Revista de Estilos de Aprendizaje / Journal of Learning Styles
ISSN: 1988-8996 / ISSN: 2332-8533

Análise Preditiva com IA para Antecipação da Evasão na Aprendizagem Profissional a Distância

José Augusto Monteiro Viana de Souza Filho
Senac PR (Servicio Nacional de Aprendizaje Comercial, Paraná, Brasil
.jose.augusto@pr.senac.br
[ORCID Autor 1 removido para revisão cega]

Andrea Maria Cardoso Laube
Senac PR (Servicio Nacional de Aprendizaje Comercial, Paraná, Brasil
andrea.cardoso@pr.senac.br
[ORCID https://orcid.org/0009-0008-2936-0057

Received: 30 May 2026 / Accepted: 11 November 2026

Resumo
A evasão em cursos a distância da Aprendizagem Profissional é um desafio estratégico institucional. Este estudo valida um sistema preditivo de apoio à decisão, baseado em Inteligência Artificial, para antecipar esse risco. Adotaram-se *gradient boosting*, explicabilidade via SHAP e validação retroativa por *split* temporal sobre as coortes de 2023 e 2024 (4.598 matrículas), com variáveis calculadas em janelas de trinta a noventa dias. O sistema identifica estudantes em risco pelo comportamento no Ambiente Virtual de Aprendizagem e os exibe em painel com explicações individualizadas. Na janela de noventa dias, o modelo alcançou AUC de 0,570 (IC 95%: 0,533–0,607), superando o classificador base (0,496; diferença de 0,074). Na janela de trinta dias, o AUC foi de 0,515, sem diferença distinguível. Das quatro estratégias de melhoria avaliadas, apenas a trajetória semanal de engajamento rendeu ganho distinguível. Duas limitações estruturais foram identificadas, a mediana de 232 dias entre matrícula e desligamento e as saídas extra-acadêmicas em cerca de um terço dos casos. A infraestrutura mostra-se viável e rastreável, e a predição requer horizonte mais longo e definição mais estrita do desfecho.

Palavras-chave: análise preditiva; inteligência artificial; evasão escolar; *learning analytics*; aprendizagem de qualificação profissional

[en] Predictive Analysis with AI for Dropout Anticipation in Vocational Distance Learning

Abstract:
Dropout in distance education courses for Professional Qualification is a strategic challenge for vocational education institutions. This study technically validates a predictive decision-support system, based on Artificial Intelligence, to anticipate that risk. It used gradient boosting algorithms, SHAP-based explainability, and temporal split retrospective validation over the 2023 and 2024 cohorts, comprising

4,598 completed enrolments, with features computed over thirty-, sixty-, and ninety-day windows from enrolment. The system identifies at-risk students from behavior in the Virtual Learning Environment and integrates results into a dashboard with individualized explanations. Over the ninety-day window, the model achieved an AUC of 0.570, with a 95% confidence interval between 0.533 and 0.607, against 0.496 for a classifier built only from enrolment modality and month, a difference of 0.074 whose interval excludes zero. Over the thirty-day window, the AUC was 0.515, with no distinguishable difference. Of four improvement strategies assessed, only the inclusion of weekly engagement trajectory produced a distinguishable gain. Two structural limitations were identified, a median of 232 days between enrolment and withdrawal and non-academic exits in roughly one third of cases. The infrastructure proves feasible and traceable, and prediction requires a longer horizon and a stricter definition of the outcome.

Keywords: dropout; artificial intelligence; predictive analytics; learning analytics; vocational education.

Sumário: 1. Introdução. 2. Referencial Teórico. 3. Metodologia. 3.1. Contexto e Dados Utilizados. 3.2. Modelagem Preditiva. 3.3. Integração Operacional. 3.4. Ambiente Computacional. 4. Resultados. 4.1. Descrição do Experimento. 4.2. Hiperparâmetros. 4.3. Curva ROC. 4.4. Métricas de Classificação e Explicabilidade. 4.5. Estratégias de Melhoria. 5. Discussão. 6. Conclusão. Referências.

1. Introdução

A expansão da Educação a Distância (EaD) na formação profissional ampliou a necessidade de monitoramento sistemático da permanência discente. O crescimento das interações mediadas por tecnologias digitais permite registrar, analisar e interpretar comportamentos que podem sinalizar risco de evasão, por exemplo, queda de frequência de acesso, redução do ritmo de estudo ou não realização de atividades avaliativas. Nesse contexto, a evasão é compreendida como um processo contínuo, marcado por sinais comportamentais detectáveis ao longo da trajetória formativa dos estudantes, e não apenas como um evento pontual de desligamento. Este estudo avalia se tal antecipação é viável a partir de registros acadêmicos e de atividade no Ambiente Virtual de Aprendizagem (AVA), e a partir de que horizonte temporal ela se torna mensurável.

A evasão em cursos a distância decorre de fatores que vão do desenho do curso à motivação e ao suporte recebido, conforme revisão de 110 estudos publicados entre 2013 e 2023 (Rahmani et al., 2024). Entre as abordagens para antecipar esse desfecho a partir de registros digitais em Ambientes Virtuais de Aprendizagem (AVA), a aprendizagem de máquina ganhou espaço na última década (Hernández-de-Menéndez et al., 2022). Entre os algoritmos mais empregados estão os métodos de *boosting* de árvores, como o XGBoost (Chen & Guestrin, 2016) e o LightGBM (Ke et al., 2017). Huo et al. (2023) aplicaram o XGBoost a estudantes de graduação não tradicionais nos Estados Unidos, com dados do *Beginning Postsecondary Students Longitudinal Study* (BPS 2012/14), e obtiveram sensibilidade de 71,40% e acurácia de 79,82% no modelo com todas as variáveis. Gonzalez-Nucamendi et al. (2023) mostraram, em uma universidade privada mexicana, que o ajuste do limiar de probabilidade de uma *Random Forest* eleva a precisão na classe de evasão. Mustofa et al. (2025) propuseram um modelo híbrido de regressão logística e rede neural que atingiu 96% de acurácia em um conjunto público de estudantes de ensino superior, com explicações via SHAP (*SHapley Additive exPlanations*) e LIME (*Local Interpretable Model-agnostic Explanations*).

Os trabalhos anteriormente mencionados concentram-se no contexto do ensino superior. Nesse cenário, evidências obtidas a partir de registros de atividade do *Moodle* demonstram o potencial desses dados para alimentar modelos de predição de evasão e de reprovação, especialmente quando estratégias de otimização são empregadas (Marcolino et al., 2025). Uma revisão sistemática recente identificou 83 modelos de aprendizagem de máquina destinados à predição da evasão universitária e destacou SHAP e LIME como os métodos de explicação mais utilizados, não encontrando evidências do uso de modelos de simulação aplicados nesse contexto (Quimiz-Moreira et al., 2025). De forma complementar, Vaarma e Li (2024) observam que dados de LMS (*Learning Management System*) têm sido utilizados para analisar a evasão no nível da disciplina, enquanto poucos estudos os relacionaram em programas de graduação.

