/B dentro de uma campanha (por exemplo, testando

**Tabela 1. Categorias de mensagens e regras de disparo pre-cadastradas**

Categoría	Tipo	Disparo do Evento
Alerta	PRE_COURSE	Dois dias antes do início do curso
	COURSE_BEGINING	Dia de início do curso
	COURSE_ENDING	Dia do fim do curso
	VENCIMENTO DE PRAZO ATIVIDADES	3 dias antes da entrega de uma atividade.
Recuperação	ALUNO_SEM_ACESSO_1aSEM	5 dias depois do início das aulas e o aluno nunca entrou
	ALUNO_SEM_ACESSO_POS_1aSEM	2, 3 e 4 semanas depois do início das aulas e o aluno nunca entrou
	ALUNO_AUSENTE	A qualquer momento, aluno já entrou na turma 1 vez, mas depois ficou 2 semanas sem entrar. Repete na 3a e 4a semana sem entrar. Houve entrega de atividade e o aluno não entregou. Ou passou o prazo da atividade e aluno não entregou
Reforço	ALUNO_NAO_ENTREGOU_ATIVIDADE	
	ALUNO_PRESENTE_1ASEM	Aluno entrou no curso até o 5º dia do início das aulas
	ALUNO_COMPROMETIDO	Aluno entrou no AVA por 3 semanas consecutivas, ou mais (em qualquer momento)
	ALUNO_ENTREGOU_ATIVIDADE	Aluno entregou atividade

uma mensagem de apoio em comparação com uma puramente informativa para o mesmo segmento de alunos). O mecanismo foi projetado para monitorar métricas de engajamento (entrega, abertura, taxas de cliques) para que, no futuro, possamos mensurar o impacto no resultado final da taxa de retenção entre períodos letivos. Este componente ainda está em desenvolvimento, mas, como dito anteriormente, será peça fundamental para a LANSE, transformando a prática institucional de "implementar e esperar" para "implementar, mensurar e otimizar".

### 3.2. Exemplo da implementação

A tabela 1 apresenta um conjunto de eventos previamente cadastrados no módulo que podem ser utilizados dentro do LANSE.

Como pode ser visto na Tabela 1, as regras inicialmente pré-cadastradas estão divididas em três grupos principais, sendo eles: eventos de alerta, de recuperação e de reforço. Nesse primeiro momento, ainda não foram criados eventos para serem disparados de maneira automática, sendo que o sistema detecta o evento a partir da regra e sugere que o mesmo possa acionar ou não o disparo do mesmo. A Figura 1 mostra esses exemplos de mensagens textuais de intervenção pré-cadastradas para serem enviadas de forma manual para os alunos selecionados. Nesta tela de exemplo, é possível selecionar alunos com e-mails ou telefones cadastrados e enviar essas mensagens para os respectivos alunos, como um primeiro exemplo do componente de Campanhas de Intervenção. A partir desse envio, essas mensagens serão registradas no componente de Testes A/B e Análises para que sejam monitorados o engajamento do estudante e o impacto na retenção dele.

Cabe ressaltar que o sistema LANSE possui um módulo de detecção automática de estudantes em risco por meio de algoritmos de aprendizado de máquina [Rebelo Marcolino et al. 2025], sendo que futuras regras baseadas na classificação automática de risco também serão cadastradas para uso dos professores e gestores.

**Intervenções**  
Selecione as mensagens à serem enviadas

	Nome	E-mail	Mensagem	Categoria	Ação	Mensagem Detalhada
<input type="checkbox"/>	Aurora Da Luz	levirios@test.lanse.com	+5 [REDACTED]	Recuperação	Não acessou o curso na última semana	*Curso Demo 3 2025-1* Olá, Aurora...
<input checked="" type="checkbox"/>	Aurora Da Rosa	otaviooliveira@test.lanse.com	+55 [REDACTED]	Reforço	Estudante comprometido	*Curso Demo 3 2025-1* Olá, Aurora...
<input checked="" type="checkbox"/>	Ayla Cunha	vieiramariafernanda@test.lanse.com		Alerta	Pré-Curso	*Curso Demo 3 2025-1* Olá, Ayla! E...
<input checked="" type="checkbox"/>	Bruno Teixeira	jooafelipesilveira@test.lanse.com		Alerta	Vencimento de atividade	*Curso Demo 3 2025-1* Olá, Bruno!...
<input checked="" type="checkbox"/>	Diego Duarte	bda-mata@test.lanse.com	+ [REDACTED]	Reforço	Atividade entregue	*Curso Demo 3 2025-1* Olá, Diego!...
<input type="checkbox"/>	Dom Da Mata	fferreira@test.lanse.com		Recuperação	Após semanas sem entrar do curso	*Curso Demo 3 2025-1* Olá, Dom! ...
<input type="checkbox"/>	Francisco Leão	vitor-hugo75@test.lanse.com	[REDACTED]	Recuperação	Após semanas sem entrar do curso	*Curso Demo 3 2025-1* Olá, Franci...

Email  
 WhatsApp

**Figura 1. MIRA: Módulo de Intervenções para Retenção Acadêmica**

## 4. Considerações finais

A *Learning Analytics* pode ser usada em métodos mistos para a simples previsão de estudantes em risco de evasão ou reprovação e a atuação na prevenção eficaz dela. Este artigo apresentou o módulo LANSE-MIRA, uma nova arquitetura de sistema cuja contribuição é a superação dessa lacuna entre previsão e intervenção. Ao apontar um amplo conjunto de pesquisas sobre retenção de alunos em uma estrutura de software configurável e escalável, o LANSE-MIRA fornece uma ferramenta concreta para as instituições atuarem com base em seus dados.

