

<https://doi.org/10.56117/resbenq.2026.v7.e072608>

O desenvolvimento do pensamento sistêmico por meio da IA na abordagem *Learning by Modelling* na Educação Básica

Developing Systems Thinking through AI in the Learning by Modeling approach in Basic Education

Desarrollo del Pensamiento Sistémico a través de IA en el enfoque de Aprendizaje por Modelado en Educación Básica

Paulo Vitor Teodoro (paulovitorteodoro@ufu.br)
Universidade Federal de Uberlândia
<https://orcid.org/0000-0003-0939-984X>

Paulo Salles (pssalles@gmail.com)
Universidade de Brasília
Ministério de Desenvolvimento, Indústria, Comércio e Serviços
<https://orcid.org/0000-0003-3089-399X>

Ricardo Gauche (ricardogauche@gmail.com)
Universidade de Brasília
<https://orcid.org/0000-0001-9310-0489>

Resumo

Este estudo apresenta os resultados de uma pesquisa que buscou demonstrar que o uso e a construção de modelos de simulação, com técnicas de IA, podem promover o pensamento sistêmico no contexto da sala de aula na Educação em Ciências. Para isso, adotamos o Raciocínio Qualitativo (RQ), uma área da IA, para representar fenômenos das Ciências Naturais passíveis de serem abordados no Ensino Médio. Utilizamos a dinâmica de sistemas como base teórica para o desenvolvimento do pensamento sistêmico e a plataforma *DynaLearn* como ferramenta para construir e simular modelos qualitativos. Esta plataforma permite visualizar relações causais entre componentes de um sistema e representações de funções matemáticas para o cálculo de valores qualitativos. A coleta de dados envolveu técnicas de pesquisa qualitativa (questionários) e quantitativa (análises estatísticas). Os resultados indicaram que os estudantes de ensino médio participantes são capazes de representar fenômenos naturais com habilidades inerentes ao pensamento sistêmico por meio da construção



Este texto é licenciado pela [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/).

de modelos. Além disso, houve diferenças estatisticamente significativas na compreensão dos estudantes sobre sistemas complexos, demonstrando o reconhecimento de conceitos necessários ao pensamento sistêmico. Os dados permitem concluir que a construção e a manipulação de modelos qualitativos, sob a abordagem *Learning by Modelling* e a ótica da dinâmica de sistemas, podem desenvolver habilidades fundamentais na Educação em Ciências para o pensamento sistêmico.

Palavras-chave: Modelagem Qualitativa. Dinâmica de sistemas. *DynaLearn*. Ensino de Ciências.

Abstract

This study presents the results of research that sought to demonstrate that the use and construction of simulation models, with AI techniques, can promote Systems Thinking in the classroom context in Science Education. To this end, we adopted Qualitative Reasoning (QR), an area of AI, to represent phenomena in Natural Sciences that can be addressed in High School. We used Systems Dynamics as a theoretical basis for the development of Systems Thinking and the *DynaLearn* platform as a tool to build and simulate qualitative models. This platform allows visualization of causal relationships between components of a system and representations of mathematical functions for the calculation of qualitative values. Data collection involved qualitative (questionnaires) and quantitative (statistical analyses) research techniques. The results indicated that the participating high school students are able to represent natural phenomena with skills inherent to Systems Thinking through the construction of models. Furthermore, there were statistically significant differences in the students' understanding of complex systems, demonstrating the recognition of concepts necessary for systems thinking. The data suggests that the construction and manipulation of qualitative models, using a Learning by Modeling approach and from the perspective of Systems Dynamics, can develop fundamental skills in Science Education for Systems Thinking.

Keywords: Qualitative Modeling. System Dynamics. *DynaLearn*. Science Education.

Resumen

Este estudio presenta los resultados de una investigación que buscó demostrar que el uso y la construcción de modelos de simulación, con técnicas de IA, pueden promover el Pensamiento Sistémico en el contexto del aula de Educación en Ciencias. Para ello, adoptamos el Razonamiento Cualitativo (RC), un área de la IA, para representar fenómenos en Ciencias Naturales que pueden abordarse en la Educación Secundaria. Utilizamos la Dinámica de Sistemas como base teórica para el desarrollo del Pensamiento Sistémico y la plataforma *DynaLearn* como herramienta para construir y simular modelos cualitativos. Esta plataforma permite la visualización de relaciones

causales entre componentes de un sistema y representaciones de funciones matemáticas para el cálculo de valores cualitativos. La recolección de datos involucró técnicas de investigación cualitativas (cuestionarios) y cuantitativas (análisis estadísticos). Los resultados indicaron que los estudiantes de secundaria participantes son capaces de representar fenómenos naturales con habilidades inherentes al Pensamiento Sistémico a través de la construcción de modelos. Además, hubo diferencias estadísticamente significativas en la comprensión de los estudiantes de sistemas complejos, lo que demuestra el reconocimiento de conceptos necesarios para el pensamiento sistémico. Los datos sugieren que la construcción y manipulación de modelos cualitativos, utilizando un enfoque de Aprendizaje por Modelado y desde la perspectiva de la Dinámica de Sistemas, pueden desarrollar habilidades fundamentales en la Educación Científica para el Pensamiento Sistémico.

Palabras clave: Modelado Cualitativo. Dinámica de Sistemas. DynaLearn. Enseñanza de las Ciencias.

Introdução

O pensamento sistêmico (em inglês, *systems thinking*) pode ser entendido como uma maneira de pensar as diversas variáveis que influenciam um determinado fenômeno. Este tipo de pensamento permite percebermos, modelarmos e avaliarmos as consequências das ações de forma ampla, no tempo e no espaço. O pensamento sistêmico viabiliza expandirmos a nossa capacidade de perceber o todo, por exemplo, uma visão de rede, a lógica de causa-efeito, a consideração dos processos dinâmicos, a estruturação de conhecimento socialmente construído, a aceitação das descrições aproximadas e das medidas qualitativas e a abordagem intelectual contextualizada (Lyneis, 2013).

Desenvolver habilidades para alcançarmos o pensamento sistêmico não implica considerar somente o problema: implica em pensar também nos seus inter-relacionamentos, presentes, inclusive nos possíveis cenários futuros (Caulfield e Maj, 2001). A partir do momento em que começamos a mudar a nossa forma de enxergar o mundo, reconheceremos como os problemas, desafios e situações complexas formam-se em camadas muitas vezes não vistas.

Nessa visão mais robusta de raciocinar, o pensamento sistêmico vem sendo amplamente reconhecido na Educação como uma forma de esquematizar, sistematizar, entender, discutir e solucionar problemas complexos, sobretudo em um mundo cada vez mais interconectado (Salles et al., 2012). Com a crescente integração de tecnologias digitais na educação, técnicas baseadas em Inteligência Artificial (IA) têm se destacado

por suas possibilidades de inovar os processos de ensino-aprendizagem. Nesse contexto, a abordagem *Learning by Modelling* (Aprender Modelando - LbM) se configura como uma metodologia que alia a construção ativa de modelos ao desenvolvimento de competências analíticas, reflexivas e críticas por parte dos estudantes.