A granularidade crescente dos registros educacionais cria oportunidades para articular sistemas preditivos a fluxos estruturados de retenção. Diante desse cenário, o objetivo deste estudo é desenvolver e validar tecnicamente, em condições retroativas, um sistema preditivo para identificar estudantes em risco de evasão a partir de dados comportamentais do AVA nos cursos de Aprendizagem Profissional de Qualificação a Distância (APQ-EaD) do [Instituição removida para revisão cega]. O modelo foi ajustado sobre a coorte encerrada de 2023 e avaliado na coorte de 2024. Intervenções pedagógicas não integraram esta etapa, sendo previstas para fase prospectiva futura. O artigo organiza-se em mais cinco seções: a Seção 2 revisa o referencial teórico sobre predição de evasão; a Seção 3 descreve a metodologia, os dados, a modelagem e o painel operacional; a Seção 4 reporta os resultados experimentais, a explicabilidade e os testes de melhoria; a Seção 5 discute os achados frente à literatura; e a Seção 6 traz as conclusões, limitações e trabalhos futuros.

2. Referencial Teórico

O engajamento do estudante deixa rastro em ambientes digitais, na frequência de acesso, na constância de estudo e na participação em atividades avaliativas, e esses registros já foram usados para antecipar o afastamento em cursos a distância (Queiroga et al., 2020; Marcolino et al., 2025). Esses indicadores permitem monitorar o percurso formativo e identificar padrões que precedem o afastamento gradual do estudante, possibilitando ações preventivas em vez de intervenções exclusivamente reativas.

Um levantamento do estado da arte em dezesseis instituições mostra que *Learning Analytics* pode apoiar ações de acompanhamento e redução de evasão quando articulado a intervenções institucionais estruturadas (Hernández-de-Menéndez et al., 2022). A revisão de Rahmani et al. (2024) organiza os determinantes da evasão online em cinco grupos, a saber demográficos, de curso, de tecnologia, motivacionais e de suporte, e exclui de seu escopo os estudos voltados à predição do desfecho. A literatura demonstra que modelos preditivos integrados a mediação humana tendem a gerar impactos mais consistentes, pois oferecem alertas e explicações que apoiam, e não substituem, a atuação docente (Ferguson, 2012; Arnold & Pistilli, 2012).

Os estudos empíricos variam em contexto, tamanho de amostra e tipo de dado. Huo et al. (2023) trabalharam com 24.770 estudantes de 1.480 instituições dos Estados Unidos, com dados sociodemográficos, financeiros e de matrícula do BPS 2012/14, e não com dados de AVA. Gonzalez-Nucamendi et al. (2023) trabalharam com 14.495 registros completos de uma universidade privada mexicana, com dados de desempenho acadêmico das primeiras semanas do primeiro semestre. Mustofa et al. (2025) usaram um conjunto público de 4.424 estudantes de ensino superior, com 34 variáveis demográficas, socioeconômicas e acadêmicas, sem informar o país de origem dos dados. Queiroga et al. (2020) são a exceção mais próxima, pois usaram interações no AVA de um curso técnico de nível médio a distância no Brasil. Nenhum dos trabalhos citados, porém, trata de formação em regime *dual*, na qual o percurso do estudante se reparte entre a escola e a empresa concedente sob vínculo celetista, e é esse recorte que delimita a contribuição do presente trabalho. A efetividade de tecnologias complexas depende tanto da qualidade técnica do modelo quanto da competência digital das equipes pedagógicas (Pérez-López & Alzás García, 2023).

Os estudos clássicos sobre evasão acadêmica, particularmente aqueles desenvolvidos por Tinto (1993), fundamentam a compreensão da permanência como resultado da interação entre fatores acadêmicos, sociais e institucionais. No campo de *Learning Analytics* e *Educational Data Mining*, autores como Arnold e Pistilli (2012), Baker e Inventado (2014) e Ferguson (2012) discutem tanto o potencial dos sistemas preditivos quanto os desafios relacionados à sua implementação, como transparência, explicabilidade, interpretação responsável e mediação pedagógica. No contexto da EaD, essa dimensão estende-se também aos estudantes, onde o engajamento nos ambientes virtuais pressupõe um repertório mínimo de competências digitais que, quando ausente ou frágil, pode amplificar o risco de evasão independentemente do conteúdo do curso (Araújo da Silva & Behar, 2023). A literatura de engenharia de sistemas de aprendizado de máquina trata do que mantém um modelo em operação, e Lima et al. (2022) sistematizam, para contextos corporativos, práticas de monitoramento contínuo, versionamento e rastreabilidade das decisões do modelo. Esses princípios foram adaptados aqui para a gestão educacional, sem que os autores originais tenham tratado de fluxos pedagógicos. Essas recomendações reforçam que a eficácia de sistemas preditivos depende não apenas da acurácia técnica do modelo, mas também de sua capacidade de se integrar a práticas institucionais consistentes

de acompanhamento e intervenção, respeitando princípios éticos e de proteção de dados (Drachsler & Greller, 2016; Slade & Prinsloo, 2013).

3. Metodologia

A metodologia adotada envolveu três etapas principais: (I) análise do contexto institucional e caracterização da evasão; (II) desenvolvimento e validação do modelo preditivo; e (III) integração do modelo a um painel operacional de suporte à decisão.

3.1. Contexto e Dados Utilizados

Foram analisados dados dos cursos de APQ-EaD ofertados pelo [Instituição removida para revisão cega]. Considerando apenas matrículas encerradas (pois matrículas em curso não possuem desfecho definido), a coorte de 2023 reuniu 2.682 matrículas, com 576 evasões (21,5%), e a de 2024 somou 1.916 matrículas, com 366 evasões (19,1%). A oscilação entre os anos é contextual e independe do sistema, que ainda não operava em tempo real e foi aplicado retrospectivamente para testar sua capacidade de detecção. Na janela principal de noventa dias, o treino reuniu as 2.404 matrículas de 2023 ativas ao final do corte, e o teste avaliou as 1.650 matrículas de 2024 na mesma condição, contabilizando 287 evasões (taxa base de 17,4%).

O modelo foi desenvolvido especificamente para o contexto da Aprendizagem Profissional, dadas suas características institucionais e pedagógicas particulares, incluindo o regime dual de formação (trabalho + estudo), perfil socioeconômico dos estudantes e especificidades do vínculo regido pela Consolidação das Leis do Trabalho (CLT). Os dados utilizados na modelagem incluíram indicadores comportamentais relacionados a acesso, participação, progressão acadêmica e interações no Ambiente Virtual de Aprendizagem, tais como:

- quantidade e frequência de acessos ao ambiente;
- percentual de progresso no curso e horas cursadas;
- atrasos em relação ao ritmo esperado de conclusão;
- realização (ou não) de atividades avaliativas;
- quando disponível, desempenho em avaliações.

Essas informações foram agregadas em bases históricas, pseudonimizadas para fins de pesquisa e estruturadas em variáveis (features) que alimentam o modelo de aprendizagem de máquina.

Tabela 1.
Perfil sociodemográfico dos estudantes do conjunto de dados

Característica	**Categoria**	**n (%)**
Faixa etária	14 a 17 anos	3.140 (68,3%)
	18 a 21 anos	1.402 (30,5%)
	22 a 24 anos	55 (1,2%)
	25 anos ou mais	1 (0,0%)
Gênero	Feminino	2.323 (50,5%)
	Masculino	2.275 (49,5%)
Escolaridade na matrícula	Ensino fundamental em curso ou concluído	450 (9,8%)
	Ensino médio em curso	2.762 (60,1%)
	Ensino médio concluído	1.349 (29,3%)

	Ensino superior em curso ou concluído	37 (0,8%)
Coorte de matrícula	2023	2.682 (58,3%)
	2024	1.916 (41,7%)
Desfecho	Evadidos	942 (20,5%)
	Não evadidos	3.656 (79,5%)

Nota. N = 4.598 matrículas com desfecho registrado nas coortes de 2023 e 2024. Idade calculada na data da matrícula, com mediana de 17,2 anos. Percentuais referentes ao total de matrículas.

