

MODELAGEM COGNITIVO- AFETIVA PARA TUTORIA INTELIGENTE: UM FRAMEWORK DE PERFIS E REGIMES PEDAGÓGICOS PARA O ENSINO DE PROGRAMAÇÃO

**COGNITIVE-AFFECTIVE MODELING FOR INTELLIGENT TUTORING: A
FRAMEWORK OF STUDENT PROFILES AND PEDAGOGICAL REGIMES FOR
PROGRAMMING EDUCATION**

Ciências Sociais Aplicadas • 15/07/2026

REGISTRO DOI: [10.70773/revistatopicos/783653574](https://doi.org/10.70773/revistatopicos/783653574)

Rafael Bianchini Glavam¹

Ronaldo T. P. Milfont²

Rossana M. C. Andrade³

Danilo R. Vasconcelos⁴

RESUMO

Este artigo apresenta um framework de modelagem cognitivo-afetiva para Sistemas Tutores Inteligentes voltados ao ensino de programação. A proposta parte do problema da evasão silenciosa, fenômeno no qual o estudante desengaja progressivamente da interação tutorial sem manifestação explícita, e argumenta que tutores que consideram apenas o desempenho cognitivo são insuficientes para sustentar a permanência do aprendiz. O framework modela o estado do estudante por meio de um vetor de quatro dimensões: maestria, engajamento, fadiga e progresso, fundamentado na Teoria da Carga Cognitiva, na Teoria da Autodeterminação e na Zona de Desenvolvimento Proximal. A partir desse vetor, define-se uma partição do espaço de estados em regimes pedagógicos qualitativos e um conjunto de sete ações instrucionais, além de quatro perfis estereotípicos de estudante. A viabilidade do framework é avaliada em um ambiente de simulação, no qual uma política de tutoria sensível ao estado afetivo reduz a taxa de evasão de 45,4% para 0,04% e atinge 74,6% de sucesso pedagógico. Os resultados indicam que a incorporação explícita de dimensões afetivas produz comportamentos pedagógicos diferenciados por contexto, oferecendo uma base conceitual replicável para o projeto de tutores inteligentes adaptativos.

Palavras-chave: Sistemas Tutores Inteligentes; modelagem cognitivo-afetiva; evasão silenciosa; ensino de programação; aprendizagem por reforço.

ABSTRACT

This article presents a cognitive-affective modeling framework for Intelligent Tutoring Systems applied to programming education. The proposal addresses the problem of silent dropout, a phenomenon in which the student progressively disengages from

the tutorial interaction without explicit manifestation, and argues that tutors considering only cognitive performance are insufficient to sustain learner retention. The framework models the student state through a four-dimensional vector: mastery, engagement, fatigue and progress, grounded in Cognitive Load Theory, Self-Determination Theory and the Zone of Proximal Development. From this vector, a partition of the state space into qualitative pedagogical regimes and a set of seven instructional actions are defined, along with four stereotypical student profiles. The feasibility of the framework is evaluated in a simulation environment, in which an affect-aware tutoring policy reduces the dropout rate from 45.4% to 0.04% and reaches 74.6% pedagogical success. The results indicate that the explicit incorporation of affective dimensions produces context-differentiated pedagogical behaviors, offering a replicable conceptual basis for the design of adaptive intelligent tutors.

Keywords: Intelligent Tutoring Systems; cognitive-affective modeling; silent dropout; programming education; reinforcement learning.

1. INTRODUÇÃO

Os Sistemas Tutores Inteligentes (STI) constituem uma das aplicações mais consolidadas da Inteligência Artificial à Educação, oferecendo instrução personalizada por meio da adaptação de conteúdos, sequências e formas de apoio às necessidades individuais do estudante (Woolf, 2021; Chen et al., 2020). No ensino de programação, em particular, a tutoria adaptativa apresenta potencial expressivo, dado que disciplinas introdutórias de programação concentram elevados índices de reprovação e abandono, frequentemente associados à frustração diante de erros, à sobrecarga cognitiva e à perda de motivação ao longo do percurso.