A abordagem de LbM constitui um processo no qual os estudantes elaboram, constroem hipóteses, testam e refinam seus modelos para explicar fenômenos (Hashem e Mioduser, 2013). Nesse sentido, os elementos centrais dessa abordagem não se limitam à manipulação de ferramentas, mas estruturam-se na exteriorização de hipóteses, conceitos e simulações, bem como no mapeamento de relações de causa e efeito que regem um sistema (Souza, 2019). Diante disso, a LbM diferencia-se substancialmente de outras abordagens por exigir a criação de um artefato dinâmico e testável: o modelo em si. Nessa perspectiva, o diferencial reside na exigência de que o estudante conceba e teste o comportamento do sistema estudado, permitindo-lhe confrontar suas próprias percepções com os resultados da simulação e, por conseguinte, reestruturar seu pensamento de forma autônoma.

Ao permitir que os estudantes participem ativamente do processo de construção, que pode acontecer por meio da modelagem, a metodologia LbM potencializa a aprendizagem de formação conceitual, viabiliza a interdisciplinaridade e o trabalho colaborativo. Além disso, a aplicação de modelos de simulação apoiados por IA facilita a visualização e a experimentação de cenários complexos, encorajando os estudantes a explorar as relações de causa e efeito e os fluxos de informação entre os componentes de um sistema.

Os modelos construídos com técnicas de IA, possibilitam representações abstratas dos sistemas físicos e naturais, mostrando as relações de causalidade e previsão de possíveis resultados (Bredeweg et al., 2013). E, com efeito, estudos anteriores têm mostrado aplicações de modelos, feitos com a IA, no Campo da Educação em Ciências, inclusive, no Ensino de Química (Guerin Junior et al., 2023; Teodoro et al., 2024).

Entretanto, ainda são poucos os exemplos do uso de modelos de simulação no ambiente da educação básica. Um dos fatores que contribuem para limitar o uso dessa abordagem é que simulações são quase sempre dependentes de dados numéricos e

funções matemáticas complexas, geralmente inacessíveis aos estudantes desse nível educacional.

Os exemplos mais conhecidos de modelagem são baseados na abordagem da dinâmica de sistemas (*system dynamics* – SD) (Forrester, 2009), uma metodologia voltada para o desenvolvimento do pensamento sistêmico. Essa abordagem é alinhada diretamente ao propósito do presente esforço de pesquisa: manter uma visão sistêmica dos fenômenos.

Diante disso, este trabalho tem como objetivo demonstrar que o uso e a construção de modelos de simulação, utilizando técnicas de IA, pode promover o pensamento sistêmico, no contexto da sala de aula, na Educação em Ciências.

As seções 2 e 3 fundamentam o pensamento sistêmico na Educação. A seção 3 descreve o desenho metodológico deste estudo. A seção 4 apresenta e discute os resultados alcançados. Finalmente, na seção 5, apresentamos os comentários sobre o trabalho e o potencial da modelagem qualitativa para a educação em Ciências.

O pensamento sistêmico no contexto da Educação Básica

O pilar central do pensamento sistêmico está em viabilizar que os estudantes pensem em sistemas, e em contextos nos quais as relações entre componentes sejam facilmente identificadas e compreendidas. Nessa mesma linha de raciocínio, Forrester (2009) destaca que pensar sistemicamente possibilita o estudante aprender por meio do ‘fazer’. O autor discute que SD é uma atividade participativa na qual se aprende pelas tentativas e também pelos erros, mas refletindo sobre o mundo com olhares mais críticos.

Para isso, Forrester (2009) mostra que os estudantes devem ser conduzidos em atividades que utilizam as tecnologias, por exemplo, para construir modelos, e incentivados a refletirem sobre relações dos sistemas a partir dos fenômenos que nos cercam. De acordo com estudos realizados no âmbito de estratégias voltadas para a SD (Richmond, 1993; Forrester, 2009), estudantes podem desenvolver bem suas habilidades que levam ao pensamento sistêmico, dependendo da forma de trabalho proposta no processo educativo e o uso de boas ferramentas (Richmond, 1993).

O Raciocínio Qualitativo (RQ) é uma área da Inteligência Artificial (IA) que se dedica à descrição de propriedades contínuas do mundo físico por meio de um sistema discreto de símbolos, visando dar suporte ao raciocínio automatizado (Forbus, 1984).

A partir de técnicas de modelagem estruturadas na IA, essa abordagem permite utilizar conhecimentos qualitativos para compreender e prever o comportamento de sistemas de grande complexidade, mesmo diante da ausência ou incompletude de dados quantitativos.

No cenário educacional, essa vertente fundamentou o desenvolvimento do projeto *Engaging and informed tools for learning conceptual systems*, uma colaboração entre pesquisadores europeus e de outros países, incluindo o Brasil (Salles et al., 2010). Como resultado desse esforço conjunto, foi construído o software *DynaLearn*, uma plataforma de modelagem baseada em IA que expressa, diagramaticamente, relações causais e previsões de simulações. O *DynaLearn* possibilita aos estudantes alcançar conclusões preditivas semelhantes às aquelas geradas por modelos matemáticos clássicos, contudo, sem a necessidade de aportes numéricos. Essa característica ajuda a mitigar uma das dificuldades históricas no processo educacional apontadas por Forrester (2009): a abordagem unilateral e puramente descritiva dos conteúdos escolares, que frequentemente negligencia a dinâmica e a interatividade dos sistemas estudados.

Richmond (1993) mostra que realmente não é trivial pensar em termos de interdependência dinâmica em sistemas. Richmond (1993) sugere uma proposta educacional em que os estudantes possam desenvolver uma visão mais ampla e crítica dos fenômenos. Essa proposta deve ser embasada em três pilares principais: o aprendizado centrado nos estudantes; que tenha o uso de boas ferramentas no processo de ensino e aprendizagem; e, ainda, propostas fundamentadas no paradigma do pensamento sistêmico.

A partir dos três pilares da proposta educacional discutida por Richmond (1993), propusemos uma intervenção didático-pedagógica, na perspectiva da Educação em Ciências, a partir de um projeto de modelagem que segue tais parâmetros. Em relação às ações serem voltadas para os estudantes, desenvolvemos a intervenção na abordagem LbM (Borkulo, 2009), em que se destaca pelo protagonismo estudantil; no que se refere ao uso de ferramentas, tivemos como base os resultados de diversas pesquisas (i.e. Mioduser et al., 2012) que sustentam o *DynaLearn* como ferramenta poderosa na representação de sistemas dinâmicos; em relação ao Paradigma do Pensamento, tivemos como base os conceitos da SD (Salles et al., 2012).

Pressupostos para alcançar o pensamento sistêmico, na escola

Caulfield e Maj (2001) mostram que os conceitos da SD possibilitam desenvolver o pensamento sistêmico. A SD se caracteriza por uma atividade relacionada à construção de modelos computacionais de simulação sobre problemas complexos, além de experimentar e estudar o comportamento desses modelos ao longo do tempo (Caulfield e Maj, 2001). Por outro lado, o pensamento sistêmico é uma forma de pensar, numa visão mais robusta e crítica, de um determinado fenômeno.