O estudo não foi submetido a Comitê de Ética em Pesquisa. Os autores o conduziram como avaliação institucional de um sistema de apoio à gestão acadêmica, sobre registros administrativos já existentes, coletados pela instituição no curso regular da matrícula e da oferta dos cursos, e não como pesquisa com seres humanos que envolva intervenção ou coleta primária junto aos estudantes. O tratamento dos dados pessoais observou a Lei Geral de Proteção de Dados, com acesso restrito à equipe técnica da instituição. Os identificadores diretos foram substituídos por códigos antes da análise, e nenhum dado que permita identificar estudantes consta deste artigo nem dos arquivos de resultado. Os autores reconhecem que a vinculação de registros em nível individual, ainda que pseudonimizada, situa o estudo em zona que recomenda apreciação ética formal, e registram essa ausência como limitação.

3.2. Modelagem Preditiva

O modelo preditivo utiliza o algoritmo XGBoost (Chen & Guestrin, 2016), selecionado após avaliação comparativa com outros métodos de conjunto de árvores: LightGBM (*gradient boosting*) e *Random Forest* (agregação *bootstrap*). A escolha baseou-se no desempenho na partição de validação, visto que os três algoritmos são compatíveis com o *TreeExplainer* do SHAP. Os hiperparâmetros foram otimizados por busca aleatória (60 tentativas e semente fixa), avaliando o AUC nos 25% mais recentes do treino conforme a data de matrícula. Para cada estudante, o modelo processa variáveis comportamentais e acadêmicas e gera um escore de risco entre 0 e 1.Na validação retroativa por *split* temporal (treino em 2023, n = 2.404; teste em 2024, n = 1.650), a separação anual impede que colegas de turma coexistam no treino e no teste e simula a operação real entre coortes sucessivas. Matrículas desligadas antes do fim da janela de observação foram excluídas, pois a interrupção de atividade apenas reflete o desligamento já consumado. O conjunto de teste não participou de nenhuma etapa de seleção de variáveis, hiperparâmetros ou ponto de operação, sendo consultado uma única vez por modelo. O desempenho foi avaliado por métricas amplamente aceitas na literatura, a saber AUC, *KS Statistic*, *Recall* e Precisão.

- AUC (Área sob a Curva ROC): sintetiza a capacidade do modelo de diferenciar estudantes que evadiram daqueles que permaneceram. A curva ROC (*Receiver Operating Characteristic*) relaciona a taxa de verdadeiros positivos à taxa de falsos positivos ao longo dos possíveis pontos de corte, e a área sob ela varia de 0 a 1, com 0,5 correspondendo ao acaso. A interpretação de valores de AUC em contextos educacionais segue os padrões técnicos vigentes do N*ational Center on Intensive Intervention* (NCII, 2025), que estabelece AUC maior ou igual a 0,80 como evidência convincente de acurácia classificatória, entre 0,70 e 0,80 como parcialmente convincente, e abaixo de 0,70 como não convincente. Bowers e Zhou (2019) discutem o uso da curva ROC como medida diagnóstica em pesquisa educacional, com foco em indicadores de evasão na educação básica, e Queiroga et al. (2020) adotam outra régua, a de Gašević et al. (2016), na qual valores entre 0,50 e 0,70 já configuram discriminação aceitável. O patamar de 0,70, limite inferior da faixa parcialmente convincente, tem sido tomado como referência mínima em estudos dessa natureza. A Seção 5 examina a pertinência desse parâmetro e justifica o seu abandono como referência deste estudo.

- Recall (sensibilidade): proporção dos estudantes que efetivamente evadiram e que foram incluídos na lista de maior risco produzida pelo modelo.

- Precisão (*precision*): proporção dos estudantes incluídos na lista de maior risco que de fato evadiram.

- *KS Statistic*: mede o grau de separação entre as distribuições de risco dos grupos que evadiram e que não evadiram, calculada sobre todo o conjunto de teste e independente de qualquer ponto de corte. Quanto maior, melhor o modelo distingue esses dois grupos.

Para servir de referência, foram calculados dois *baselines*. O primeiro é um classificador ingênuo, que prediz sempre a classe majoritária, ou seja, não evasão. O segundo é um classificador informado, construído apenas com a modalidade e o mês de matrícula, que reproduz o que seria possível antecipar sem qualquer informação comportamental. Os resultados de ambos são reportados na subseção 4.4.

Métodos de explicabilidade foram incorporados, em especial SHAP (Lundberg & Lee, 2017), técnica baseada na teoria dos jogos que quantifica a contribuição de cada variável para cada predição. Valores positivos aumentam o risco estimado e valores negativos o diminuem. A abordagem oferece explicabilidade global, ao identificar os fatores mais influentes no modelo como um todo, e local, ao justificar o risco de cada estudante individualmente. É essa segunda dimensão que transforma uma pontuação numérica em informação acionável para as equipes pedagógicas, por permitir compreender não apenas que um estudante está em risco, mas por quê.

3.3. Integração Operacional

O painel atende analistas e instrutores, exibindo a lista de estudantes de cada turma ordenada decrescentemente pelo escore e faixa de risco, com filtros por curso, unidade e risco e opção de exportação. O perfil individual apresenta as variáveis de maior contribuição calculadas via SHAP e traduzidas em linguagem corrente, além de horas cursadas, horas previstas e percentual de progresso. A equipe pedagógica registra as intervenções em planos individuais contendo atividades, prazos e situação. Os escores são atualizados semanalmente, e o sistema armazena logs de execução e o histórico longitudinal de risco e de ações por estudante, garantindo rastreabilidade e auditabilidade ao fluxo de *learning analytics*.

3.4 Ambiente computacional

Os experimentos foram executados em ambiente Windows, com *Python* 3.11.9 em ambiente virtual isolado. Os modelos foram implementados com XGBoost 2.1.3, e as métricas e a calibração de probabilidades com *scikit-learn* 1.5.2. A manipulação e a agregação dos dados utilizaram pandas 2.2.3, numpy 2.1.2 e *scipy* 1.13.1. As explicações individuais foram calculadas com SHAP 0.46.0, e a busca de hiperparâmetros foi implementada com *numpy*, por amostragem aleatória com semente fixa. O processamento foi realizado em processador Intel Core i7-13700 de 13ª geração, com 16 núcleos e 24 processadores lógicos, e 32 GB de memória RAM, sem uso de unidade de processamento gráfico.

4. Resultados

4.1 Descrição do experimento

Seguindo o recorte de treino (coorte 2023) e teste (coorte 2024) definido na Seção 3, as variáveis foram calculadas em janelas de trinta, sessenta e noventa dias contados da matrícula, descartando-se qualquer evento posterior a cada corte.

A análise de importância por SHAP indicou predomínio de indicadores comportamentais de engajamento no Ambiente Virtual de Aprendizagem entre as dez variáveis de maior contribuição média. Em primeiro lugar está a tendência semanal de interações, com importância média absoluta de 0,062, seguida pela idade na matrícula, com 0,044, e pela tendência semanal de acessos, com 0,043. Completam a lista as semanas sem acesso e as horas cursadas, ambas com 0,034, o segundo maior intervalo sem acesso, com 0,028, a nota média normalizada e o percentual do curso concluído em relação à turma, ambos com 0,026, o desvio dos dias com acesso em relação à mediana da turma, com 0,021, e o progresso esperado da turma, com 0,018. Das dez variáveis, apenas a idade na matrícula é atributo fixo no momento da entrada, e as nove restantes descrevem comportamento, desempenho ou ritmo registrados ao longo do curso. A Figura 1 apresenta a ordenação completa por magnitude de contribuição média absoluta.