Um aspecto recorrentemente negligenciado nessa literatura é o fenômeno da evasão silenciosa, isto é, o desengajamento progressivo do estudante em relação à interação tutorial sem manifestação explícita de desistência. Esse fenômeno emerge da combinação entre queda de engajamento e acúmulo de fadiga cognitiva, e não é capturado por tutores que modelam exclusivamente o desempenho cognitivo do aprendiz. Estudos recentes confirmam que ainda não existem técnicas amplamente validadas para incorporar fatores afetivos e dinâmicos, como frustração acumulada, motivação flutuante ou fadiga, de forma robusta às políticas de tutoria (Roayaei, 2024).

Essa lacuna encontra respaldo em modelos consolidados da Psicologia da Educação. A Teoria da Carga Cognitiva postula que a aprendizagem efetiva é fortemente condicionada pela limitação da memória de trabalho, sendo prejudicada quando a carga imposta pela tarefa excede a capacidade do estudante (Sweller et al., 2011). A Teoria da Autodeterminação, por sua vez, destaca o papel da motivação intrínseca como condição necessária para a aprendizagem significativa (Ryan e Deci, 2000). Tais referenciais sugerem que a incorporação explícita de variáveis afetivas, como engajamento e fadiga, em modelos computacionais de tutoria é uma estratégia promissora para aproximar as decisões algorítmicas do comportamento real dos estudantes.

Diante desse cenário, este artigo tem como objetivo apresentar e fundamentar um framework de modelagem cognitivo-afetiva para tutoria inteligente no ensino de programação. O framework é composto por três elementos articulados: um vetor de estado do estudante com dimensões cognitivas e afetivas, uma partição do espaço de estados em regimes pedagógicos qualitativos e um

conjunto de ações instrucionais associado a perfis estereotípicos de aprendiz. Como objetivo secundário, avalia-se a viabilidade do framework por meio de um ambiente de simulação, verificando se uma política de tutoria sensível ao estado afetivo é capaz de sustentar o engajamento e reduzir a evasão.

A relevância da proposta reside em oferecer uma base conceitual replicável e teoricamente fundamentada para o projeto de tutores adaptativos, deslocando o foco da maximização isolada do ganho cognitivo para a sustentabilidade da trajetória de aprendizagem. As seções seguintes apresentam a fundamentação teórica (Seção 2), a descrição do framework e do ambiente de avaliação (Seção 3), os resultados obtidos em simulação (Seção 4) e as considerações finais (Seção 5).

2. FUNDAMENTAÇÃO TEÓRICA

Esta seção apresenta os referenciais que sustentam a definição das dimensões do framework. Cada dimensão cognitivo-afetiva é ancorada em uma teoria estabelecida da Psicologia da Educação ou da literatura de modelagem do estudante, de modo que o framework não seja uma escolha arbitrária de variáveis, mas uma operacionalização de construtos consolidados.

2.1. Maestria e a Modelagem do Conhecimento

A dimensão de maestria representa o nível estimado de domínio do estudante sobre o conteúdo em estudo. Essa noção é central na literatura de modelagem do conhecimento, na qual a estimativa contínua do estado de aprendizagem orienta a seleção de atividades e a progressão curricular (Woolf, 2021). No ensino de programação, a maestria pode ser associada ao domínio progressivo

de conceitos fundamentais, como variáveis, estruturas condicionais, estruturas de repetição e funções, que constituem uma sequência curricular cumulativa.

2.2. Fadiga e a Teoria da Carga Cognitiva

A dimensão de fadiga representa a sobrecarga cognitiva acumulada ao longo da interação. Sua fundamentação repousa na Teoria da Carga Cognitiva, segundo a qual a memória de trabalho possui capacidade limitada e a aprendizagem é comprometida quando a carga imposta pela tarefa excede essa capacidade (Sweller et al., 2011). No contexto da tutoria, intervenções cognitivamente exigentes aplicadas em sequência, sem gestão da sobrecarga, tendem a reduzir a eficácia do aprendizado. A fadiga atua, portanto, como um modulador da eficácia das ações pedagógicas: uma mesma intervenção pode ser produtiva em condições de baixa fadiga e contraproducente em condições de sobrecarga.

