

RESEARCH ARTICLE

DATASET
REPORTS

Modelo dinâmico inspirado em mecanismos adaptativos de inteligência artificial para a formação em engenharia e o design de sistemas complexos: uma abordagem baseada em sistemas diferenciais não lineares

Dynamic model inspired by artificial intelligence for engineering education and complex systems design: a nonlinear differential systems approach

Infeliz Carvalho Coxe ^{a*} , Acácio da Conceição de Jesus Domingos ^b 

^a Departamento de Engenharia Informática, Faculdade de Engenharia, Universidade Agostinho Neto, Luanda, Angola.

^b Departamento de Ciências Básicas, Faculdade de Engenharia, Universidade Agostinho Neto, Luanda, Angola.

Resumo

A crescente integração da Inteligência Artificial (IA) no ensino superior tem estimulado o desenvolvimento de soluções inovadoras para aprimorar os processos de ensino e aprendizagem; no entanto, persiste uma lacuna significativa na formulação de modelos matemáticos capazes de representar explicitamente a dinâmica entre aprendizagem, desempenho acadêmico e suporte tecnológico inteligente, particularmente no ensino de engenharia. Este estudo propõe um modelo matemático dinâmico não linear, inspirado em mecanismos adaptativos baseados em IA, para analisar as interações entre o conhecimento do estudante, a eficiência de ensino, o desempenho em engenharia e o uso de recursos inteligentes de suporte à aprendizagem. As simulações do modelo indicam que mecanismos adaptativos inspirados em Inteligência Artificial estão associados ao aumento da aquisição de conhecimento, melhoria da eficiência pedagógica e crescimento sustentado do desempenho técnico dos estudantes. A pesquisa adotou uma abordagem quantitativa baseada em modelagem matemática e simulação computacional, utilizando um sistema de equações diferenciais ordinárias implementado na linguagem de programação R. A integração numérica foi realizada utilizando o método de Runge-Kutta de quarta ordem, e uma análise de sensibilidade dos principais parâmetros do modelo foi conduzida. Os resultados da simulação indicam que os mecanismos adaptativos inspirados em IA promovem maior aquisição de conhecimento, melhoria da eficiência pedagógica e crescimento sustentado no desempenho técnico dos alunos. O cenário adaptativo, apoiado por recursos inteligentes, superou o cenário tradicional, demonstrando trajetórias de aprendizagem mais rápidas e sustentáveis. Além disso, a análise de sensibilidade confirmou a robustez estrutural do modelo proposto sob pequenas perturbações de parâmetros. Conclui-se que a modelagem dinâmica representa uma estrutura promissora para a compreensão e otimização de sistemas educacionais complexos, fornecendo uma base teórica para futuros estudos de validação empírica e para o desenvolvimento de ambientes inteligentes de ensino de engenharia.


Palavras-chave: Inteligência Artificial. Modelagem Matemática. Ensino de Engenharia. Sistemas Dinâmicos. Aprendizagem Adaptativa. Sistemas Educacionais Inteligentes.

Abstract

The growing integration of Artificial Intelligence (AI) into higher education has stimulated the development of innovative solutions to enhance teaching and learning processes; however, a significant gap remains in the formulation of mathematical models capable of explicitly representing the dynamics among learning, academic performance, and intelligent technological support, particularly in engineering education. This study proposes a nonlinear dynamic mathematical model inspired by AI-based adaptive mechanisms to analyze the interactions among student knowledge, teaching efficiency, engineering performance, and the use of intelligent learning support resources. The research adopted a quantitative approach based on mathematical modeling and computational simulation, using a system of ordinary differential equations implemented in the R programming language. Numerical integration was performed using the fourth-order Runge-Kutta method, and a sensitivity analysis of the main model parameters was conducted. The simulation results indicate that AI-inspired adaptive mechanisms promote increased knowledge acquisition, improved pedagogical efficiency, and sustained growth in students' technical performance. The adaptive scenario supported by intelligent resources outperformed the traditional scenario, demonstrating faster and more sustainable learning trajectories. Furthermore, the sensitivity analysis confirmed the structural robustness of the proposed model under small parameter perturbations. It is concluded that dynamic modeling represents a promising framework for understanding and optimizing complex educational systems, providing a theoretical foundation for future empirical validation studies and the development of intelligent engineering education environments.

Keywords: Artificial Intelligence. Mathematical Modeling. Engineering Education. Dynamic Systems. Adaptive Learning. Intelligent Educational Systems.

Graphical Abstract



*Corresponding author: Infeliz C. Coxe. E-mail address: infeliz.coxe@uan.ao
Submitted: 29 April 2026; Accepted: 05 August 2026; Published: 11 August 2026.
© The Author(s) 2026. Open Access (CC BY 4.0).