Nesse sentido, Richmond (1993) apresenta o pensamento sistêmico em sete faixas de habilidades, o qual o autor também chama de "Habilidades de Pensamento Crítico" (Richmond, 1993, p. 122):

a) Pensamento dinâmico: é a capacidade de deduzir padrões de comportamento. Para isso é preciso pensar nos fenômenos como resultados de processos circulares e contínuos que acontecem ao longo do tempo. Para desenvolver essa habilidade, os estudantes devem pensar em diversos processos do dia-a-dia em termos gráficos, relacionando sempre com o tempo. Outra estratégia para desenvolver essa habilidade é relacionada ao uso de modelos simples, em que os estudantes podem ser solicitados a identificar resultados de padrões de comportamento quando um determinado sistema for perturbado.

b) Pensamento em loops fechados: é a habilidade de pensar em ciclos fechados. Isso significa: enxergar o mundo como um conjunto de processos contínuos e interdependentes, com relações de causa e efeito circulares, com a atuação dos mecanismos de retroalimentação nos sistemas.

c) Pensamento genérico: é a habilidade de compreender os mecanismos de retroalimentação como princípio básico inerente a comportamentos específicos em diferentes fenômenos. Para desenvolver esse tipo de pensamento, os estudantes devem ser inseridos em situações em que eles trabalhem com estruturas genéricas e que, progressivamente, compreendam comportamentos mais complexos.

d) Pensamento estrutural: uma das faixas mais rigorosas dos sistemas. É aqui que os estudantes devem pensar em termos de unidades de medidas. Essa habilidade do pensamento sistêmico consiste em buscar a coerência entre as unidades de medida usadas para representar diferentes variáveis de um sistema. Assim como às leis de conservação física devem ser rigorosamente cumpridas. Nessa habilidade do

pensamento sistêmico, é exigida a diferença entre fluxo (taxas) e estoques (variáveis de estado).

e) Pensamento operacional: O pensamento operacional significa pensar em termos de como as coisas realmente funcionam. Para isso, é preciso perceber como os estudantes analisam os processos do mundo real. Nessa habilidade, os estudantes podem esquematizar e descrever as observações resultantes de como funciona o sistema.

f) Pensamento contínuo: O pensamento contínuo é alimentado por abordagens que utilizam processos contínuos. Por exemplo, o consumo de água seria continuamente afetado na medida em que água disponível estivesse se esgotando. Ou seja, medidas como racionamento e aumento dos preços da água entrariam em ação para controlar o sistema e não deixar que a água chegue à zero. O pensamento contínuo é a habilidade de encontrar soluções intermediárias entre duas extremidades que parecem ser diferentes. Seria encontrar "tons de cinza entre extremos de branco e preto" (Richmond, 1993, tradução nossa).

g) Pensamento científico: esta é a habilidade de teste de hipóteses. Nessa habilidade é possível desenvolver a capacidade de quantificar as variáveis de um sistema, mesmo sem fazer medições. Por exemplo, é possível estabelecer uma escala, mas sem especificar exatamente (com o rigor quantitativo) quais desses valores estão no sistema real.

Pesquisas no contexto internacional mostram que escolas estadunidenses utilizam a SD para desenvolver o pensamento sistêmico há alguns anos (Forrester, 2009). E de fato, Caulfield e Maj (2001) pontuam que, no contexto estadunidense, a SD foi uma das melhores abordagens para desenvolver o pensamento sistêmico (Caulfield e Maj, 2001).

Segundo Forrester (2009), ainda nas séries iniciais, no contexto estadunidense, já são introduzidos conceitos base da SD, e que podem levar os estudantes ao desenvolvimento do pensamento sistêmico. Entre esses conceitos, destacamos: processos, taxas, influências diretas, proporcionalidades qualitativas, variáveis de estado (também chamadas de estoques), desigualdades, fluxos e os mecanismos de retroalimentação. Todos esses conceitos são essenciais para compreender como funcionam os controles em um sistema dinâmico e, por conseguinte, pensar sistemicamente sobre os fenômenos (Salles et al., 2012). Diante disso, é possível

verificar, por meio desses conceitos, se os estudantes compreendem (ou não) os comportamentos de sistemas (Forrester, 2009). Não é o objetivo deste texto aprofundar nesses conceitos, mas o detalhamento deles pode ser acessado em Salles et al. (2012).

Procedimentos Metodológicos

No intuito de promover ações em que os estudantes compreendam o comportamento de sistemas naturais, a partir de técnicas de IA, na abordagem da SD, foi necessário implementar uma intervenção, na escola de Educação Básica, de modelagem qualitativa com IA, de 54h aula de 50 minutos cada. Isso porque, até então, os estudantes não tinham acesso a técnicas de IA. Ao total, tivemos a participação de duas turmas (Turma A e Turma B) da 1.^a série do Ensino Médio, de uma instituição pública federal, localizada no Estado de Goiás. A participação dos estudantes, nesta ação, aconteceu por adesão, no contraturno das atividades regulares da escola, com o apoio dos docentes da área de Ciências (Química, Física e Biologia).

Na pesquisa, participaram 25 estudantes da Turma A e 23 da Turma B. Desses, 22 da turma A (88%) e 17 da turma B (74%) concluíram as atividades de modelagem oferecidas, na escola. Os estudantes da Turma A faziam o curso técnico em Informática, integrado ao Ensino Médio; por outro lado, a turma B era composta por estudantes do curso de mineração. Por meio da plataforma *DynaLearn*, os estudantes elaboraram modelos em níveis crescentes de complexidade, ampliando, em níveis crescentes de complexidade, sua visão sobre o comportamento de sistemas naturais.

Nossa intenção foi garantir que os estudantes tivessem participações ativas na representação de sistemas dinâmicos por meio da construção de modelos. Por isso, adotamos a abordagem LbM (Borkulo, 2009) como estratégia para ser usada na representação de sistemas dinâmicos no contexto do Ensino Médio. Com isso, desde o primeiro encontro, os estudantes já iniciaram a exploração da plataforma *DynaLearn*, com a construção de modelos mais simples, no primeiro Espaço de Aprendizagem (em inglês, *Learning Space* - LS1). A partir disso foram construídos modelos gradativamente mais complexos (LS2, LS3), até chegarmos a conceitos mais específicos da SD, como a noção de processos, mecanismos de retroalimentação, influências diretas e proporcionalidades, trabalhados em LS4. No total, foram construídos e explorados 55

modelos, dos quais a grande maioria, 32, foi elaborada em LS4 (principal nível para a abordagem de sistemas complexos). Os exemplos diagramáticos dos modelos construídos pelos estudantes podem ser consultados em Souza et al. (2016), Souza et al. (2017), Souza (2019), Souza et al. (2019), Teodoro et al. (2023), Teodoro et al. (2024), Teodoro e Freire (2025). Durante a intervenção, utilizamos diagramas, livros didáticos, vídeos e noticiários para fundamentar a elaboração dos modelos.