2.3. Engajamento e a Teoria da Autodeterminação

A dimensão de engajamento mensura o envolvimento e a prontidão do estudante na interação. Sua ancoragem teórica está na Teoria da Autodeterminação, que postula a motivação intrínseca como condição necessária para a aprendizagem significativa (Ryan e Deci, 2000). A Teoria de Controle-Valor das Emoções complementa essa perspectiva ao destacar o papel de estados afetivos, como interesse, frustração e tédio, na regulação do engajamento e da persistência do aluno (Pekrun e Linnenbrink-Garcia, 2012). A queda persistente de engajamento é o principal precursor da evasão silenciosa, o que torna essa dimensão decisiva para a sustentabilidade da interação.

2.4. Progresso e a Zona de Desenvolvimento Proximal

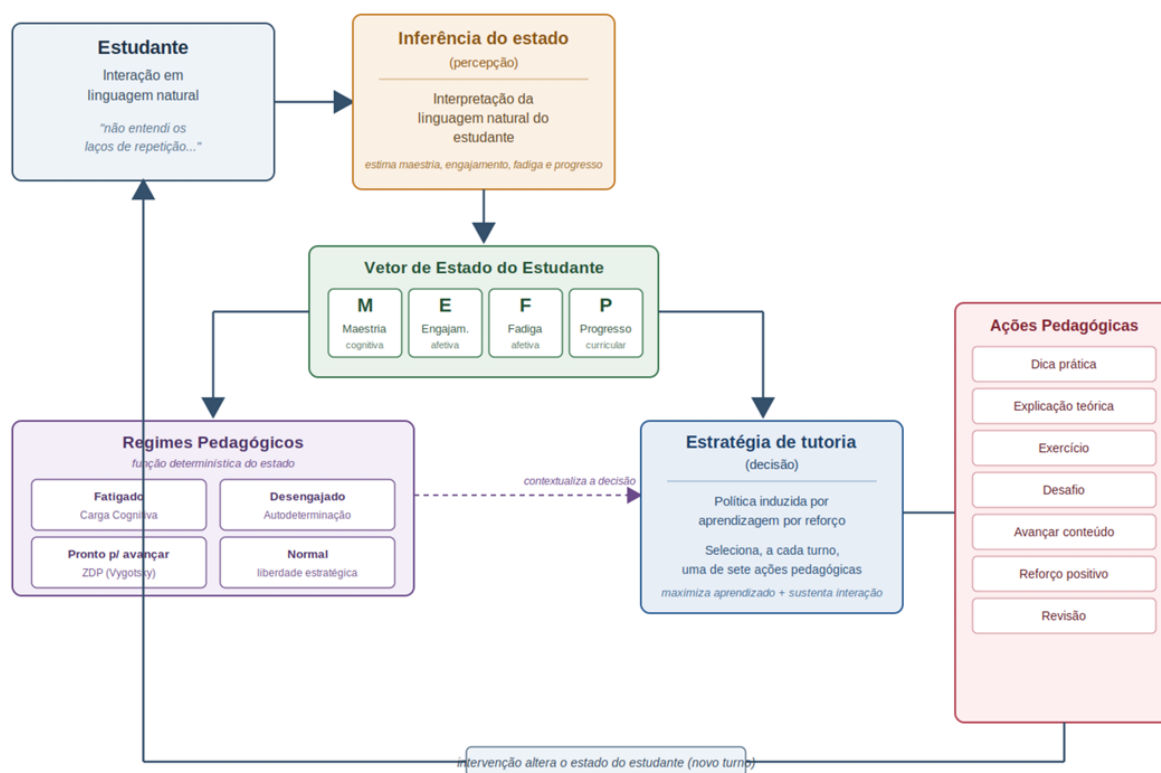
A dimensão de progresso indica a posição do estudante na trajetória curricular. A definição de quando avançar para um novo conteúdo relaciona-se ao conceito de Zona de Desenvolvimento Proximal, que delimita a faixa de dificuldade na qual a aprendizagem é mais eficaz: nem tão simples a ponto de não desafiar, nem tão complexa a ponto de exceder a capacidade atual do estudante (Vygotsky, 1978). A progressão curricular, nesse sentido, deve ser condicionada à prontidão cognitiva e afetiva do aprendiz, evitando tanto o avanço prematuro quanto a estagnação em conteúdos já dominados.