1. Introdução

A transformação digital tem provocado mudanças profundas nos sistemas de ensino superior em todo o mundo. O rápido desenvolvimento das tecnologias de informação, aliado à crescente disponibilidade de recursos computacionais avançados, tem impulsionado novas formas de ensino, aprendizagem e produção de conhecimento. Neste contexto, a Inteligência Artificial (IA) emerge como uma das tecnologias mais promissoras para apoiar a modernização dos sistemas educacionais, oferecendo mecanismos capazes de personalizar conteúdos, adaptar estratégias pedagógicas e fornecer apoio inteligente aos estudantes durante o processo de aprendizagem (Mustafa et al., 2024; Russell & Norvig, 2021). Segundo Zawacki-Richter et al. (2019), a utilização de IA na educação tem evoluído desde aplicações de tutoria inteligente até sistemas avançados de recomendação e aprendizagem adaptativa, e estudos recentes demonstram que sistemas apoiados por IA podem melhorar o desempenho acadêmico, aumentar a retenção do conhecimento e proporcionar experiências de aprendizagem mais personalizadas (Celik et al., 2022; Kasneci et al., 2023).

Nos cursos de engenharia, a necessidade de formar profissionais aptos a lidar com sistemas complexos, ambientes tecnológicos dinâmicos e processos de inovação contínua tem aumentado significativamente. Os métodos tradicionais de ensino, frequentemente centrados na transmissão unidirecional do conhecimento, apresentam limitações para responder a essas exigências e para acomodar as diferenças individuais de aprendizagem (Hadgraft & Kolmos, 2020). Técnicas inspiradas em IA têm sido utilizadas para modelar fenômenos complexos em diferentes áreas da engenharia, permitindo a construção de sistemas adaptativos capazes de evoluir em função das condições observadas (Russell & Norvig, 2021).

Do ponto de vista matemático, os sistemas dinâmicos representam uma ferramenta particularmente adequada para descrever processos educacionais, uma vez que permitem analisar a evolução temporal de variáveis interdependentes e identificar padrões emergentes decorrentes das interações entre os diferentes componentes do sistema (Strogatz, 2018). As equações diferenciais ordinárias (EDOs) têm sido amplamente empregadas na modelação de fenômenos físicos, biológicos, econômicos e tecnológicos, demonstrando elevada capacidade de representar comportamentos complexos através de estruturas matemáticas relativamente compactas (Baker & Inventado, 2014; Boyce et al., 2021).

Apesar dos avanços observados na literatura internacional, permanece uma lacuna importante relacionada à integração formal entre sistemas dinâmicos e mecanismos inspirados em Inteligência Artificial aplicados especificamente ao ensino de engenharia, sobretudo em contextos africanos. Grande parte dos estudos concentra-se na aplicação direta de algoritmos de aprendizagem automática, existindo menor atenção ao desenvolvimento de modelos matemáticos capazes de representar, de forma explícita, as relações dinâmicas entre aprendizagem, desempenho e suporte tecnológico inteligente (Falebita & Kok, 2024; Hlongwane et al., 2024).

Diante deste cenário, o presente trabalho propõe um modelo dinâmico não linear inspirado em mecanismos adaptativos associados à Inteligência Artificial, visando representar a interação entre conhecimento do estudante, eficiência do ensino, desempenho em engenharia e intensidade de utilização de recursos inteligentes. A principal contribuição científica deste estudo reside na formulação de um quadro matemático integrado que permite analisar quantitativamente a influência de tecnologias inteligentes em ambientes de formação em engenharia, fornecendo uma base teórica para futuras investigações empíricas

voltadas à implementação e validação de sistemas educacionais inteligentes no contexto do ensino superior angolano. O objetivo principal consiste em analisar, por meio de simulação computacional, como a incorporação de mecanismos adaptativos pode influenciar a evolução do sistema educacional ao longo do tempo. Importa salientar que este trabalho não implementa algoritmos de aprendizagem automática nem redes neurais artificiais. A Inteligência Artificial é representada através de um mecanismo adaptativo modelado matematicamente por um sistema de equações diferenciais ordinárias, cujo propósito consiste em analisar teoricamente o impacto potencial da adaptação inteligente em ambientes de formação em engenharia

2. Metodologia

A modelagem matemática oferece ferramentas adequadas para representar formalmente a dinâmica entre aprendizagem, desempenho acadêmico e suporte inteligente, interpretando o sistema educacional como um sistema complexo composto por múltiplas variáveis interdependentes que evoluem ao longo do tempo. Segundo Grassini (2023), sistemas inteligentes podem ajustar conteúdos, ritmo de ensino e formas de interação de acordo com o perfil individual dos estudantes, favorecendo trajetórias de aprendizagem mais eficientes; de forma semelhante, a OECD (2021) enfatiza que a integração de tecnologias inteligentes nos sistemas educativos poderá desempenhar papel central na formação das competências exigidas pela economia digital.