Para a coleta de dados, adotamos questionários, com questões fechadas, embasadas na escala Likert (1932), com o padrão de cinco categorias ('muito difícil', 'difícil', 'médio', 'fácil' e 'muito fácil'). Além disso, este estudo também contou com uma etapa experimental, a partir de pré-testes e pós-testes. Isso implica em um conjunto de questões feitas aos participantes, antes do início da formação (ou antes, de um determinado tratamento experimental), e após a intervenção.

A comparação entre o pré e o pós-teste possibilita determinar se houve (ou não) diferença estatisticamente significativa entre o desempenho dos estudantes. Gil (2012) mostra que as questões, tanto no pré quanto no pós-teste, devem ter o mesmo nível de dificuldade, mas, conforme Cohen et al. (2011) destacam, as perguntas devem ser diferentes. Na prática, são formas equivalentes para perguntar sobre o mesmo conteúdo. O tratamento e a análise estatística dos resultados, da parte experimental deste estudo, foi realizado a partir do teste, não paramétrico, de Wilcoxon pareado (Callegari-Jaques, 2003). Para isso, foi utilizado o programa SPSS [em inglês, *Statistical Package for the Social Sciences*].

Foram aplicadas oito avaliações, sendo quatro pré e quatro pós-testes. Seguimos as orientações, citadas na metodologia deste texto (Rijo, 2008; Cohen et al., 2011), sobre a elaboração e aplicação dos testes. Diante disso, os pré e os pós tiveram o mesmo conteúdo, com perguntas diferentes. E, durante a aplicação, foram destinados entre 10 e 25 minutos para que o teste fosse respondido.

Os testes foram realizados em diferentes níveis de complexidade de *DynaLearn*, com questões envolvendo a estrutura e o funcionamento de sistemas, desde os mais simples, àqueles mais complexos, com representação dos conceitos necessários para o desenvolvimento do pensamento sistêmico. Garantimos que o mesmo grupo de estudantes fosse submetido às análises, sendo uma antes e outra após o tratamento. Abaixo é apresentado a Tabela 1, com o resumo dos testes realizados.

Tabela 1

Resumo dos testes realizados.

Teste	Nível	Tipo de questões	Objetivo principal do teste
1	LS1 e LS2	1- analisar modelos em LS1 e LS2, reconhecendo os elementos e prevendo o comportamento do sistema modelado; 2- Fazer inferências a partir de modelos; 3- tradução de modelos verbais.	Verificar se os estudantes são capazes de identificar a estrutura e reconhecer o funcionamento de sistemas em LS 1 e LS2.
2	LS2	1- construir modelos em LS2, a partir de texto problematizador; 2- interpretar os resultados de um modelo qualitativo.	Verificar se os estudantes são capazes de construir modelos causais básicos e reconhecer o funcionamento desses sistemas.
3	LS3 e LS4	1- interpretar o comportamento de um sistema por meio de gráficos cartesianos; 2- reconhecer os efeitos das magnitudes e derivadas em modelos feitos em LS3 e em LS4.	Verificar se os estudantes são capazes de compreender o funcionamento de sistemas em LS3 e em LS4.
4	LS4	1- representar processos; 2- analisar a coerência entre as unidades de medidas para identificar taxas e variáveis de estados; 3- interpretar gráficos cartesianos; 4- explicar como os processos determinam o comportamento de um sistema.	Verificar se os estudantes são capazes de identificar a estrutura e reconhecer o funcionamento de sistemas em LS4.

Nota. Elaborado pelo autor.

Foi adotado o nível de significância de 5% (0,05) para as análises e a rejeição, ou aceitação, da hipótese nula foi dada pelo valor de *psig* no teste de Wilcoxon. Para valores de *psig* maiores que 0,05 ou 5%, as diferenças são tidas como não significativas. Isso significa que os resultados das amostras comparadas não podem ser distinguidos do ponto de vista da análise estatística. Valores de *psig* menores que 0,05 indicam que as diferenças são significativas.

Esses instrumentos investigaram a apropriação de conceitos, conforme destacados na fundamentação teórica deste texto; bem como a concepção dos estudantes sobre a construção de modelos, em diferentes níveis de complexidade. As aulas foram subdivididas da seguinte forma: 44 horas-aula regulares de modelagem, oito horas-aula de atendimento para auxílio nas tarefas e esclarecimento de dúvidas, e duas horas-aula destinadas à apresentação dos trabalhos para a comunidade escolar (totalizando, 54h/aula). A sequência de atividades buscou contribuir para a aquisição de conceitos científicos pelos estudantes, no desenvolvimento do raciocínio lógico, na compreensão de fenômenos gerados em sistemas dinâmicos, bem como no

desenvolvimento de habilidades relacionadas ao pensamento sistêmico (Richmond, 1993), como mostra a Tabela 2.

Tabela 2

Habilidades para pensar sistemicamente segundo Richmond (1993).

Habilidade do Pensamento crítico	Principais noções	Verificação na intervenção
Pensamento dinâmico	Previsão de comportamento. Isso colabora para pensar sobre a variação do sistema ao longo do tempo, ou seja, pensar em sistemas dinâmicos, em lugar da análise de eventos isolados.	Atividades de pré e pós-testes.
Pensamento em loops fechados	Enxergar o mundo como processos contínuos, interdependentes e circulares, por meio de mecanismos de retroalimentação.	Questionário.
Pensamento genérico	Nível crescente de trabalhos envolvendo estruturas genéricas a comportamentos mais complexos, uma vez que mecanismos geram efeitos similares em diferentes sistemas.	Atividades de pré e pós-testes.
Pensamento estrutural	Coerência entre as unidades de medidas, diferenciando taxas e estoques.	Questionário.
Pensamento operacional	Interpretação de como os sistemas funcionam.	Atividades de pré e pós-testes.
Pensamento contínuo	Pensamento sobre aspectos contínuos dos sistemas, identificando gradientes de comportamentos e características.	Atividades de pré e pós-testes.
Pensamento científico	Teste de hipóteses.	Atividade de pré e pós-testes.

Nota. Elaborado pelo autor.

Em consonância com o nosso objetivo, de demonstrar que o uso e a construção de modelos de simulação, utilizando técnicas de IA, pode promover o pensamento sistêmico, no contexto da sala de aula, na Educação em Ciências, destinamos maior carga horária aos modelos em LS4. É nesse espaço de aprendizagem que representamos processos, taxas e mecanismos de retroalimentação essenciais para o pensamento sistêmico.

A identificação detalhada de cada modelo trabalhado no *software DynaLearn*, bem como a sua distribuição por espaço de aprendizagem, está disponível em (Autor do Trabalho). Cumpre destacar que a pesquisa foi conduzida sob estritos critérios éticos: todos os estudantes e seus respectivos responsáveis assinaram o Termo de Consentimento Livre e Esclarecido (TCLE), e o anonimato dos participantes e da instituição escolar foi integralmente preservado ao longo de todo o desenvolvimento do estudo.