3. MATERIAIS E MÉTODOS

Esta seção descreve o framework proposto e o ambiente utilizado para avaliar sua viabilidade. A pesquisa caracteriza-se como aplicada e experimental, conduzida em ambiente de simulação computacional. O framework é apresentado em três componentes: o vetor de estado do estudante (Seção 3.1), os regimes pedagógicos e o espaço de ações (Seção 3.2) e os perfis estereotípicos de estudante (Seção 3.3). O ambiente de simulação e o procedimento de avaliação são descritos na Seção 3.4.

A Figura 1 sintetiza a organização geral do framework e o fluxo de informação entre seus componentes. A interação do estudante, expressa em linguagem natural, é interpretada de modo a inferir o vetor de estado cognitivo-afetivo. Esse vetor determina o regime pedagógico corrente e fundamenta a estratégia de tutoria, responsável por selecionar a ação pedagógica mais adequada, cuja aplicação altera o estado do estudante e inicia um novo turno de interação.

Figura 1. Visão geral do framework cognitivo-afetivo e fluxo de informação entre as camadas



Fonte: elaborado pelos autores.

3.1. O Vetor de Estado Cognitivo-Afetivo

O estado do estudante é modelado como um vetor de quatro dimensões, cada uma variando no intervalo de 0 a 1: maestria (M), engajamento (E), fadiga (F) e progresso (P). Diferentemente de abordagens tradicionais, que consideram apenas o desempenho cognitivo, esse modelo integra explicitamente dimensões afetivas. As dimensões de engajamento e fadiga desempenham papel central na dinâmica do sistema, pois influenciam não apenas a eficácia das ações pedagógicas, mas também a probabilidade de continuidade da interação. Trajetórias caracterizadas por queda persistente de engajamento e aumento de fadiga tendem a convergir para estados de evasão, configurando o fenômeno da evasão silenciosa como propriedade emergente do modelo.

3.2. Regimes Pedagógicos e Espaço de Ações

O espaço de estados admite uma partição em quatro regiões qualitativamente distintas, denominadas regimes pedagógicos. Esses regimes não constituem variáveis adicionais no vetor de estado, mas funções determinísticas dele, que estruturam o espaço em regiões com semântica pedagógica distinta. O Quadro 1 sintetiza os regimes, suas condições de ativação e seus fundamentos teóricos.

Quadro 1. Regimes pedagógicos, condições de ativação e fundamentação teórica

Regime	Condição	Fundamentação e implicação pedagógica
Fatigado	Fadiga elevada	Teoria da Carga Cognitiva: a absorção de novos conhecimentos está comprometida; intervenções exigentes tornam-se contraproducentes.
Desengajado	Engajamento baixo	Teoria da Autodeterminação: risco elevado de evasão silenciosa; intervenções afetivas tornam-se prioritárias sobre as cognitivas.
Pronto para avançar	Maestria e engajamento altos	Zona de Desenvolvimento Proximal: há domínio e prontidão suficientes para absorver novos conteúdos ou desafios mais complexos.
Normal	Demais configurações	Configuração padrão; o tutor dispõe de maior liberdade estratégica em função do perfil e do histórico de progresso.

Fonte: elaborado pelos autores.

A relevância dos regimes está na não linearidade que introduzem: uma mesma ação pedagógica pode produzir efeitos qualitativamente diferentes conforme o regime em que o estudante se encontra. Uma intervenção de alta exigência cognitiva é eficaz no regime pronto para avançar e potencialmente prejudicial no regime fatigado. Essa propriedade é central para induzir um comportamento sensível ao contexto afetivo-cognitivo do estudante.

O tutor seleciona suas intervenções a partir de um conjunto discreto de sete ações pedagógicas, cada uma projetada para atuar de forma diferenciada sobre as dimensões do estado, conforme apresentado no Quadro 2.