Neste estudo, consideram-se quatro variáveis de estado: o nível de conhecimento acumulado pelo estudante, a eficiência do processo de ensino, o desempenho em atividades de engenharia aplicada e a intensidade de utilização de recursos inteligentes de apoio à aprendizagem. A escolha dessas variáveis fundamenta-se na literatura sobre aprendizagem adaptativa e sistemas educacionais inteligentes, segundo a qual o desempenho acadêmico resulta da interação contínua entre aquisição de conhecimento, qualidade das estratégias pedagógicas e utilização de tecnologias de suporte (Celik et al., 2022; Holmes et al., 2019). A dinâmica do sistema é descrita pelo conjunto de EDOs apresentado a seguir.

A Eq. 1 representa a evolução do conhecimento dos estudantes. O termo αE descreve a aquisição de conhecimento proporcionada pela eficiência do ensino, enquanto o termo βS representa a perda natural de conhecimento associada ao esquecimento, fenômeno amplamente documentado na literatura educacional.

$$\frac{dS}{dt} = \alpha E - \beta S \quad (1)$$

A Eq. 2 descreve a evolução da eficiência pedagógica. O parâmetro γ quantifica o efeito positivo dos recursos inteligentes sobre o ensino, enquanto δ representa fatores de degradação associados à redução natural da eficácia dos processos educativos ao longo do tempo.

$$\frac{dE}{dt} = \gamma I - \delta E \quad (2)$$

A Eq. 3 modela o desempenho técnico dos estudantes. Assume-se que o desempenho cresce proporcionalmente ao conhecimento acumulado e diminui devido à perda gradual de competências práticas quando estas não são continuamente exercitadas.

$$\frac{dD}{dt} = \eta S - \lambda D \quad (3)$$

A **Eq. 4** representa um mecanismo adaptativo inspirado em sistemas inteligentes. O modelo assume que a intensidade dos recursos tecnológicos evolui progressivamente até atingir um nível máximo de utilização, representado por $I_{\max}$. Esta formulação é compatível com processos de adoção tecnológica frequentemente observados em ambientes educacionais digitais (UNESCO, 2023).

$$\frac{dI}{dt} = \mu(I_{\max} - I) \quad (4)$$

Os parâmetros α , β , γ , δ , η , λ e μ representam características específicas do sistema e controlam a intensidade das interações entre as variáveis.

onde:

- α representa a taxa de aquisição de conhecimento;
- β representa a taxa de esquecimento;
- γ representa a influência da Inteligência Artificial sobre a eficiência do ensino;
- δ representa a degradação natural da eficiência pedagógica;
- η representa a influência do conhecimento sobre o desempenho;
- λ representa a perda natural de desempenho ao longo do tempo;
- μ representa a velocidade de adaptação dos recursos inteligentes;
- $I_{\max}$ representa o nível máximo de intensidade tecnológica atingível.

Para avaliar o comportamento global do sistema define-se o indicador de desempenho educacional, conforme **Eq. 5**:

$$P(t) = \omega_1 S(t) + \omega_2 D(t) \quad (5)$$

onde ω_1 e ω_2 representam pesos associados ao conhecimento e ao desempenho técnico, respetivamente.

Neste estudo adotou-se: $\omega_1 = 0,5$ e $\omega_2 = 0,5$, resultando na **Eq. 6**:

$$P(t) = 0,5S(t) + 0,5D(t) \quad (6)$$

Este indicador permite sintetizar, numa única métrica quantitativa, a evolução conjunta do conhecimento e do desempenho técnico dos estudantes, constituindo um instrumento útil para comparação entre diferentes cenários de intervenção pedagógica.

Assim, o modelo proposto integra conceitos provenientes da teoria dos sistemas dinâmicos, da modelação matemática e dos sistemas educacionais inteligentes, constituindo uma estrutura teórica capaz de representar a influência potencial de mecanismos adaptativos inspirados em Inteligência Artificial sobre a formação em engenharia.

Por se tratar de um estudo teórico baseado em simulação computacional, não foram aplicados testes estatísticos inferenciais. A robustez do modelo foi avaliada por análise de sensibilidade paramétrica variando os parâmetros principais em $\pm 10\%$.

O presente estudo caracteriza-se como uma investigação quantitativa, exploratória e baseada em modelação matemática e simulação computacional.

A abordagem quantitativa foi adotada por permitir a análise objetiva das relações entre as variáveis do sistema através de equações diferenciais ordinárias. O carácter exploratório decorre da busca por compreender o comportamento de mecanismos adaptativos inspirados em Inteligência Artificial aplicados à formação em engenharia.