Como planejamento para desenvolvimentos e pesquisas futuras, é importante entender a mudança de uma gestão de intervenções textuais estáticas e baseadas em regras para um mecanismo de intervenção adaptável. Pesquisas futuras devem focar em um sistema capaz de aprender a estratégia de intervenção ideal (ou seja, o melhor conteúdo de mensagem, o melhor momento e o melhor canal) para diferentes segmentos de alunos ao longo do tempo, com base em dados históricos de engajamento e sucesso.

Além disso, planejamos integrar técnicas de IA Explicável (XAI) ao painel do administrador. Isso tornaria os motivos por trás da pontuação de risco de um aluno transparentes para os orientadores, permitindo a geração de mensagens ainda mais personalizadas e empáticas, fortalecendo ainda mais o aspecto humano no ciclo da estrutura.

O *design*, a segmentação diferenciada e os recursos integrados de testes A/B representam um passo significativo para a concretização de todo o potencial da LA. Ele fornece uma metodologia estruturada para que as instituições passem da adivinhação para a prática baseada em evidências em seus esforços de retenção de alunos. Embora a validação empírica desse sistema seja o próximo passo do estudo, a própria arquitetura tecnológica se destaca como uma contribuição robusta e bem fundamentada para a área, oferecendo um caminho para transformar a LA de uma ferramenta de diagnóstico em um mecanismo para aprimorar o sucesso de estudantes.

## Agradecimento

Este trabalho foi financiado pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) - Projeto 409633/2022-4

## Referências

- Bañeres, D., Guerrero-Roldán, A.-E., Rodríguez-González, M. E., and Karadeniz, A. (2021). A predictive analytics infrastructure to support a trustworthy early warning system. *Applied Sciences*, 11(13).
- Bañeres, D., Rodríguez-González, M. E., Guerrero-Roldán, A.-E., and Cortadas, P. (2023). An early warning system to identify and intervene online dropout learners. *International Journal of Educational Technology in Higher Education*, 20(1):3.
- Bañeres, D., Rodríguez-González, M. E., and Serra, M. (2019). An early feedback prediction system for learners at-risk within a first-year higher education course. *IEEE Transactions on Learning Technologies*, 12(2):249–263.
- Bañeres, D., Rodríguez, M. E., Guerrero-Roldán, A. E., and Karadeniz, A. (2020). An early warning system to detect at-risk students in online higher education. *Applied Sciences*, 10(13).
- Boath, E., Machin, R., Dixon, M., Thomas, N., O'CONNELL, P., and Taylor, L. (2016). Stop with the flo: using text messaging to improve retention rates in university students. *Innovative Practice in Higher Education*, 2(3):29–39.
- Castleman, B. L. and Meyer, K. E. (2020). Can text message nudges improve academic outcomes in college? evidence from a west virginia initiative. *The Review of Higher Education*, 43(4):1125–1165.
- Cechinel, C., Queiroga, E. M., Primo, T. T., Santos, H. L. d., Ramos, V. F. C., Munoz, R., Mello, R. F., and Machado, M. F. B. (2024). Lanse: a cloud-powered learning analytics platform for the automated identification of students at risk in learning management systems. In *International Conference on Artificial Intelligence in Education*, pages 127–138. Springer.
- Deighton, K., Hudson, J., Manley, A. J., Kaiseler, M., Patterson, L. B., Rutherford, Z. H., and Swainson, M. (2019). Effects of emotional intelligence and supportive text messages on academic outcomes in first-year undergraduates. *Journal of Further and Higher Education*, 43(4):494–507.
- Herodotou, C., Naydenova, G., Boroowa, A., Gilmour, A., and Rienties, B. (2020). How can predictive learning analytics and motivational interventions increase student retention and enhance administrative support in distance education? *Journal of Learning Analytics*, 7(2):72–83.
- Irwin, V., Wang, K., Jung, J., Tezil, T., Alhassani, S., Filbey, A., Dilig, R., and Mann, F. B. (2024). Report on the condition of education 2024. nces 2024-144. *National Center for Education Statistics*.
- O'Hara, R. E., Sparrow, B., and Joy, L. (2022). Values-based interventions increase reenrollment and equity among community college pre-allied health students. *Journal of Postsecondary Student Success*, 1(3):75–102.

- Raffaghelli, J. E., Rodríguez, M. E., Guerrero-Roldán, A.-E., and Bañeres, D. (2022). Applying the utaut model to explain the students' acceptance of an early warning system in higher education. *Computers & Education*, 182:104468.
- Rebelo Marcolino, M., Reis Porto, T., Thomsen Primo, T., Targino, R., Ramos, V., Marques Queiroga, E., Munoz, R., and Cechinel, C. (2025). Student dropout prediction through machine learning optimization: insights from moodle log data. *Scientific Reports*, 15(1):1–16.
- Rodríguez-González, M. E., Raffaghelli, J. E., Bañeres, D., Guerrero-Roldán, A.-E., and Crudele, F. (2024). Exploring higher education students' experience with ai-powered educational tools: The case of an early warning system. *Formazione & insegnamento*, 22(1):74–84.
- SEMESP (2025). Mapa do ensino superior no brasil. <https://www.semesp.org.br/mapa/edicao-15/>. Acessado em: 23/07/2025.
- Tippetts, M. M., Davis, B., Nalbone, S., and Zick, C. D. (2022). Thx 4 the msg: Assessing the impact of texting on student engagement and persistence. *Research in higher education*, 63(6):1073–1093.
- Zick, C. D., Tippetts, M., and Davis, B. (2022). Money well spent? the cost-effectiveness of a texting intervention targeting college persistence. *Journal of Research on Educational Effectiveness*, 15(2):394–412.