Quadro 2. Espaço de ações pedagógicas e efeito predominante

Ação	Efeito pedagógico predominante
Dica prática	Favorece a progressão imediata com baixo impacto em fadiga.
Explicação teórica	Promove aumento de maestria com custo moderado de fadiga.
Exercício	Consolida o conhecimento com impacto gradual na maestria.
Desafio	Potencializa ganhos de maestria, com maior risco de fadiga e variação de engajamento.
Avançar conteúdo	Altera o progresso curricular, introduzindo novos conceitos quando há evidência de domínio.
Reforço positivo	Atua predominantemente sobre o engajamento, restaurando ou sustentando a motivação.
Revisão	Reforça conteúdos já vistos, com baixo custo afetivo, consolidando a base de conhecimento.

Fonte: elaborado pelos autores.

3.3. Perfis Estereotípicos de Estudante

Para favorecer a generalização das estratégias de tutoria, o framework define quatro perfis estereotípicos de estudante, caracterizados por parâmetros distintos de aprendizado, sensibilidade à fadiga e volatilidade do engajamento. Esses perfis representam uma hipótese de abstração do comportamento estudantil, segundo a qual a dinâmica de aprendizagem pode ser representada por um conjunto limitado de padrões. O Quadro 3 descreve os perfis.

Quadro 3. Perfis estereotípicos de estudante

Perfil	Características
Com dificuldade	Baixa taxa de aprendizado e alta sensibilidade à fadiga; requer intervenções de suporte frequentes e apresenta maior risco de evasão.
Aprendiz rápido	Alta taxa de aprendizado e baixa fadiga; o desafio do tutor é evitar o desengajamento por subestimulação.
Inseguro	Elevada volatilidade no engajamento, com forte dependência de reforços afetivos.
Médio	Parâmetros intermediários, servindo como linha de base de comportamento equilibrado.

Fonte: elaborado pelos autores.

3.4. Ambiente de Simulação e Procedimento de Avaliação

Para avaliar a viabilidade do framework sem expor estudantes reais a estratégias de tutoria ainda não validadas, foi desenvolvido um

ambiente de simulação no qual o estado do estudante evolui em resposta às ações do tutor. A dinâmica de transição combina os parâmetros do perfil, os modificadores de cada regime pedagógico, bloqueios contextuais que penalizam combinações inadequadas de ação e estado, e um fator de penalização por repetição que reduz a eficácia de ações aplicadas de forma monótona. Ruído estocástico foi introduzido nas transições para promover robustez. O simulador não pretende reproduzir fielmente o comportamento humano, mas capturar regularidades estruturais relevantes do processo de aprendizagem.

A interação é organizada em episódios com horizonte máximo de trinta turnos, encerrados ao se atingir o domínio do conteúdo, ao esgotar o horizonte ou ao caracterizar evasão por engajamento persistentemente baixo. Como estratégia de tutoria, foi induzida uma política por meio de aprendizagem por reforço, utilizando o algoritmo Proximal Policy Optimization (Schulman et al., 2017), que observa o vetor de estado completo e seleciona, a cada turno, uma das sete ações pedagógicas. Essa política, doravante denominada política proposta, foi comparada a estratégias de referência baseadas em regras fixas e a uma variante que observa apenas as dimensões cognitivas, ignorando engajamento e fadiga.

A métrica principal de avaliação é a Taxa de Sucesso Pedagógico (TSP), definida como a proporção de episódios em que o estudante atinge o domínio do conteúdo mantendo condições afetivas sustentáveis. Como métrica complementar, registrou-se a taxa de evasão. A avaliação foi conduzida de forma estocástica sobre cinco mil episódios por configuração, distribuídos uniformemente entre os quatro perfis e replicados com cinco inicializações independentes para controlar a variabilidade.

4. RESULTADOS E DISCUSSÃO

Esta seção apresenta as evidências de viabilidade do framework obtidas em simulação. Os resultados são organizados em três eixos: a redução da evasão e o desempenho global (Seção 4.1), a variação de desempenho entre perfis (Seção 4.2) e a evidência comportamental de sensibilidade ao estado afetivo (Seção 4.3).