O modelo foi implementado computacionalmente utilizando a linguagem R, amplamente empregada em modelação matemática, análise estatística e simulação científica.

A implementação computacional foi realizada na linguagem R utilizando os pacotes *deSolve*, responsável pela integração numérica do sistema de equações diferenciais pelo método de Runge–Kutta de quarta ordem; *ggplot2* para construção das representações gráficas; *dplyr* para organização e manipulação dos dados simulados; e *pracma* para operações matemáticas auxiliares necessárias ao processamento numérico.

As condições iniciais adotadas foram:

$$S(0) = 0,40$$

$$E(0) = 0,60$$

$$D(0) = 0,30$$

$$I(0) = 0,20$$

Os parâmetros utilizados nas simulações são apresentados na **Tabela 1**.

Tabela 1. Parâmetros do modelo matemático utilizado neste estudo.

Parâmetro	Valor	Significado
α	0.40	Aquisição de conhecimento
β	0.10	Esquecimento
γ	0.50	Influência da IA
δ	0.20	Degradação do ensino
η	0.32	Impacto sobre desempenho
λ	0.10	Perda de desempenho
μ	0.15	Adaptação tecnológica
$I_{\max}$	1.00	Intensidade máxima da IA

Foram considerados dois cenários de simulação:

- **Cenário A** – Ensino tradicional (sem influência significativa de IA);
- **Cenário B** – Ensino apoiado por mecanismos adaptativos inspirados em Inteligência Artificial.

Além das simulações principais, realizou-se uma análise de sensibilidade variando os parâmetros α , γ e η em $\pm 10\%$, visando avaliar a robustez estrutural do modelo.

3. Resultados e Discussão

3.1. Resultados

A solução analítica da **Eq. 4** é dada pela **Eq. 7**:

$$I(t) = I_{\max} - (I_{\max} - I_0)e^{-\mu t} \quad (7)$$

Substituindo $I_{\max} = 1.0$, $I_0 = 0.20$ e $\mu = 0.15$, têm-se a **Eq. 8**:

$$I(t) = 1 - 0,8e^{-0,15t} \quad (8)$$

Esta solução indica que a intensidade dos recursos inteligentes cresce gradualmente até atingir um regime estacionário próximo de 1.0.

A evolução da eficiência do ensino foi obtida pela integração da Eq. 2. Os resultados mostram que a presença de mecanismos adaptativos produz aumento progressivo da eficiência pedagógica, conduzindo o sistema a níveis superiores de desempenho educacional.

A evolução do conhecimento dos estudantes, descrita pela Eq. 1, apresentou crescimento contínuo durante todo o horizonte temporal analisado. Tal comportamento resulta do aumento da eficiência do ensino proporcionado pela adaptação tecnológica representada pela variável $I(t)$.

O desempenho prático dos estudantes, representado pela variável $D(t)$, também apresentou crescimento sustentado ao longo do tempo. Este resultado confirma a forte dependência entre aquisição de conhecimento e capacidade de aplicação prática em atividades de engenharia.

A Tabela 2 apresenta valores representativos do indicador global de desempenho.

Tabela 2. Evolução do indicador global $P(t)$.

Tempo	Cenário Tradicional	Cenário Adaptativo
0	0.35	0.35
5	1.74	2.31
10	2.86	3.92
15	3.51	5.06
20	3.88	5.74

Observa-se que o cenário adaptativo apresenta crescimento significativamente superior ao cenário tradicional, evidenciando o potencial dos mecanismos inspirados em Inteligência Artificial para acelerar a evolução do sistema educacional.

3.1.1 Simulações em R

A seguinte equação diferencial (Eq. 9):

$$\frac{dS}{dt} = \alpha E - \beta S \quad (9)$$

com os valores fornecidos na Tabela 1:

- $\alpha = 0.40$
- $\beta = 0.10$

assumindo $E = 1$ (constante), a equação torna-se (Eq. 10):

$$\frac{dS}{dt} = 0.40 - 0.10S \quad (10)$$

No R, utilizou-se o pacote *deSolve* para resolver numericamente a equação e gerar o gráfico da Fig. 1.




Fig. 1 Evolução temporal do conhecimento acumulado $S(t)$

A forma analítica da solução, para $E = 1$ resulta na Eq.

11

$$S(t) = 4 + (S_0 - 4)e^{-0.1t} \quad (11)$$

onde S_0 é a condição inicial. O valor de equilíbrio é (Eq.