Figura 1.
Principais fatores de risco segundo os valores SHAP

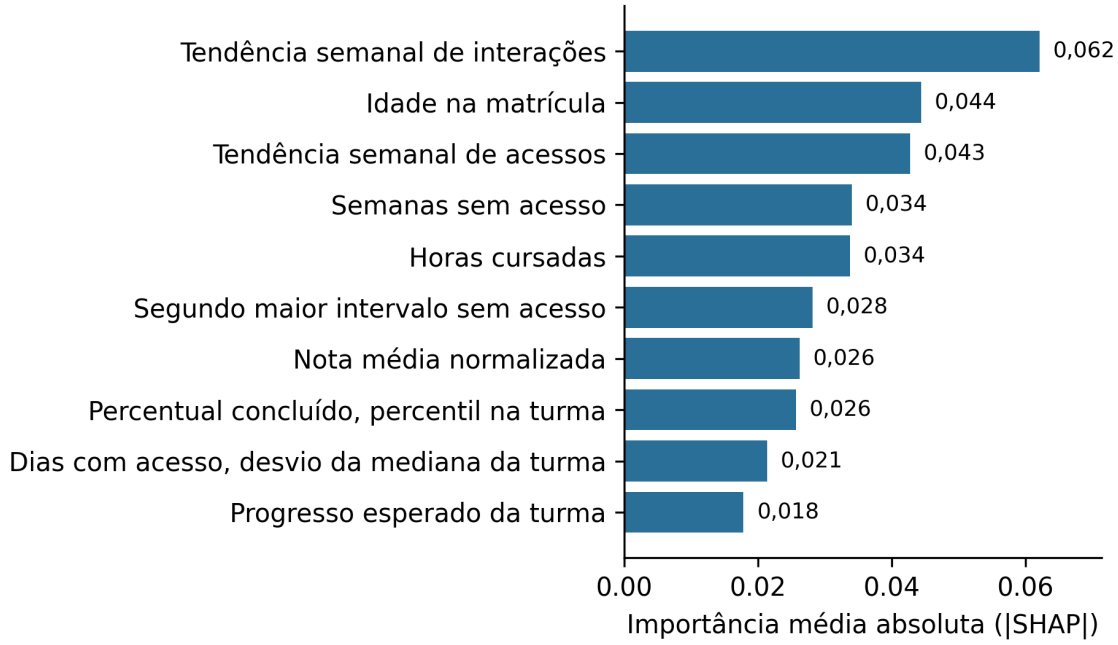

Fonte: (Autores)

4.2. Configuração ótima de hiperparâmetros

A busca de hiperparâmetros percorreu sessenta combinações sorteadas por amostragem aleatória com semente fixa. Cada combinação foi ajustada sobre os primeiros 75% da coorte de 2023, ordenados por data de matrícula, e avaliada sobre os 25% mais recentes dessa mesma coorte, a partir de 18 de agosto de 2023. A coorte de 2024 não participou de nenhuma etapa da seleção, de modo que o conjunto de teste permaneceu intocado até a medição final. A combinação escolhida foi a de número treze, cujos valores constam na Tabela 2.

Tabela 2.
Hiperparâmetros explorados e valores escolhidos na busca aleatória

Hiperparâmetro	Faixa explorada	Valor escolhido
max_depth	{2, 3, 4, 5, 6}	3
learning_rate	0,010 a 0,200 (escala logarítmica)	0,013
n_estimators	{100, 200, 300, 400, 500}	100
subsample	0,600 a 1,000	0,889
colsample_bytree	0,400 a 1,000	0,677
min_child_weight	{1, 3, 5, 10, 20}	10
reg_lambda	0,500 a 20,000 (escala logarítmica)	3,174
gamma	0,000 a 2,000	0,305

scale_pos_weight	{1,000; 4,789}	1,000

4.3 Curva ROC

A Figura 2 apresenta a Curva ROC do modelo para APQ-EaD. A curva situa-se acima da linha diagonal que representa desempenho aleatório, e a área sob a curva, de 0,570, supera os 0,496 do classificador de referência. A distância modesta em relação à diagonal indica que, ao variar o ponto de corte, o ganho sobre a classificação trivial permanece limitado.

Figura 2.
Curva ROC

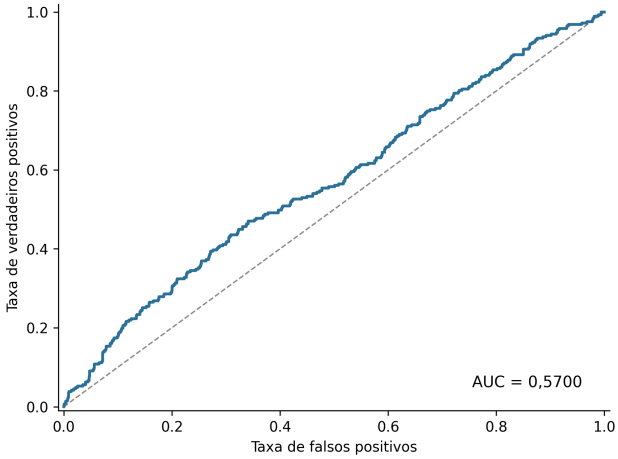

Fonte: (Autores)

4.4 Métricas de classificação e explicabilidade

O modelo para cursos de APQ-EaD alcançou AUC de 0,570, com intervalo de confiança de 95% entre 0,533 e 0,607, na janela de noventa dias contados da matrícula. O classificador de referência, construído apenas com modalidade e mês de matrícula, alcançou 0,496, com intervalo entre 0,462 e 0,535. Na prática, ao comparar aleatoriamente um estudante que evadiu com outro que não evadiu dentro do segmento de Aprendizagem Profissional, o modelo atribui maior risco ao primeiro em cerca de 57% dos pares. A diferença pareada entre os dois é de 0,074, com intervalo de confiança entre 0,021 e 0,129, que exclui o zero. Existe, portanto, sinal comportamental demonstrado, ainda que de magnitude reduzida.

Na janela de trinta dias o AUC foi de 0,515, com intervalo entre 0,482 e 0,551, e na de sessenta dias foi de 0,548, com intervalo entre 0,513 e 0,584. Em nenhuma dessas duas janelas a diferença em relação ao classificador de referência exclui o zero, respectivamente 0,022 com intervalo de menos 0,028 a 0,072 e 0,053 com intervalo de menos 0,000 a 0,103. A capacidade discriminativa cresce com a extensão da janela de observação, e somente aos noventa dias ela se distingue do acaso informado. O sistema depende, portanto, do acúmulo de comportamento registrado e não possui valor demonstrado como alerta nas primeiras semanas após a matrícula.

Como métrica operacional adotou-se a lista dos estudantes de maior risco, e não um limiar fixo de classificação, porque as equipes pedagógicas trabalham com capacidade de atendimento definida e não com um corte de probabilidade. Entre os 20% de maior risco, o modelo recuperou 27,9% dos estudantes que efetivamente evadiram, com precisão de 24,2%. Como a taxa de evasão no conjunto de teste é de 17,4%, a lista concentra 1,4 vez mais evasões do que uma seleção aleatória de mesmo tamanho. O limiar de 0,40, usual na literatura para fins de comparação, produz poucos alertas nesta base, uma vez que com taxa de evasão de 17,4% as probabilidades estimadas concentram-se abaixo desse valor. A definição do ponto de operação constitui decisão institucional, e não técnica, e deve ser revisada conforme a capacidade de atendimento.