Resultados e discussão

O primeiro ponto muito importante para avaliarmos, durante este estudo, foi a concepção dos estudantes sobre conceitos específicos sobre as técnicas de IA necessárias para o desenvolvimento do pensamento sistêmico. Alguns dos conceitos para a compreensão de sistemas, conforme mencionado na fundamentação teórica deste texto (Richmond, 1993), são fundamentais no desenvolvimento do pensamento sistêmico, como: Processos, Taxas, Influências diretas, Proporcionalidades qualitativas, Variável de estado, Agentes, Desigualdades, Variáveis exógenas e Retroalimentação. Segundo Salles et al. (2012), esses conceitos constituem a base ontológica para que os estudantes pensem sistemicamente. De fato, com a apropriação conceitual, os estudantes podem representar e descrever objetos, situações, relações de causalidade, premissas e previsão de mecanismos de mudanças.

Na pesquisa, foi possível notar uma maior variação entre os graus de dificuldade, segundo os dados coletados, principalmente sobre o conceito de 'Processos', primordial na modelagem baseada na SD, seja qualitativa ou seja numérica (Richmond, 1993). Este conceito, conforme pode ser visto na Figura 1, foi classificado por grande parte dos estudantes da turma A (60%) como 'fácil'. Na turma B, 60% mencionaram como 'médio', 20% 'muito fácil' e 20% 'difícil'.

Figura 1

Grau de dificuldade sobre Processos




Nota. Elaborada pelo autor.

Outro conceito fundamental na modelagem é a compreensão de Taxas (Richmond, 1993). Nesse caso, 73,33% da turma A sugerem ser ‘fácil’, ou ‘muito fácil’ (Figura 2).

Figura 2

Grau de dificuldade sobre Taxas



Nota. Elaborada pelo autor.


Na turma B, considerando essas categorias, o número é de 60%. De acordo com Richmond (1993), a estruturação do pensamento sistêmico exige que o estudante compreenda a diferenciação entre as variáveis de estado (estoques) e as taxas (fluxos).

No contexto da modelagem qualitativa, essa dinâmica é manifestada pelas ações que causam mudanças no sistema (ou seja, os processos). Diante disso, os sujeitos da pesquisa precisam desenvolver a habilidade de discernir os processos que regem o sistema e as taxas associadas a eles, permitindo-lhes compreender quais variáveis ingressam ou saem de um sistema complexo. As Figuras 1 e 2 apresentam, respectivamente, os resultados referentes à percepção de dificuldade quanto a esses dois conceitos centrais: os processos e as taxas.

Em relação às Influências diretas, outro conceito importante que expressa causalidade (Richmond, 1993), percebemos que na turma A, 53,33% dos participantes consideram ‘fácil’ ou ‘muito fácil’, e 13,33% ‘difícil’ (Figura 3). Na turma B, 50% indicam ser ‘fácil’ ou ‘muito fácil’, e 30% consideram ‘difícil’. Por outro lado, as influências diretas (proporcionalidades qualitativas), na turma A é avaliada com 66,66% de indicação como ‘fácil’ ou ‘muito fácil’. Na turma B, essas categorias são consideradas por 80% dos estudantes. Esses números são mostrados nas Figuras 3 e 4.

Figura 3


Grau de dificuldade sobre Influências diretas



Nota. Elaborada pelo autor.

Figura 4

Grau de dificuldade sobre Proporcionalidades qualitativas



Nota. Elaborada pelo autor.


As variações percentuais entre as turmas indicam que, embora os grupos tenham sido submetidos à mesma proposta de modelagem com o *DynaLearn*, a apropriação dos conceitos não ocorreu de forma homogênea. A acentuação da dificuldade na turma B em conceitos de causalidade direta (influências diretas) pode estar atrelada a própria transição do pensamento linear para o pensamento sistêmico, em que a identificação de processos e taxas exige maior nível de abstração. Por outro lado, o alto índice de facilidade da turma B com as proporcionalidades (80%) sugere uma inclinação desse grupo para correlações de dependência direta e estática entre variáveis, um raciocínio que costuma ser mais intuitivo.

Essas assimetrias reforçam que o desenvolvimento do pensamento sistêmico não ocorre de maneira uniforme, sendo diretamente atravessado pelas particularidades de cada ambiente de sala de aula. Embora o mapeamento detalhado do histórico escolar dos sujeitos fuja do escopo desta pesquisa, entende-se que cada turma constitui um cenário dinâmico singular. Fatores como a heterogeneidade dos perfis de aprendizagem, fortemente atrelados à bagagem técnica do curso de origem (Informática ou Mineração), as demandas do contexto de inserção e o nível de formação crítica já consolidado ou em desenvolvimento pelos estudantes moldam as diferentes percepções de facilidade ou dificuldade observadas entre os grupos.

No que tange à variável de estado (o estoque de um sistema), o nível "médio" de complexidade foi o mais apontado por ambos os grupos, embora com distribuições distintas. Na turma A, essa categoria concentrou 53,33% das respostas. Já na turma B, o nível "médio" é de 40% das menções (Figura 5).

Figura 5

Grau de dificuldade sobre Variáveis de estado



Nota. Elaborada pelo autor.


Essa divergência no formato das distribuições indica que, embora a variável de estado seja um conceito estrutural básico, sua percepção é moldada pelas particularidades de cada sala de aula. A maior concentração de respostas na turma A, em contraste com o perfil simétrico e diluído da turma B, reforça que cada grupo se comporta como um ecossistema singular. Fatores subjetivos e intrínsecos a cada cenário, como os diferentes perfis de aprendizagem e a familiaridade prévia com

representações gráficas de acúmulos, influenciam diretamente o modo como os estudantes processam e avaliam a complexidade das ferramentas de modelagem.

No que concerne ao conceito de desigualdades, as respostas revelaram dinâmicas opostas de concordância entre as turmas investigadas. Na turma A, as percepções fragmentaram-se de maneira marcadamente heterogênea, conforme pode ser visto na Figura 6: 46,67% classificaram o item como "médio", 40% como "fácil" e o restante o considerou "difícil". Em contrapartida, a turma B exibiu um perfil de respostas muito mais concentrado e consensual, com 70% dos estudantes situando o conceito no nível "médio" (Figura 6). Essa assimetria evidencia, novamente, como a recepção de ferramentas de modelagem é sensível ao contexto de cada sala de aula. Enquanto a dispersão da turma A reflete ritmos e históricos de aprendizagem diversos coexistindo no mesmo espaço, a concentração observada na turma B sugere uma interpretação mais homogênea do grupo quanto à complexidade moderada desse descritor.

Figura 6

Grau de dificuldade sobre desigualdades




Nota. Elaborada pelo autor.

No que diz respeito aos ciclos de *feedback*, a retroalimentação balanceadora (Figura 7) revelou percepções distintas entre os grupos: enquanto 53,33% da turma A classificou como "fácil" ou "muito fácil", 60% da turma B a considerou de nível "médio".

Figura 7

Grau de dificuldade sobre Retroalimentação balanceadora




Nota. Elaborada pelo autor.

Essa diferença reitera que a familiarização com estruturas de autorregulação do sistema varia de acordo com as particularidades e o perfil de cada sala de aula.