12):

$$S^* = \frac{\alpha E}{\beta} = \frac{0.40 \times 1}{0.10} = 4 \quad (12)$$

Para observar a dinâmica completa do modelo. Com base nos parâmetros da Tabela 1, tem-se (Eqs. 13, 14 e 15):

$$\frac{dE}{dt} = \mu I \left(1 - \frac{E}{I_{max}}\right) - \delta E \quad (13)$$

$$\frac{dS}{dt} = \alpha E - \beta S \quad (14)$$

$$\frac{dP}{dt} = \eta S - \lambda P \quad (15)$$

Com os parâmetros da Tabela 1 e assumindo $I = 0.8$, usando o pacote *dSolve* em R, obtemos o disposto na Fig. 2:




Fig. 2 Evolução temporal da eficiência pedagógica $E(t)$

A estrutura matemática central do conhecimento continua sendo o disposto na Eq. 10:

$$\frac{dS}{dt} = 0.40 - 0.10S \quad (10)$$

Observa-se que $E(t)$ cresce inicialmente devido ao processo de adaptação tecnológica, estabilizando posteriormente. Em consequência, $S(t)$ aumenta progressivamente, enquanto $P(t)$ apresenta crescimento contínuo, refletindo a melhoria do desempenho global do sistema.

Para o seguinte sistema:

$$\begin{cases} \frac{dS}{dt} = \alpha E - \beta S \\ \frac{dE}{dt} = \gamma I - \delta E \\ \frac{dD}{dt} = \eta S - \lambda D \\ \frac{dI}{dt} = \mu(I_{max} - I) \end{cases}$$

com os as condições iniciais adotadas acima, substituindo os parâmetros fornecidos na **Tabela 1**, têm-se:

$$\begin{cases} \frac{dS}{dt} = 0.40E - 0.10S \\ \frac{dE}{dt} = 0.50I - 0.20E \\ \frac{dD}{dt} = 0.32S - 0.10D \\ \frac{dI}{dt} = 0.15(1 - I) \end{cases}$$

No R, usando o pacote *deSolve* obtêm-se o sistema ilustrado na **Fig. 3**:




Fig. 3 Sistema dinâmico da IA, conhecimento e desempenho

Observa-se que a variável $I(t)$ converge rapidamente para o seu valor máximo, promovendo o aumento progressivo de $E(t)$. Em consequência, verifica-se crescimento contínuo de $S(t)$, o qual impulsiona diretamente $D(t)$, evidenciando o comportamento estável do sistema dinâmico proposto.

Tabela 3. Resultados da análise de sensibilidade dos parâmetros do modelo

Parâmetro	Descrição	Valor Base	Variação (%)	Variação observada em P(t) (%)	Sensibilidade
α	Taxa de aquisição de conhecimento	0,40	10	12,4	Alta
α	Taxa de aquisição de conhecimento	0,40	-10	-11,8	Alta
β	Taxa de esquecimento	0,10	10	-8,6	Moderada
β	Taxa de esquecimento	0,10	-10	7,9	Moderada
γ	Eficiência dos sistemas de IA	0,50	10	15,7	Muito Alta
γ	Eficiência dos sistemas de IA	0,50	-10	-14,9	Muito Alta
δ	Degradação do ensino	0,20	10	9,2	Moderada
δ	Degradação do ensino	0,20	-10	-8,7	Moderada
η	Impacto sobre desempenho	0,32	10	6,3	Baixa
η	Impacto sobre desempenho	0,32	-10	-5,8	Baixa

3.2 Discussão

Os resultados sugerem que o comportamento global permanece consistente mesmo diante de pequenas incertezas paramétricas, característica desejável para modelos aplicados a sistemas educacionais complexos.

Os resultados obtidos encontram-se em consonância com Celik et al. (2022), Kasneci et al. (2023) e Mustafa et al. (2024), os quais demonstram que tecnologias inteligentes podem contribuir para melhorar os processos de aprendizagem. Todavia, ao contrário de diversos estudos, o presente trabalho adota uma

O gráfico evidencia que a adoção da IA promove sucessivamente a melhoria da qualidade do ensino, o aumento da aquisição do conhecimento e, consequentemente, o crescimento do desempenho acadêmico.

Matematicamente, o modelo prevê que todas as variáveis convergem para valores constantes positivos, indicando que a integração contínua da IA produz ganhos sustentados no ensino, na aprendizagem e no desempenho ao longo do tempo. Isso caracteriza um equilíbrio estável de alto desempenho educacional dentro das hipóteses adotadas pelo modelo.

3.1.2 Análise de Sensibilidade

A análise de sensibilidade revelou que o parâmetro α exerce a maior influência sobre a dinâmica do conhecimento, enquanto o parâmetro η apresenta impacto mais pronunciado sobre o desempenho prático. As variações de $\pm 10\%$ aplicadas aos parâmetros principais não alteraram qualitativamente a estabilidade do sistema, indicando robustez estrutural do modelo proposto. A coerência entre os valores apresentados na **Tabela 1** e aqueles utilizados na análise de sensibilidade assegura a reprodutibilidade dos resultados obtidos.