A *KS Statistic* do modelo foi de 0,129 na janela de noventa dias, 0,074 na de sessenta e 0,048 na de trinta. O classificador ingênuo descrito na subseção 3.2, que prediz sempre a classe majoritária, atinge acurácia de 82,6% no conjunto de teste, com Recall nulo para a classe de evasão e AUC de 0,500 por

construção, o que confirma a inadequação da acurácia como métrica neste contexto.

A integração operacional demonstrou estabilidade no processamento de dados reais. As coortes analisadas abrangem 136 turmas de Aprendizagem Profissional, e todas as 136 contam com pelo menos uma matrícula vinculada aos registros do Ambiente Virtual de Aprendizagem. A vinculação utilizou o código do estudante registrado no Ambiente Virtual de Aprendizagem, confrontado de forma independente com o endereço eletrônico, e alcançou 4.591 das 4.598 matrículas, o que corresponde a 99,8%. A qualidade e a completude dos dados de entrada condicionam a eficácia do sistema, problema que Sculley et al. (2015) descrevem para modelos em produção e que aqui se manifesta na etapa de vinculação de registros. O painel entrega às equipes a lista ordenada por escore, as explicações individualizadas e o histórico auditável de ações, em linha com as recomendações de transparência e rastreabilidade para *learning analytics* (Drachsler & Greller, 2016; Slade & Prinsloo, 2013). A Figura 3 apresenta o painel operacional em uso.

Figura 3.
Painel operacional de monitoramento

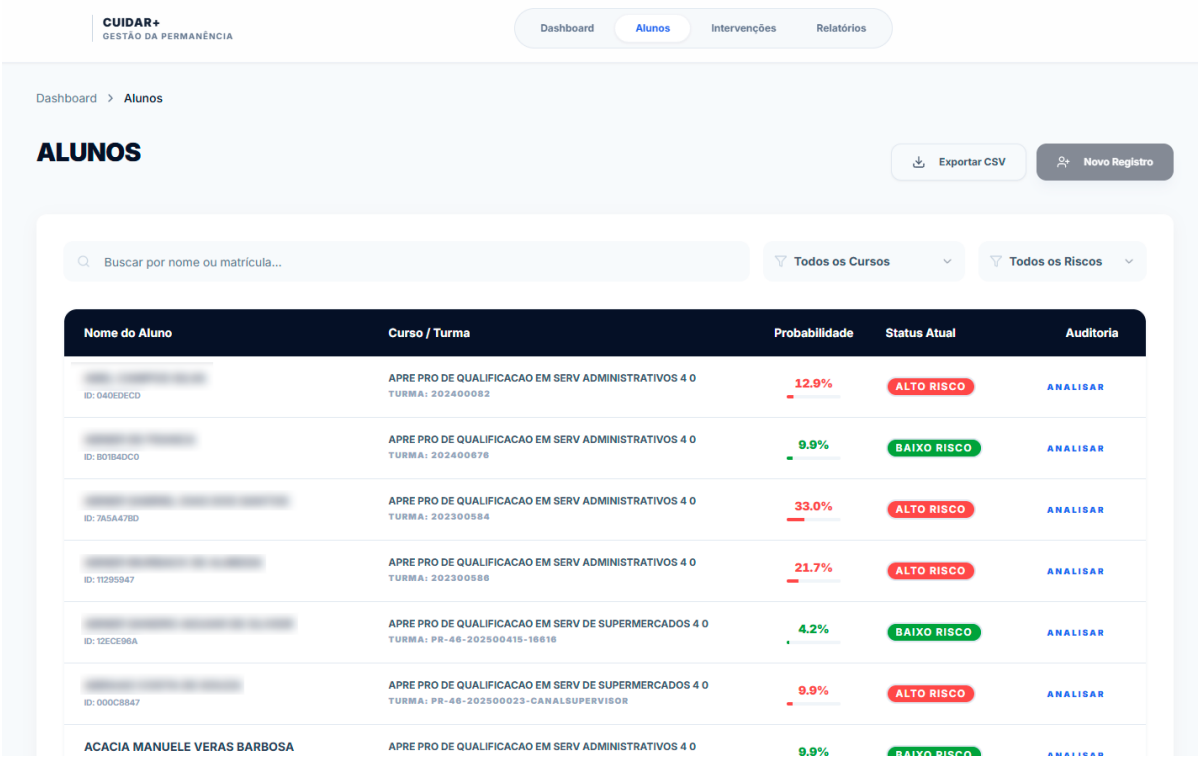

Fonte: Cuidar+ (Autores)

4.5. Estratégias de melhoria e análise do patamar observado

O modelo de referência foi construído por acréscimos sucessivos a partir de um conjunto inicial de trinta e uma variáveis acadêmicas e de atividade. Quatro etapas foram avaliadas de forma encadeada, cada uma comparada à anterior por diferença pareada de AUC com intervalo de confiança de 95% obtido por reamostragem. A inclusão de variáveis de trajetória semanal de engajamento rendeu 0,029 na janela de noventa dias, com intervalo de 0,005 a 0,050, e é a única etapa cujo intervalo exclui o zero. A normalização da atividade em relação à turma rendeu 0,000, com intervalo de menos 0,021 a 0,023. A remoção de variáveis sem variação útil rendeu 0,010, com intervalo de menos 0,005 a 0,025. O ajuste de hiperparâmetros rendeu menos 0,007, com intervalo de menos 0,031 a 0,017. Nas janelas de trinta e de sessenta dias nenhuma das quatro etapas produziu ganho cujo intervalo excluísse o zero.

O efeito acumulado das quatro etapas sobre o conjunto inicial é de 0,032 na janela de noventa dias, com intervalo de menos 0,001 a 0,064 (incluindo o zero e, portanto, sem evidência robusta de ganho real), enquanto o ganho do modelo final sobre o classificador de modalidade e mês é de 0,074, com

intervalo de 0,021 a 0,129 (excluindo o zero e confirmando a superioridade do modelo). Registra-se que o modelo imediatamente anterior ao ajuste de hiperparâmetros apresenta AUC ligeiramente superior ao do modelo final na janela de noventa dias. O modelo final foi mantido por ter sido declarado como referência antes da medição, e substituí-lo pelo melhor desempenho observado no conjunto de teste configuraria seleção sobre o próprio teste. Registra-se também que o conjunto de comparações realizadas ao longo da investigação não recebeu correção para múltiplos testes, de modo que os intervalos nominais são otimistas e um intervalo cujo limite inferior se aproxima de zero não constitui evidência forte.

Para verificar se o desempenho decorreria de diferenças entre cursos e não de comportamento individual, comparou-se o modelo com e sem os atributos calculados em relação à turma. A diferença pareada é de 0,000 na janela de noventa dias, com intervalo de menos 0,021 a 0,023, que inclui o zero. A capacidade discriminativa observada não se explica, portanto, por características do curso.

A extensão da janela de observação foi avaliada em seis valores, de trinta a cento e oitenta dias, mantidos o modelo, o mesmo procedimento de ajuste e a mesma separação por coortes. A Tabela 3 reúne os resultados. O AUC cresce de 0,515 na janela de trinta dias para 0,640 na de cento e cinquenta, e o ganho sobre o classificador de modalidade e mês passa de 0,022, com intervalo que inclui o zero, para 0,138, com intervalo entre 0,087 e 0,193. A *KS Statistic* acompanha o movimento, de 0,048 para 0,217, assim como o *recall* entre os 20% de maior risco, que passa de 21,8% para 33,7%. Na janela de cento e oitenta dias o desempenho recua para 0,617, de modo que o crescimento não é estritamente monótono. O conjunto desses valores sustenta de forma direta a hipótese de desencontro de horizonte, pois o sinal comportamental existe e se torna mensurável à medida que a janela se aproxima do tempo típico até o desligamento.