Por outro lado, a retroalimentação reforçadora (Figura 8) gerou uma convergência notável de complexidade entre as turmas, sendo avaliada majoritariamente como "médio" (40% na turma A e 50% na turma B) e apontada como "difícil" ou "muito difícil" por aproximadamente 30% dos estudantes de ambos os grupos. Essa percepção generalizada de maior dificuldade nos *loops* reforçadores é coerente com os desafios inerentes à modelagem sistêmica. Estruturas reforçadoras rompem com o raciocínio linear e descritivo ao gerarem comportamentos de crescimento ou declínio exponenciais, demandando dos estudantes de ambas as turmas um esforço reflexivo superior para compreender o efeito cumulativo que rege esses fenômenos.

Figura 8

Grau de dificuldade sobre Retroalimentação reforçadora



Nota. Elaborada pelo autor.

Conforme Richmond (1993), os conceitos aqui explorados são essenciais para o desenvolvimento do pensamento sistêmico e estão intrinsecamente ligados a fenômenos naturais. Ao analisar uma inundação urbana (Teodoro et al. 2024), por exemplo, a compreensão de suas consequências (como danos sociais, econômicos e a desarticulação da infraestrutura local) exige uma avaliação sistêmica dos múltiplos fatores e retroalimentações que compõem o evento, superando a análise de causalidade linear simples.


Modelagem como compreensão de sistema

Para avaliarmos a modelagem como compreensão de um sistema, elaboramos quatro sentenças: 1- A modelagem me fez pensar sobre os sistemas de uma forma diferente; 2- Ser capaz de simular os modelos me ajudou a desenvolver minha compreensão do comportamento dos sistemas; 3- A modelagem qualitativa pouco contribuiu para o meu entendimento de como se comporta um sistema; 4- as simulações tornam mais difícil o reconhecimento das relações de causa e efeito que operam no sistema.

Os estudantes concordam ou concordam plenamente que a modelagem contribui para pensar em sistemas (Figura 9).

Figura 9

Grau de concordância dos estudantes sobre a modelagem para pensar em sistemas




Nota. Elaborada pelo autor.

Assim como, 100% da turma A concorda ou concorda plenamente que as simulações colaboram para desenvolver a compreensão do comportamento dos sistemas (Figura 10). Na turma B, 30% dos estudantes indicaram 'neutro' para esta afirmação. Os demais concordam ou concordam plenamente.

Figura 10

Grau de concordância dos estudantes quanto ao papel das simulações na compreensão de sistemas



Nota. Elaborada pelo autor.


Essa divergência acentuada evidencia como o cenário de cada grupo interfere na recepção da modelagem. Como as turmas pertencem a cursos técnicos com matrizes e focos distintos (Informática e Mineração), é legítimo inferir que o perfil formativo e possivelmente a familiaridade prévia com ferramentas e tecnologias digitais afetam nessa percepção. Para os estudantes da área de Informática, a linguagem de modelagem e a interação com interfaces de *software* (como o *DynaLearn*) tendem a ser incorporadas de forma mais natural e fluida.

Em contrapartida, para os estudantes do curso de Mineração, a transição para um ambiente de simulação digital complexo pode ter demandado um esforço adaptativo diferente, justificando o maior índice de respostas neutras como um reflexo de um grupo que ainda estava tateando a novidade tecnológica. Adicionalmente, não se pode descartar o efeito da cultura interna e da influência mútua entre os pares dentro do ecossistema de cada sala de aula, fatores que naturalmente moldam as tendências de resposta em questionários de percepção.

As afirmações 3 e 4 são antagônicas às afirmações 1 e 2. Quando afirmado que a modelagem qualitativa pouco contribuiu para o meu entendimento de como se comporta um sistema (afirmação 3), e as simulações tornam mais difíceis o reconhecimento das relações de causa e efeito que opera no sistema (afirmação 4), 100% dos estudantes discordaram ou discordaram totalmente das referidas afirmações, conforme mostram as Figuras 11 e 12.

Figura 11


Grau de concordância dos estudantes em relação à premissa de que a modelagem pouco contribui para o entendimento de sistemas



Nota. Elaborada pelo autor.

Figura 12

Grau de concordância dos estudantes sobre a premissa de que as simulações tornam difíceis as relações causais



Nota. Elaborada pelo autor.

Etapa experimental deste estudo

A aplicação dos pré e pós testes constituiu a parte experimental da pesquisa, e teve por objetivo verificar, estatisticamente, se a construção e a manipulação de modelos qualitativos contribuíram para a compreensão dos estudantes sobre a estrutura e o funcionamento de sistemas. Os resultados das duas turmas foram resumidos e apresentados nas Tabelas 3 e 4.

Tabela 3

Resultados do teste de Wilcoxon na turma A

Teste	Somatória de pontos dos testes	Média do pré-teste	Média do pós-teste	Valores de psig	Significância
1	20,0 pontos	$\bar{X}_{\text{pré-teste}} = 15,56$	$\bar{X}_{\text{pós-teste}} = 18,13$	psig<0,05	Sim
2	30,0 pontos	$\bar{X}_{\text{pré-teste}} = 23,00$	$\bar{X}_{\text{pós-teste}} = 27,47$	psig<0,05	Sim
3	15,0 pontos	$\bar{X}_{\text{pré-teste}} = 10,29$	$\bar{X}_{\text{pós-teste}} = 13,29$	psig<0,05	Sim
4	20,0 pontos	$\bar{X}_{\text{pré-teste}} = 15,40$	$\bar{X}_{\text{pós-teste}} = 17,65$	psig<0,05	Sim

Nota. Elaborada pelo autor.

Analogamente ao procedimento realizado com o primeiro grupo, o Teste de Wilcoxon também foi aplicado para analisar o comportamento da Turma B, cujos resultados e níveis de significância estão detalhados na Tabela 4.

Tabela 4

Resultados do teste de Wilcoxon - turma B

Teste	Somatória de pontos dos testes	Média do pré-teste	Média do pós-teste	Valores de psig	Significância
1	20,0 pontos	$\bar{X}_{\text{pré-teste}} = 12,54$	$\bar{X}_{\text{pós-teste}} = 18,46$	psig<0,05	Sim
2	30,0 pontos	$\bar{X}_{\text{pré-teste}} = 21,53$	$\bar{X}_{\text{pós-teste}} = 27,73$	psig<0,05	Sim
3	15,0 pontos	$\bar{X}_{\text{pré-teste}} = 8,62$	$\bar{X}_{\text{pós-teste}} = 11,54$	psig<0,05	Sim
4	20,0 pontos	$\bar{X}_{\text{pré-teste}} = 14,29$	$\bar{X}_{\text{pós-teste}} = 17,65$	psig<0,05	Sim

Nota. Elaborada pelo autor.

A análise estatística dos resultados obtidos em todos os testes, nas turmas A e B indica que houve diferenças significativas entre os respectivos pré e pós-testes. Assim, a construção e a manipulação de modelos resultaram em diferenças estatisticamente significativas na melhora do desempenho dos estudantes sobre a estrutura e o funcionamento de sistemas.