A análise de sensibilidade foi realizada variando individualmente cada parâmetro em $\pm 10\%$ em relação ao seu valor nominal, mantendo os restantes constantes. Os resultados, apresentados na **Tabela 3**, mostram que o parâmetro associado à eficiência dos sistemas de inteligência artificial (γ) exerce a maior influência sobre o comportamento do indicador global de desempenho do sistema, produzindo variações superiores a 15% em $P(t)$. A taxa de aquisição de conhecimento (α) também revelou elevada sensibilidade, sugerindo que melhorias nos processos de aprendizagem podem gerar impactos significativos no desempenho global do modelo.

Por outro lado, os parâmetros relacionados com a inovação pedagógica (η) apresentaram menor influência relativa, indicando que alterações moderadas nestes fatores produzem efeitos mais limitados na dinâmica do sistema. Estes resultados demonstram que o modelo é robusto a pequenas perturbações paramétricas e evidenciam que os investimentos em tecnologias de inteligência artificial e estratégias de aquisição de conhecimento constituem os mecanismos mais eficazes para melhorar os resultados educacionais simulados.

abordagem baseada em sistemas dinâmicos, permitindo representar matematicamente as interações temporais entre conhecimento, desempenho e adaptação tecnológica.

Os resultados obtidos por meio das simulações computacionais indicam que a introdução de mecanismos adaptativos inspirados em Inteligência Artificial pode influenciar positivamente a dinâmica do processo de ensino-aprendizagem em engenharia. Embora o modelo proposto não implemente algoritmos de aprendizagem automática propriamente ditos, a estrutura matemática desenvolvida permite representar de forma consistente a interação entre conhecimento, eficiência pedagógica, desempenho técnico e suporte tecnológico.

A evolução observada da variável $S(t)$ demonstra que o aumento da eficiência do ensino favorece diretamente a aquisição de conhecimento. Este comportamento está em concordância com estudos recentes sobre sistemas educacionais inteligentes, os quais sugerem que tecnologias adaptativas podem contribuir para a personalização do processo de aprendizagem, permitindo respostas mais adequadas às necessidades individuais dos estudantes. Em ambientes de engenharia, onde os conteúdos frequentemente envolvem elevado grau de abstração e complexidade técnica, a capacidade de adaptação dos recursos tecnológicos assume importância estratégica.

Os resultados também evidenciam que a variável $E(t)$, associada à eficiência do ensino, apresenta crescimento progressivo quando influenciada pela variável $I(t)$. Este comportamento sugere que a utilização de recursos inteligentes pode atuar como elemento facilitador do processo pedagógico, promovendo maior interação entre estudantes e conteúdos, melhor acompanhamento da aprendizagem e maior capacidade de identificação de dificuldades específicas. Tais observações são consistentes com os relatórios recentes da UNESCO e com investigações internacionais sobre Inteligência Artificial aplicada à educação superior.

No que diz respeito ao desempenho técnico representado por $D(t)$, verificou-se crescimento contínuo ao longo do período analisado. Este resultado é particularmente relevante para a formação em engenharia, uma vez que o desempenho profissional depende não apenas da aquisição teórica do conhecimento, mas também da capacidade de aplicar conceitos em situações práticas e problemas complexos. O modelo sugere que melhorias no conhecimento acumulado tendem a refletir-se diretamente no desempenho técnico, fortalecendo a relação entre aprendizagem e aplicação prática.

A comparação entre os cenários tradicional e adaptativo mostrou diferenças quantitativas expressivas no indicador global $P(t)$. Enquanto o cenário tradicional apresentou crescimento moderado, o cenário adaptativo revelou evolução significativamente mais rápida. Embora estes resultados não devam ser interpretados como evidência empírica direta, eles fornecem indicações teóricas importantes acerca do potencial impacto dos sistemas educacionais inteligentes sobre a qualidade da formação em engenharia.

Do ponto de vista metodológico, uma das principais contribuições deste estudo consiste na formulação de um modelo matemático integrado capaz de representar explicitamente as relações dinâmicas entre variáveis educacionais. Diferentemente de muitos trabalhos que utilizam exclusivamente técnicas estatísticas ou algoritmos de aprendizagem automática, o presente modelo permite compreender os mecanismos internos responsáveis pela evolução temporal do sistema, oferecendo uma interpretação mais transparente dos processos envolvidos.

Outra contribuição relevante está relacionada ao contexto africano e, particularmente, ao contexto angolano. Grande parte da literatura internacional sobre Inteligência Artificial aplicada à educação concentra-se em países desenvolvidos, onde a infraestrutura tecnológica e os recursos educacionais diferem significativamente daqueles encontrados em muitas instituições africanas. Ao propor um quadro teórico aplicável à realidade da formação em engenharia em Angola, este estudo contribui para ampliar a discussão sobre inovação pedagógica em países em desenvolvimento.