Tabela 3.
Desempenho do modelo por extensão da janela de observação

Janela	n teste	Taxa base	AUC (IC 95%)	Baseline (IC 95%)	Diferença (IC 95%)	KS	Recall top 20%
30 dias	1.675	18,6%	0,515 (0,482 a 0,551)	0,493 (0,460 a 0,528)	0,022 (-0,028 a 0,072)	0,048	21,8%
60 dias	1.662	18,0%	0,548 (0,513 a 0,584)	0,495 (0,460 a 0,530)	0,053 (-0,000 a 0,103)	0,074	25,1%
90 dias	1.650	17,4%	0,570 (0,533 a 0,607)	0,496 (0,462 a 0,535)	0,074 (0,021 a 0,129)	0,129	27,9%
120 dias	1.628	16,3%	0,585 (0,546 a 0,622)	0,500 (0,465 a 0,536)	0,085 (0,035 a 0,134)	0,139	29,1%
150 dias	1.609	15,3%	0,640 (0,601 a 0,679)	0,502 (0,466 a 0,536)	0,138 (0,087 a 0,193)	0,217	33,7%
180 dias	1.577	13,6%	0,617 (0,575 a 0,658)	0,491 (0,454 a 0,529)	0,125 (0,063 a 0,182)	0,172	31,8%

Três ressalvas delimitam a interpretação da Tabela 3. A primeira é que as janelas não avaliam a mesma população, uma vez que matrículas cujo desligamento ocorre antes do encerramento da janela são

excluídas. Como consequência, o conjunto de teste reduz de 1.675 para 1.577 matrículas e a taxa base diminui de 18,6% para 13,6%. A comparação entre janelas, portanto, combina efeitos de ganho de informação e mudança de composição do conjunto avaliado.

A segunda ressalva é que janelas mais longas proporcionam menor antecedência para intervenção. Aos cento e oitenta dias já ocorreram 30,7% dos desligamentos do período, de modo que o ganho estatístico vem acompanhado de perda operacional.

A terceira é que a janela de noventa dias foi previamente definida como referência antes da medição e assim permanece. As demais janelas são apresentadas como análises secundárias, e não como uma seleção do melhor resultado observado no conjunto de teste.

Duas características dos dados explicam o patamar observado. A primeira é o desencontro entre a janela de observação e o horizonte do evento de interesse. Entre as matrículas que resultaram em evasão, a mediana entre a matrícula e o desligamento é de 232 dias, e apenas 8,4% dos desligamentos ocorrem em até noventa dias, alcançando 30,7% em até cento e oitenta dias. Assim, o modelo observa de trinta a noventa dias de comportamento para estimar um evento que, tipicamente, se consuma meses depois, em um curso cuja duração mediana é de 374 dias.

A segunda é a composição do desfecho. Entre os motivos de saída registrados no período, cerca de um terço não guarda relação com comportamento acadêmico, incluindo obtenção de outro emprego, mudança de cidade e efetivação na empresa concedente. A efetivação constitui o melhor desfecho possível da Aprendizagem no regime da Consolidação das Leis do Trabalho e, quando classificada como evasão, introduz erro no rótulo. Comportamento registrado no Ambiente Virtual de Aprendizagem não contém informação sobre esse subconjunto de saídas, o que impõe teto ao desempenho alcançável com as variáveis disponíveis.

5. Discussão

Os resultados desta fase retroativa demonstram que a adoção de Inteligência Artificial para a gestão da permanência é tecnicamente viável e operacionalmente sustentável no contexto institucional. O modelo para APQ-EaD alcançou AUC de 0,570 na janela de noventa dias. Esse valor fica abaixo da meta de 0,70 derivada dos padrões do *National Center on Intensive Intervention* (NCII, 2025), e cabe examinar a pertinência desse parâmetro. Os critérios do NCII foram formulados para ferramentas de triagem acadêmica na educação básica, nas quais o preditor e o desfecho medem essencialmente a mesma competência em dois momentos, condição que favorece valores elevados de AUC. Prever evasão é tarefa de outra natureza, pois envolve um evento futuro determinado em parte por circunstâncias que nenhum registro educacional captura. Transpor o limiar de triagem para esse contexto confunde duas tarefas distintas, e este estudo deixa de adotá-lo como referência.

Os resultados podem ser comparados com Huo et al. (2023), que obtiveram AUC de 0,8713 no modelo 2, com variáveis selecionadas, e com Gonzalez-Nucamendi et al. (2023), que relataram precisão de 13,2% na classe de evasão com o corte padrão de 0,5. Mustofa et al. (2025) relataram acurácia de 96%, mas agruparam estudantes graduados e matriculados como não evadidos. Essas diferenças de população, de rótulo e de métrica limitam a comparação direta. O presente estudo obteve AUC de 0,570 na janela de noventa dias, valor inferior ao de todos os trabalhos citados, o que decorre menos do método e mais da cobertura dos dados disponíveis, conforme se argumenta na sequência. A comparação mais próxima vem de Baig et al. (2026), que preveem ruptura de contrato de aprendizagem na França com 3.511 contratos correspondentes a 2.935 aprendizes e alcançam AUC de 0,9253. O dado decisivo está na tabela de comparação daquele estudo: o XGBoost isolado, o mesmo algoritmo empregado aqui, atinge AUC de 0,9255, acima do próprio modelo proposto pelos autores. A distância em relação aos 0,570 obtidos neste trabalho não decorre, portanto, da escolha do algoritmo. Aquele estudo observa o vínculo de trabalho, por meio de avaliações de competência produzidas pelo aprendiz, pelo mestre na empresa e pelo tutor da instituição formadora, com participação adicional do gestor do portfólio digital em parte dos contratos. O sistema descrito neste artigo observa apenas o Ambiente Virtual de Aprendizagem. Registre-se que Baig et al. não informam o horizonte de predição e que as contagens de contratos e de estudantes divergem entre a Tabela 1 e o corpo do texto daquele artigo.

Essa diferença reorganiza a leitura dos resultados. A Aprendizagem Profissional é formação em regime *dual*, e o percurso do estudante se reparte entre a escola e a empresa concedente. O *pipeline* aqui descrito instrumenta apenas a primeira metade. O terço de saídas sem relação com comportamento acadêmico que a análise identificou, com obtenção de outro emprego, mudança de cidade e efetivação,

não constitui ruído aleatório, e sim o sinal que reside precisamente na metade não observada. Baig et al. (2026) instrumentaram essa metade. O desempenho obtido neste estudo indica, portanto, limite de cobertura dos dados, e não limite do método.

O ponto de operação do sistema envolve *trade-off* entre cobertura e capacidade de atendimento (Ferguson, 2012; Arnold & Pistilli, 2012). Considerando que cada intervenção pedagógica estruturada demanda de trinta a sessenta minutos de trabalho tutorial, entre contato inicial, diagnóstico de situação e encaminhamento institucional, a lista de risco precisa ser dimensionada pela capacidade real da equipe. Com o desempenho medido, uma lista correspondente aos 20% de maior risco recupera 27,9% das evasões, contra os 20% que uma seleção aleatória recuperaria, o que significa que a maior parte dos casos não é sinalizada e que parte dos alertas recai sobre estudantes que não evadiriam. Esse resultado não sustenta o uso do sistema como substituto do acompanhamento pedagógico regular, e sim como um critério adicional de priorização entre estudantes já acompanhados.