Os resultados obtidos na etapa experimental corroboram a proposição de Hashem e Mioduser (2013) de que o ciclo de elaborar, testar e refinar modelos, característico da abordagem LbM, funciona como o mecanismo para o desenvolvimento das habilidades do pensamento sistêmico, preconizadas por Richmond (1993). A necessidade de confrontar as próprias hipóteses com o comportamento simulado pelo modelo de simulação incentiva o estudante a reestruturar suas percepções e a compreender as teias de causa e efeito que regem o sistema estudado. Essa articulação teórico-prática justifica os resultados observados no pós-teste em ambas as turmas.

Com efeito, a construção de modelos, durante a intervenção, por parte dos estudantes, foi a base principal da proposta. Os resultados indicam que o tratamento experimental, com práticas de modelagem sobre diversos temas, favoreceu o desenvolvimento da compreensão dos estudantes sobre sistemas.

É importante mencionar que a complexidade na modelagem foi explorada de forma crescente, iniciando com sistemas simples, em LS1 e em LS2. Após a familiaridade dos estudantes com modelos mais simples, o nível de complexidade foi aumentado para sistemas em LS3, os quais já evidenciam a dinâmica, e finalmente, atividades em LS4, com processos e feedbacks.

As questões dos testes, abrangem-se quatro categorias importantes para a compreensão de sistemas, conforme mostramos em nossa fundamentação teórica,

sobretudo com Richmond (1993): a) Estrutura de sistemas, b) Previsão e explicação do comportamento de sistemas; c) Predições de resultados com efeitos causados por processos antagônicos; d) Construção de modelos [desde os mais simples, aos mais complexos]. Por meio dessas categorias, foi possível agregar resultados de diferentes testes e aplicar novamente o teste estatístico de Wilcoxon. Com essa ação foi possível verificar se, nas referidas categorias, houve ou não diferença significativa, seguindo os objetivos avaliados na tabela 5.

Tabela 5

Itens avaliados nas categorias elaboradas

Categoria	Objetivos avaliados
Estrutura do sistema (ES)	a) Identificar entidades, quantidades, configurações, espaços quantitativos, valores possíveis para as derivadas. b) Reconhecer os efeitos das magnitudes e derivadas.
Previsão e explicação do comportamento do sistema (PECS)	a) Interpretar resultados de simulações. b) realizar inferências e explicar o comportamento de sistemas.
Previsão de resultados com efeitos causados por processos antagônicos (PREPA)	Interpretar como os processos antagônicos determinam o comportamento de um sistema.
Construção de modelos (CM)	Construir modelos nos diferentes níveis de complexidade.

Nota. Elaborado pelo autor.

Complementando esse panorama, a Tabela 6 detalha os desdobramentos desses mesmos indicadores para a turma A.

Tabela 6

Resultados do teste de Wilcoxon a partir de categorias na turma A (n = 22)

Categoria	Somatória de pontos/ categoria	Média/ pré-testes	Média/ pós-testes	Valores de psig	Significância
ES	15,0 pontos	$\bar{X}_{\text{pré-teste}} = 7,38$	$\bar{X}_{\text{pós-teste}} = 10,10$	psig<0,05	Sim
PECS	19,0 pontos	$\bar{X}_{\text{pré-teste}} = 12,86$	$\bar{X}_{\text{pós-teste}} = 14,29$	psig<0,05	Sim
PREPA	14,0 pontos	$\bar{X}_{\text{pré-teste}} = 9,04$	$\bar{X}_{\text{pós-teste}} = 11,12$	psig>0,05	Não
CM	37,0 pontos	$\bar{X}_{\text{pré-teste}} = 23,38$	$\bar{X}_{\text{pós-teste}} = 28,33$	psig<0,05	Sim

Nota. Elaborada pelo autor.

Na sequência, a Tabela 7 condensa a segunda parte dos resultados, organizados sob o mesmo critério analítico, para a turma B.

Tabela 7

Resultados do teste de Wilcoxon a partir de categorias na turma B (n = 17)

Categoria	Somatória de pontos/ categoria	Média/ pré-testes	Média/ pós-testes	Valores de psig	Significância
ES	15,0 pontos	$\bar{X}_{\text{pré-teste}} = 6,06$	$\bar{X}_{\text{pós-teste}} = 9,44$	psig<0,05	Sim
PECS	19,0 pontos	$\bar{X}_{\text{pré-teste}} = 14,75$	$\bar{X}_{\text{pós-teste}} = 16,75$	psig<0,05	Sim
PREPA	14,0 pontos	$\bar{X}_{\text{pré-teste}} = 8,47$	$\bar{X}_{\text{pós-teste}} = 9,65$	psig>0,05	Não
CM	37,0 pontos	$\bar{X}_{\text{pré-teste}} = 21,47$	$\bar{X}_{\text{pós-teste}} = 30,76$	psig<0,05	Sim

Nota. Elaborada pelo autor.

Os resultados indicam que, em ambas as turmas, houve diferenças significativas entre os respectivos pré e pós-testes nas categorias 'ES', 'PECS' e 'CM'. No que se refere à categoria 'Previsão de resultados com efeitos causados por processos antagônicos', os testes não deram diferença significativa. Ou seja, não houve diferença no desempenho dos estudantes entre os pré e os pós-testes, dessa categoria. Nessa categoria, o teste foi composto por três questões. Nas duas primeiras não teve diferença significativa porque os estudantes tiveram bom desempenho no par de testes. No entanto, na terceira questão, os estudantes não tiveram bons resultados. Isso aconteceu porque o exercício, formulado por nós, não foi suficientemente claro.

Considerações finais

“O modelo permite a gente ter uma visão de todos os assuntos, da gente aprofundar mais sobre aquilo que influencia as coisas. E outra coisa, não é um estudo cansativo porque primeiro você entende, você tenta entender, você se diverte fazendo, você aprende mais e ainda por cima você cria uma opinião.”

(Estudante participante da intervenção)

Os resultados deste texto foram fundamentados duas bases teóricas: o pensamento sistêmico e a SD. Além disso, nos apropriamos do *DynaLearn* como instrumento de modelagem para representar diagramaticamente o comportamento de sistemas físicos. Durante toda a intervenção, os estudantes construíram modelos,

valorizando a abordagem escolhida neste estudo, LbM. Essa abordagem enfatiza o protagonismo dos estudantes no processo de aprendizagem, uma vez que eles constroem modelos, fazem adaptações e analisam os sistemas e os resultados das simulações.

Diversas estratégias de trabalho, para alcançarmos os nossos objetivos, foram realizadas valorizando o protagonismo estudantil, em abordagem LbM, com trabalhos, junto aos estudantes, abrangendo conceitos fundamentais para o desenvolvimento do pensamento sistêmico. Dessa forma, consideramos que esse conjunto de conceitos foi importante para possibilitar que os estudantes utilizassem a linguagem de modelagem para representar fenômenos em níveis crescentes de complexidade, e tivessem solidez na representação do conhecimento por meio de sistemas, reconhecendo, inclusive, que no mundo as 'coisas' estão interconectadas.