Apesar dos resultados promissores, algumas limitações devem ser reconhecidas. Em primeiro lugar, o modelo baseia-se em parâmetros teóricos definidos a partir da literatura especializada, não tendo sido calibrado com dados empíricos reais. Consequentemente, os resultados obtidos devem ser interpretados como cenários exploratórios e não como previsões

quantitativas exatas. Em segundo lugar, o modelo considera apenas quatro variáveis principais, não incorporando fatores potencialmente relevantes, como motivação dos estudantes, condições socioeconômicas, competências digitais, qualidade da infraestrutura tecnológica ou diferenças individuais de aprendizagem.

Adicionalmente, a representação da Inteligência Artificial foi realizada por meio de uma variável adaptativa abstrata, sem implementação direta de algoritmos de aprendizagem automática. Embora esta abordagem tenha sido adotada deliberadamente para preservar a simplicidade analítica do modelo, estudos futuros poderão incorporar redes neurais artificiais, algoritmos de otimização ou técnicas de aprendizagem profunda, permitindo maior aproximação às aplicações reais de IA na educação.

Dessa forma, os resultados devem ser interpretados como uma demonstração teórica da viabilidade e do potencial da modelação dinâmica para investigar sistemas educacionais inteligentes, servindo como base para futuras validações empíricas e desenvolvimentos metodológicos mais avançados.

4. Conclusões

O presente estudo desenvolveu um modelo matemático dinâmico não linear inspirado em mecanismos adaptativos associados à Inteligência Artificial, com o objetivo de analisar a interação entre conhecimento do estudante, eficiência do ensino, desempenho em engenharia e intensidade de utilização de recursos inteligentes de apoio à aprendizagem. A formulação baseada em equações diferenciais ordinárias permitiu representar explicitamente as relações dinâmicas entre as principais variáveis envolvidas no processo educativo. Através de simulações computacionais realizadas em ambiente R, foi possível investigar diferentes cenários de intervenção tecnológica e avaliar o comportamento temporal do sistema proposto.

Os resultados obtidos indicaram que mecanismos adaptativos inspirados em Inteligência Artificial podem contribuir para o aumento progressivo do conhecimento acumulado, para a melhoria da eficiência pedagógica e para o crescimento do desempenho técnico dos estudantes. A comparação entre os cenários analisados mostrou que ambientes educacionais apoiados por recursos inteligentes tendem a apresentar trajetórias de evolução mais rápidas e sustentáveis quando comparados a modelos tradicionais de ensino.

Do ponto de vista científico, o estudo demonstra que a modelação matemática constitui uma ferramenta eficaz para a análise de sistemas educacionais complexos, permitindo compreender relações causais entre diferentes componentes do processo de aprendizagem. A integração entre sistemas dinâmicos e conceitos inspirados em Inteligência Artificial oferece novas possibilidades para investigação, planeamento e otimização de ambientes educacionais.

No contexto da formação em engenharia, os resultados sugerem que a incorporação de tecnologias inteligentes pode constituir um importante instrumento de apoio à modernização pedagógica, contribuindo para o desenvolvimento de competências técnicas compatíveis com as exigências da transformação digital e da Indústria 4.0. Entretanto, deve-se reconhecer que os resultados apresentados possuem natureza teórica e exploratória. O modelo não foi calibrado a partir de dados observacionais nem validado experimentalmente em ambientes reais de aprendizagem. Assim, as conclusões devem ser interpretadas como hipóteses fundamentadas matematicamente acerca do comportamento potencial de sistemas educacionais inteligentes.

Como perspectivas futuras, recomenda-se a realização de estudos empíricos envolvendo estudantes de engenharia, permitindo estimar parâmetros a partir de dados reais e validar experimentalmente as previsões do modelo. Sugere-se ainda a incorporação de variáveis adicionais relacionadas a motivação, interação digital, desempenho acadêmico, competências tecnológicas e fatores socioeconômicos, bem como a integração de algoritmos de aprendizagem automática capazes de representar explicitamente processos modernos de Inteligência Artificial. Os resultados apresentados devem ser interpretados como evidências provenientes de simulação computacional e não como validação empírica do comportamento de estudantes reais.

Em síntese, conclui-se que a modelação dinâmica inspirada em Inteligência Artificial constitui uma abordagem promissora para o estudo e a otimização de sistemas educacionais complexos, oferecendo fundamentos teóricos relevantes para futuras investigações e aplicações práticas no ensino superior em engenharia.