4.1. Redução da Evasão e Desempenho Global

A política proposta atingiu Taxa de Sucesso Pedagógico global de 74,6%, com baixa dispersão entre as cinco inicializações independentes, indicando alta reprodutibilidade. O resultado mais expressivo refere-se à evasão: enquanto uma política aleatória produziu taxa de evasão de 45,4%, confirmando que o ambiente gera evasão de forma sistemática, a política proposta reduziu essa taxa para 0,04%. Esse contraste evidencia que a estratégia aprendida mantém o engajamento sistematicamente acima do limiar de evasão ao longo da sessão, atacando diretamente o problema da evasão silenciosa.

A comparação com as estratégias de referência reforça esse achado, conforme a Tabela 1. As estratégias baseadas em regras fixas alcançaram apenas 1,3% de sucesso pedagógico, pois concentraram a maior parte dos turnos em uma única ação, acionando progressivamente o fator de penalização por repetição sem capacidade de adaptação. A diferença expressiva em relação à política proposta indica que a sofisticação das regras, isoladamente, é insuficiente, e que a capacidade de adaptar a estratégia ao estado do estudante é o fator determinante.

Tabela 1. Taxa de Sucesso Pedagógico por estratégia

Estratégia	Dimensões observadas	TSP
Regras simples	Maestria	1,3%
Regras por regime	Maestria, engajamento, fadiga	1,3%
Política sem estado afetivo	Maestria, progresso	72,1%
Política proposta	Estado completo	74,6%

Fonte: elaborado pelos autores.

4.2. Variação de Desempenho Entre Perfis

A Tabela 2 apresenta o desempenho da política proposta estratificado por perfil de estudante. A variação observada é coerente com os parâmetros que definem cada perfil. O perfil aprendiz rápido atingiu sucesso pleno, ao passo que o perfil com dificuldade, caracterizado por baixa taxa de aprendizado e alta sensibilidade à fadiga, apresentou o menor desempenho, refletindo a dificuldade intrínseca de atingir o domínio dentro do horizonte de trinta turnos. O perfil inseguro, marcado por alta volatilidade de engajamento, exigiu mais turnos para estabilização afetiva antes do avanço cognitivo, mas alcançou desempenho elevado, demonstrando que a estratégia consegue gerir dinâmicas afetivas instáveis.

Tabela 2. Taxa de Sucesso Pedagógico e taxa de evasão por perfil

Perfil	TSP	Evasão
Com dificuldade	21,1%	0,72%
Aprendiz rápido	100,0%	0,00%

Inseguro	79,9%	0,00%
Médio	96,2%	0,00%
Global	74,6%	0,04%

Fonte: elaborado pelos autores.

4.3. Sensibilidade Ao Estado Afetivo

A evidência mais relevante para a hipótese central do framework decorre da comparação entre a política proposta e a variante que observa apenas as dimensões cognitivas. Embora ambas alcancem TSP global próxima, seus comportamentos diferem qualitativamente. Quando o engajamento do estudante encontra-se baixo, a política proposta seleciona a ação de reforço positivo com frequência aproximadamente duas vezes maior do que a variante cega ao afeto. Esse comportamento é coerente com o esperado de um tutor sensível ao estado afetivo: a detecção de engajamento reduzido motiva uma mudança de estratégia em direção à recuperação motivacional. A variante que não observa o engajamento mantém sua distribuição de ações relativamente estável, independentemente do estado afetivo corrente.

Adicionalmente, a análise da política proposta revela um comportamento preventivo: o tutor aprendeu a evitar ativamente os regimes de fadiga elevada e desengajamento, mantendo o estudante em condições afetivas sustentáveis ao longo da sessão. Esse achado indica que a política não apenas reage a estados afetivos adversos quando eles ocorrem, mas atua de forma a preveni-los, o que está diretamente alinhado ao objetivo de reduzir trajetórias de evasão silenciosa.

É importante reconhecer uma limitação dos resultados em simulação. A dinâmica do ambiente apresenta correlações estruturais entre as dimensões cognitivas e afetivas, de modo que uma estratégia que otimiza apenas o desempenho cognitivo pode, indiretamente, sustentar o engajamento por meio dessas correlações. Isso reduz a diferença quantitativa observada entre as duas políticas no ambiente simulado, ainda que a diferença comportamental seja evidente. Essa limitação reforça a necessidade de validação posterior com estudantes reais, na qual a percepção do estado afetivo será mediada pela interpretação da linguagem natural, quebrando tais correlações artificiais.