As explicações locais mudam o que chega à equipe pedagógica. Em vez de um número, o tutor lê que o estudante está há dezoito dias sem acessar o ambiente, ou que o seu ritmo está 40% abaixo do esperado para a turma. Ferguson (2012) argumenta que o valor analítico aparece no processo decisório que a informação alimenta, e não na previsão isolada. Interpretar esse diagnóstico e convertê-lo em plano de intervenção exige competência digital e pedagógica das equipes tutoriais (Pérez-López & Alzás García, 2023), inclusive para diversificar estratégias de reengajamento e adequar recursos digitais aos estilos de aprendizagem dos estudantes (Campos Ortuño et al., 2023), o que desloca parte do esforço de implantação da técnica para a formação de quem opera o painel.

A experiência relatada mostra que é possível implementar técnicas de aprendizagem de máquina e *learning analytics* de forma gradual e institucionalizada, com um modelo tecnicamente confiável, *pipeline* rastreável com logs de execução auditáveis e painel de uso cotidiano integrado às rotinas pedagógicas, respeitando os limites reais de infraestrutura, cultura institucional e maturidade analítica (Lima et al., 2022). A experiência também indica que, em sistemas preditivos aplicados, a definição do desfecho e o alinhamento entre janela de observação e horizonte do evento são tão determinantes para o resultado quanto a escolha do algoritmo, resultado consistente com as observações de Sculley et al. (2015) sobre dívida técnica oculta em sistemas de aprendizagem de máquina em produção.

6. Conclusão

O estudo apresentou o desenvolvimento e a validação técnica de um *pipeline* preditivo voltado à permanência discente em cursos da Aprendizagem Profissional a Distância. O sistema combina modelagem preditiva, engenharia de dados e integração operacional, e entrega às equipes pedagógicas um painel com lista priorizada de estudantes, explicações individualizadas via SHAP e registro auditável de intervenções.

Os resultados confirmam a viabilidade operacional da infraestrutura, mas revelam capacidade preditiva modesta. Aos noventa dias, o modelo alcançou AUC de 0,570, superando o *baseline* de modalidade e mês (0,496; diferença de 0,074), enquanto aos trinta dias não houve ganho distinguível. Entre as quatro melhorias testadas, apenas a trajetória semanal de engajamento gerou ganho significativo, e a ampliação da janela para cento e cinquenta dias elevou o AUC a 0,640.

Duas características estruturais explicam esse teto. A primeira é a mediana de 232 dias até o desligamento (apenas 8,4% ocorrem até noventa dias), desencontro de horizonte confirmado pela melhora do modelo em janelas mais longas. A segunda é a presença de cerca de um terço de saídas extra-acadêmicas, incluindo a efetivação na empresa concedente, que configura sucesso formativo e não evasão. Nenhuma dessas barreiras cede a ajustes algorítmicos, pois ambas decorrem de o pipeline monitorar apenas a metade escolar de uma formação *dual*.

Baig et al. (2026), trabalhando com aprendizes franceses e utilizando avaliações de competência do empregador, do tutor e do próprio aprendiz, alcançaram AUC de 0,9253. O contraste sugere que o caminho para melhorar a predição neste contexto passa por instrumentar o vínculo de trabalho, com registros estruturados de acompanhamento do tutor e retorno periódico da empresa concedente, e não por refinamento adicional do modelo sobre registros do Ambiente Virtual de Aprendizagem.

A contribuição deste trabalho está menos no desempenho alcançado e mais na documentação de uma implantação institucional completa, com controles explícitos contra vazamento entre treino e teste, validação temporal sem seleção sobre o conjunto de teste e identificação dos mecanismos que limitam a predição neste contexto formativo. Relatos de resultado negativo com explicação de mecanismo são

escassos na literatura de *Learning Analytics* aplicada à educação profissional, e essa ausência contribui para expectativas desalinhadas sobre o que sistemas preditivos entregam em operação real. A validação prospectiva, com acompanhamento de turmas em tempo real, permanece etapa necessária e não substituível por validação retroativa.

Cinco limitações delimitam o alcance destes resultados. O treino e o teste reuniram apenas matrículas com situação encerrada, enquanto o painel, em operação, pontua matrículas em curso, de modo que o desempenho medido não se transfere automaticamente para a população efetivamente monitorada. O conjunto de teste reuniu 1.650 matrículas com 287 evasões, o que produz intervalos de confiança de largura próxima a 0,07 e impede distinguir diferenças inferiores a 0,04 entre modelos. As comparações realizadas ao longo da investigação não receberam correção para múltiplos testes. Por fim, os motivos de saída estão disponíveis apenas para a coorte mais recente, o que impede, no momento, modelar separadamente a evasão por desengajamento e as saídas de natureza extra-acadêmica. Acrescente-se que a contagem de itens de conteúdo soma as salas de cada pessoa, e não as da matrícula específica, o que afeta os dezesseis estudantes com mais de uma turma no período.

Como trabalhos futuros, propõe-se:

- a realização de um estudo prospectivo de impacto institucional, acompanhando, ao longo de um período maior, em que medida o uso sistemático do painel e das predições de risco se traduz em redução efetiva de evasão;

- o aprofundamento da análise de conteúdo textual das interações estudantis (mensagens, fóruns, diários), explorando técnicas de processamento de linguagem natural e análise de sentimentos para identificar sinais adicionais de desengajamento, linha já explorada em contextos de ensino superior (Grimalt-Álvaro & Usart, 2024; Shaik et al., 2023);

- a ampliação do *pipeline* para outros segmentos formativos e contextos institucionais, avaliando sua generalização e necessidade de ajustes locais.

- a reformulação do desenho preditivo para risco em tempo discreto com censura, contemplando as matrículas em curso, em vez de excluí-las, e alinhar a janela de observação ao horizonte efetivo do evento, acompanhada da obtenção dos motivos de saída para todas as coortes, a fim de distinguir a evasão por desengajamento das saídas de natureza extra-acadêmicas.

- a instrumentação do vínculo de trabalho, com coleta estruturada de avaliações do tutor e da empresa concedente, de modo a cobrir a metade do regime *dual* que hoje permanece fora do conjunto de variáveis.

Referências

Araújo da Silva, K. K. y Behar, P. A. (2023). Modelo de Competências Digitais para alunos na Educação a Distância: revisão e atualização de uma proposta brasileira. Revista de Estilos de Aprendizaje, 16 (32), 5-18. https://doi.org/10.55777/rea.v16i31.5399

Arnold, K. E. y Pistilli, M. D. (2012). Course Signals at Purdue: Using Learning Analytics to Increase Student Success. Proceedings of the 2nd International Conference on Learning Analytics and Knowledge, 267-270. https://doi.org/10.1145/2330601.2330666

Baig, D.; Nurbakova, D.; Calabretto, S. y Mbaye, B. (2026). An Ensemble Stacking with Perception-aware Meta-learning (ESPM) for Apprenticeship Dropout Prediction in France. Proceedings of the 19th International Conference on Educational Data Mining, 415-421. https://doi.org/10.5281/zenodo.21039699

Baker, R. S. y Inventado, P. S. (2014). Educational data mining and learning analytics. En J. A. Larusson y B. White (Eds.), Learning analytics: From research to practice (pp. 61-75). Springer. https://doi.org/10.1007/978-1-4614-3305-7_4