Os resultados encontrados nas atividades de pré e pós-testes e questionários nos deram evidências de que a modelagem baseada na SD, pode promover o pensamento sistêmico. De fato, a etapa experimental demonstrou que práticas de modelagem baseadas no ciclo de elaborar, testar e refinar modelos, em consonância com as proposições de Hashem e Mioduser (2013), expandem a capacidade dos estudantes de identificar a estrutura e compreender o funcionamento de sistemas, desde os cenários mais simples aos mais complexos, o que tangibiliza o desenvolvimento das habilidades defendidas por Richmond (1993).

Esta pesquisa também pôde identificar algumas características (que podem ser limitações em alguns contextos) para o desenvolvimento de trabalhos de modelagem nas escolas de Educação Básica. É prudente dizer que as condições de trabalho do professor influenciam diretamente na execução de projetos de pesquisa como este. A modelagem qualitativa é computacional, o que implica no uso de computadores em pleno funcionamento e com acesso à internet. Além disso, os professores precisam de tempo para planejamento das atividades, para que eles se apropriem de estudos e ferramentas como essas explicitadas neste estudo. *DynaLearn* é um instrumento poderoso para a representação de sistemas dinâmicos; porém, o manuseio da plataforma exige intenso período de aprendizagem, dedicação e trabalho para a construção de modelos e de outros materiais. É essencial envolver os professores na modelagem qualitativa para que esta ferramenta realmente possa desenvolver todo o potencial para transformar a educação científica.

Referências

- Borkulo, S. P. (2009). The assessment of learning outcomes of computer modeling in secondary science education. Ph.D. thesis, University of Twente, The Netherlands.
- Bredeweg, B., Liem, J., Beek, W., Linnebank, F., Gracia, J., Lozano, E., ... & Mioduser, D. (2013). *DynaLearn* – An Intelligent Learning Environment for Learning Conceptual Knowledge. *AI Magazine*, 34(4), 46-65.
- Callegari-Jaques, S. M. (2003). Bioestatística- Princípios e Aplicações, Porto Alegre: Artmed, 239(1), 166-167.
- Caulfield, C. W., & Maj, S. P. (2001). A case for systems thinking and system Dynamics. Proceedings of the IEEE International Conference on Systems, Man and Cybernetics, Tucson, AZ, 2793-2798.
- Cohen, L, Manion, L., & Morrison, K. (2011). Research Methods in Education. 7th Edition. New York: Routledge.
- Forbus, K. D. (1984). Qualitative Process Theory. *Artificial Intelligence*, 24(1), p. 85-168.
- Forrester, J. W. (2009). Learning through System Dynamics as Preparation for the 21st Century. Portland, OR: Productivity Press. Reviewed in 2009. Disponível em: <http://web.mit.edu/sysdyn/sd-intro/D-4434-1.pdf>. Acesso em 27 abr 25.
- Gil, A. C. (2012). Métodos e Técnicas de Pesquisa Social. 6 ed. São Paulo: Atlas.
- Guerin Junior, C., Cunha, F. I. J., Dinardi, A. J., Teodoro, P. V. (2024). Saberes Didático-pedagógicos a partir de Modelos Didáticos Tridimensionais: em foco, o Ensino de Ciências. *Ensino & Pesquisa*, 22(1), 690-704.
- Hashem, K., Mioduser, D. (2013). Learning by Modeling (LbM): Understanding Complex Systems by Articulating Structures, Behaviors, and Functions. *International Journal of Advanced Computer Science and Applications*, 4(4), 80-86.
- Likert, R. (1932). A technique for the measurement of attitudes. *Archives of Psychology*, 22(140), 44-53.
- Lyneis, D. A. (2013). Bringing system dynamics to a school near you: suggestions for Introducing and Sustaining System Dynamics in K-12 Education. Acton, MA, 2013. Disponível em: <http://www.clexchange.org/gettingstarted/intropacket.asp>. Acesso em 29 abr 2025.
- Mioduser, D. et al. (2012). Final report on *DynaLearn* evaluation studies. *DynaLearn*, EC FP7 STREP project 231526, Deliverable D7.4.
- Richmond, B. (1993). Systems thinking: critical thinking skills for the 1990s and beyond. *System Dynamics Review*, 9(2), 113-133.
- Rijo, P. M. (2008). Orientações para pré e pós-teste. Washington: I-TECH, 2008. 8 p. Disponível em:

<https://docplayer.com.br/24207-Utilizacao-dos-pre-e-pos-testes-desenvolvimento-do-pre-e-pos-teste.html>. Acesso em: 12 set. 2025.

Salles, P., Bredeweg, B., Noble, R., Zitek, A., & Souza, A. B. (2012). Qualitative Model Patterns: a Toolkit for Learning by Modelling. *In 26th International Workshop on Qualitative Reasoning*, Playa Vista, CA, USA (Vol. 1).

Teodoro, P. V., Salles, P., & Gauche, R. (2023). A qualitative model of the evaporation process for science education. *Proceedings of 15th Conference of the European Science Education Research Association (ESERA)*, Capadócia, Turquia.

Teodoro, P. V., Salles, P., & Gauche, R. (2024). De um Simples Modelo à Complexidade de um Sistema Dinâmico: a transformação dos estados físicos e a tempestade. *Revista da Sociedade Brasileira de Ensino de Química*, 5(1), p. e052407.

Teodoro, P. V., & Freire, V. (2025). Artificial Intelligence and Qualitative Reasoning in Science Education: A Systematic Review of Lusophone Literature (2000–2024). *In* A. I. Cristea, E. Walker, Y. Lu, O. C. Santos, & S. Isotani (Eds.) *Artificial Intelligence in Education* (25th ed., pp. 449-456). Springer Nature.

Salles, P. et al. (2010). FUB evaluation of DynaLearn prototype. DynaLearn, EC FP7 STREP project 231526, Deliverable D7.2.1.

Souza, P. V. T. (2019). *Modelos de simulação qualitativos como estratégia para o ensino de ciências* [Tese de Doutorado, Universidade de Brasília].

Souza, P. V. T., Salles, P., & Gauche, R. (2016). Elementos para a elaboração de uma estratégia didática para o ensino de Química, destinada ao aprendizado de surdos e ouvintes, baseada em Raciocínio Qualitativo. *Anais do XVIII Encontro Nacional de Ensino de Química*. UFSC.

Souza, P. V. T., Salles, P., Gauche, R. (2017). Um modelo de simulação baseado em raciocínio qualitativo para a educação em ciências. *ACTIO: Docência em Ciências*, 2(1), 162-183.

Souza, P. V. T., Salles, P., & Gauche, R. (2019). O uso de modelos qualitativos como recurso didático para o Ensino de Ciências. *Atas do XII Encontro Nacional de Pesquisa em Educação em Ciências*. UFRN.

Submetido em: 25/02/2026

Aceito em: 23/04/2026

Publicado em: 25/09/2026

Periódico organizado pela Sociedade Brasileira de Ensino de Química – SBEnQ

Sociedade **B**rasileira
de **E**nsino de **Q**uímica



Este texto é licenciado pela Creative Commons Attribution 4.0 International License.