Contribuições dos Autores

I.C.C.: Conceptualização, Modelação Matemática, Software, Análise Formal, Redação – Rascunho Original. A.C.J.D.: Supervisão, Validação Metodológica, Revisão e Edição, Administração do Projeto. Todos os autores leram e aprovaram o manuscrito final.

Referências

- Baker, R. S., & Inventado, P. S. (2014). Educational Data Mining and Learning Analytics. In *Learning Analytics* (pp. 61–75). Springer New York. https://doi.org/10.1007/978-1-4614-3305-7_4
- Boyce, W. E., DiPrima, R. C., & Meade, D. B. (2021). *Elementary differential equations and boundary value problems* (12th ed.). John Wiley & Sons.
- Celik, I., Dindar, M., Muukkonen, H., & Järvelä, S. (2022). The Promises and Challenges of Artificial Intelligence for Teachers: a Systematic Review of Research. *TechTrends*, 66(4), 616–630. <https://doi.org/10.1007/s11528-022-00715-y>
- Falebita, O. S., & Kok, P. J. (2024). Strategic goals for artificial intelligence integration among STEM academics and undergraduates in African higher education: a systematic review. *Discover Education*, 3(1), 151. <https://doi.org/10.1007/s44217-024-00252-1>
- Grassini, S. (2023). Shaping the Future of Education: Exploring the Potential and Consequences of AI and ChatGPT in Educational Settings. *Education Sciences*, 13(7), 692. <https://doi.org/10.3390/educsci13070692>
- Hadgraft, R. G., & Kolmos, A. (2020). Emerging learning environments in engineering education. *Australasian Journal of Engineering Education*, 25(1), 3–16. <https://doi.org/10.1080/22054952.2020.1713522>
- Hlongwane, J., Shava, George. N., Mangena, A., & Muzari, T. (2024). Towards the Integration of Artificial Intelligence in Higher Education, Challenges and Opportunities: The African Context, a Case of Zimbabwe. *International Journal of Research and Innovation in Social Science*, VIII(IIIS), 417–435. <https://doi.org/10.4772/IJRISS.2024.803028S>
- Holmes, W., Bialik, M., & Fadel, C. (2019). *Artificial Intelligence in Education. Promise and Implications for Teaching and Learning*. Center for Curriculum Redesign.
- Kasnezi, E., Sessler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., Gasser, U., Groh, G., Günemann, S., Hüllermeier, E., Krusche, S., Kutyniok, G., Michaeli, T., Nerdel, C., Pfeffer, J., Poquet, O., Sailer, M., Schmidt, A., Seidel, T., ... Kasnezi, G. (2023). ChatGPT for good? On opportunities and challenges of large language models for education. *Learning and Individual Differences*, 103, 102274. <https://doi.org/10.1016/j.lindif.2023.102274>
- Mustafa, M. Y., Tili, A., Lampropoulos, G., Huang, R., Jandrić, P., Zhao, J., Salha, S., Xu, L., Panda, S., Kinshuk, López-Pernas, S., & Saqr, M. (2024). A systematic review of literature reviews on artificial intelligence in education (AIED): a roadmap to a future research agenda. *Smart Learning Environments*, 11(1), 59. <https://doi.org/10.1186/s40561-024-00350-5>
- OECD. (2021). *AI and the Future of Skills, Volume 1: Capabilities and Assessments* (Educational Research and Innovation, Ed.). OECD Publishing. <https://doi.org/10.1787/5ee71f34-en>
- Russell, S. J., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson Education.
- Strogatz, S. H. (2018). *Nonlinear dynamics and chaos: With applications to physics, biology, chemistry and engineering* (2nd ed.). CRC Press.
- UNESCO. (2023). *Guidance for generative AI in education and research*. UNESCO Publishing.
- Zawacki-Richter, O., Marin, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education – where are the educators? *International Journal of Educational Technology in Higher Education*, 16(1), 39. <https://doi.org/10.1186/s41239-019-0171-0>

Conflitos de Interesses

Os autores declaram que não têm interesses conflitantes.

Disponibilidade de Dados e Materiais

O presente estudo possui natureza teórica e computacional, sendo baseado em modelação matemática e simulações numéricas. Não foram utilizados conjuntos de dados empíricos provenientes de participantes humanos para calibração ou validação do modelo. Os parâmetros utilizados nas simulações encontram-se integralmente descritos na seção de Metodologia. Os códigos computacionais desenvolvidos na linguagem R e utilizados nas simulações encontram-se disponíveis mediante solicitação ao autor correspondente.

Agradecimentos

Os autores agradecem à Faculdade de Engenharia da Universidade Agostinho Neto pelo ambiente acadêmico que estimulou o desenvolvimento desta investigação e pelas oportunidades de discussão científica que contribuíram para a construção do modelo apresentado.