Bowers, A. J. y Zhou, X. (2019). Receiver Operating Characteristic (ROC) Area Under the Curve (AUC): A Diagnostic Measure for Evaluating the Accuracy of Predictors of Education Outcomes. Journal of Education for Students Placed at Risk (JESPAR), 24(1), 20-46. https://doi.org/10.1080/10824669.2018.1523734

Campos Ortuño, R.; Hernández-Serrano, M. J.; Renes-Arellano, P. y Lena-Acebo, F. J. (2023). Los Recursos Educativos Abiertos adaptados a estilos de aprendizaje en la enseñanza de competencias digitales en educación superior. Revista de Estilos de Aprendizaje, 16(31), 4-18. https://doi.org/10.55777/rea.v16i31.4602

Chen, T. y Guestrin, C. (2016). XGBoost: A scalable tree boosting system. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 785-794. https://doi.org/10.1145/2939672.2939785

Drachsler, H. y Greller, W. (2016). Privacy and analytics, it's a DELICATE issue. A checklist for trusted learning analytics. Proceedings of the Sixth International Conference on Learning Analytics and Knowledge, 89-98. https://doi.org/10.1145/2883851.2883893

Ferguson, R. (2012). Learning analytics: drivers, developments and challenges. International Journal of Technology Enhanced Learning, 4(5/6), 304-317. https://doi.org/10.1504/IJTEL.2012.051816

Gašević, D.; Dawson, S.; Rogers, T. y Gasevic, D. (2016). Learning analytics should not promote one size fits all: The effects of instructional conditions in predicting academic success. The Internet and Higher Education, 28, 68–84. https://doi.org/10.1016/j.iheduc.2015.10.002

Gonzalez-Nucamendi, A.; Noguez, J.; Neri, L.; Robledo-Rella, V. y García-Castelán, R. M. G. (2023). Predictive analytics study to determine undergraduate students at risk of dropout. Frontiers in Education, 8, Article 1244686. https://doi.org/10.3389/feduc.2023.1244686

Grimalt-Álvaro, C. y Usart, M. (2024). Sentiment analysis for formative assessment in higher education. A systematic literature review. Journal of Computing in Higher Education, 36, 647-682. https://doi.org/10.1007/s12528-023-09370-5

Hernández-de-Menéndez, M.; Morales-Menendez, R.; Escobar, C. A. y Ramírez Mendoza, R. A. (2022). Learning analytics: state of the art. International Journal on Interactive Design and Manufacturing (IJIDeM), 16(3), 1209-1230. https://doi.org/10.1007/s12008-022-00930-0

Huo, H.; Cui, J.; Hein, S.; Padgett, Z.; Ossolinski, M.; Raim, R. y Zhang, J. (2023). Predicting dropout for nontraditional undergraduate students: A machine learning approach. Journal of College Student Retention: Research, Theory & Practice, 24(4), 1054-1077. https://doi.org/10.1177/1521025120963821

Ke, G.; Meng, Q.; Finley, T.; Wang, T.; Chen, W.; Ma, W.; Ye, Q. y Liu, T.-Y. (2017). LightGBM: A highly efficient gradient boosting decision tree. Advances in Neural Information Processing Systems, 30, 3146-3154. https://dl.acm.org/doi/10.5555/3294996.3295074

Lima, A.; Monteiro, L. y Furtado, A. P. (2022). MLOps: Practices, maturity models, roles, tools, and challenges. A systematic literature review. Proceedings of the 24th International Conference on Enterprise Information Systems, 1, 308-320. https://doi.org/10.5220/0010997300003179

Lundberg, S. M. y Lee, S.-I. (2017). A unified approach to interpreting model predictions. Advances in Neural Information Processing Systems, 30, 4765-4774. https://doi.org/10.48550/arXiv.1705.07874

Marcolino, M.; Porto, T. R.; Primo, T. T.; Targino, R.; Ramos, V.; Queiroga, E. M.; Munoz, R. y Cechinel, C. (2025). Student dropout prediction through machine learning optimization: Insights from Moodle log data. Scientific Reports, 15, 9840. https://doi.org/10.1038/s41598-025-93918-1

Mustofa, S.; Emon, Y. R.; Mamun, S. B.; Akhy, S. A. y Ahad, M. T. (2025). A novel AI-driven model for student dropout risk analysis with explainable AI insights. Computers and Education: Artificial Intelligence, 8, Article 100352. https://doi.org/10.1016/j.caeai.2024.100352

National Center on Intensive Intervention. (2025). Academic screening tools chart: Technical review standards. Arlington, VA: American Institutes for Research. https://bit.ly/4nCowqe

Pérez-López, E. y Alzás García, T. (2023). La competencia digital y el uso de herramientas tecnológicas en el profesorado universitario. Revista de Estilos de Aprendizaje, 16(31), 69-81. https://doi.org/10.55777/rea.v16i31.5364

Queiroga, E. M.; Lopes, J. L.; Kappel, K.; Aguiar, M.; Araújo, R. M.; Munoz, R.; Villarroel, R. y Cechinel, C. (2020). A learning analytics approach to identify students at risk of dropout. A case study with a technical distance education course. Applied Sciences, 10(11), Article 3998. https://doi.org/10.3390/app10113998

Quimiz-Moreira, M.; Delgadillo, R.; Parraga-Alava, J.; Maculan, N. y Mauricio, D. (2025). Factors, prediction, explainability, and simulating university dropout through machine learning: A systematic review, 2012-2024. Computation, 13(8), 198. https://doi.org/10.3390/computation13080198

Rahmani, A. M.; Groot, W. y Rahmani, H. (2024). Dropout in online higher education. A systematic literature review. International Journal of Educational Technology in Higher Education, 21, Article 19. https://doi.org/10.1186/s41239-024-00450-9

Sculley, D.; Holt, G.; Golovin, D.; Davydov, E.; Phillips, T.; Ebner, D.; Chaudhary, V.; Young, M.; Crespo, J.-F. y Dennison, D. (2015). Hidden technical debt in machine learning systems. Advances in Neural Information Processing Systems, 28, 2503-2511.

Shaik, T.; Tao, X.; Dann, C.; Xie, H.; Li, Y. y Galligan, L. (2023). Sentiment analysis and opinion mining on educational data. A survey. Natural Language Processing Journal, 2, Article 100003. https://doi.org/10.1016/j.nlp.2022.100003

Slade, S. y Prinsloo, P. (2013). Learning analytics. Ethical issues and dilemmas. American Behavioral Scientist, 57(10), 1510-1529. https://doi.org/10.1177/0002764213479366

Tinto, V. (1993). Leaving College: Rethinking the Causes and Cures of Student Attrition (2ª ed.). University of Chicago Press.

Vaarma, M. y Li, H. (2024). Predicting student dropouts with machine learning: An empirical study in Finnish higher education. Technology in Society, 76, Article 102474. https://doi.org/10.1016/j.techsoc.2024.102474

Financiamento
O presente artigo não conta com financiamento específico para seu desenvolvimento e/ou publicação.

Agradecimentos
Os autores agradecem à equipe técnica, gestores e estudantes da instituição pelo apoio na coleta de dados e validação do sistema operacional.

Conflito de interesses
Os autores declaram que não existe conflito de interesses em relação à publicação deste artigo.

Contribuição dos autores
[Autor 1 removido para revisão cega] (50%): Conceituação institucional, revisão do artigo. [Autor 2 removido para revisão cega] (50%): Metodologia, desenvolvimento do sistema, análise de dados, implementação técnica e redação do artigo.

© 2026 by the authors. Submitted for open access publication under the terms and conditions of the Creative Commons