5. CONSIDERAÇÕES FINAIS

Este artigo apresentou um framework de modelagem cognitivo-afetiva para tutoria inteligente no ensino de programação, composto por um vetor de estado de quatro dimensões, uma partição do espaço de estados em regimes pedagógicos e um conjunto de ações instrucionais associado a perfis estereotípicos de estudante. Cada dimensão foi ancorada em referenciais consolidados da Psicologia da Educação, conferindo fundamentação teórica à escolha das variáveis.

Os resultados obtidos em simulação respondem ao objetivo de avaliar a viabilidade do framework. Uma estratégia de tutoria sensível ao estado afetivo reduziu a taxa de evasão de 45,4% para 0,04% e atingiu 74,6% de sucesso pedagógico, superando amplamente estratégias baseadas em regras fixas. A análise comportamental evidenciou que a incorporação explícita das dimensões afetivas produz uma estratégia funcionalmente distinta,

que adapta suas intervenções ao contexto afetivo-cognitivo do estudante e atua preventivamente contra a evasão silenciosa.

As principais contribuições do trabalho são a sistematização de um framework conceitual replicável, que articula teoria educacional e modelagem computacional, e a demonstração, em ambiente controlado, de que a sensibilidade ao estado afetivo é um princípio de projeto relevante para tutores adaptativos. Como limitação, reconhece-se que os resultados decorrem de simulação e que as correlações estruturais do ambiente restringem a separabilidade empírica entre estratégias com e sem observação afetiva. Como trabalhos futuros, prevê-se a validação do framework com estudantes reais em disciplinas introdutórias de programação, a inclusão de instrumentos de medida da aprendizagem, como pré-testes e pós-testes, e a mediação da percepção do estado afetivo pela interpretação da linguagem natural do estudante.

REFERÊNCIAS BIBLIOGRÁFICAS

CHEN, X.; XIE, H.; ZOU, D.; HWANG, G.-J. Artificial intelligence in education: a review. *IEEE Access*, v. 8, p. 75264-75278, 2020.

PEKRUN, R.; LINNENBRINK-GARCIA, L. Academic emotions and student engagement. *In: Handbook of Research on Student Engagement*. Boston: Springer, 2012. p. 259-282.

ROAYAEI, M. Comprehensive survey of adaptive and intelligent education system using reinforcement learning. *In: Advances in Educational Technologies and Instructional Design*. [s. l.]: IGI Global, 2024. p. 176-197.

RYAN, R. M.; DECI, E. L. Self-determination theory and the facilitation of intrinsic motivation, social development, and well-being. *American Psychologist*, v. 55, n. 1, p. 68-78, 2000. DOI: 10.1037/0003-066X.55.1.68.

SCHULMAN, J.; WOLSKI, F.; DHARIWAL, P.; RADFORD, A.; KLIMOV, O. Proximal policy optimization algorithms. *arXiv preprint arXiv:1707.06347*, 2017. Disponível em: <https://arxiv.org/abs/1707.06347>. Acesso em: 16 jun. 2026.

SWELLER, J.; AYRES, P.; KALYUGA, S. *Cognitive Load Theory*. New York: Springer, 2011. DOI: 10.1007/978-1-4419-8126-4.

VYGOTSKY, L. S. *Mind in society: the development of higher psychological processes*. Cambridge: Harvard University Press, 1978.

WOOLF, B. P. *Building Intelligent Interactive Tutors: student-centered strategies for revolutionizing e-learning*. [s. l.]: Morgan Kaufmann, 2021.

¹ Doutorado em Desenvolvimento Socioeconômico, UCEFF Educacional. E-mail: [acesse o artigo original para visualizar o e-mail](#)

² Mestrado em Engenharia de Teleinformática, Universidade Federal do Ceará. E-mail: [acesse o artigo original para visualizar o e-mail](#)

³ Doutorado em Ciência da Computação, Universidade Federal do Ceará. E-mail: [acesse o artigo original para visualizar o e-mail](#)

⁴ Doutorado em Ciência da Computação, Instituto Federal do Ceará. E-mail: [acesse o artigo original para visualizar o e-mail](#)

