

Ciências da natureza e suas tecnologias

Inteligência artificial: análise dos obstáculos epistemológicos emergentes na leitura visual de hidrocarbonetos

Artificial intelligence: analysis of emerging epistemological obstacles in the visual reading of hydrocarbons

Inteligencia artificial: análisis de los obstáculos epistemológicos emergentes en la lectura visual de hidrocarburos

Gabriel Mateus Arantes Pereira¹   e Irene Cristina de Mello²  

Resumo

As inteligências artificiais generativas (IAs) não compreendem microscopicamente os problemas químicos submetidos a elas. O objetivo deste artigo é investigar a precisão das nomenclaturas de hidrocarbonetos geradas por IAs (ChatGPT e Gemini) por meio do reconhecimento visual de estruturas químicas, para avaliar as barreiras epistemológicas emergentes nessa interação. Para tanto, foram escolhidas dez estruturas e adota-se a perspectiva qualitativa e a análise de conteúdo. Após a análise das respostas, foram percebidos os erros verbais e do realismo qualitativo devido à geração de termos incompatíveis com as estruturas em quantidade de carbonos, presença ou não de ramificações e insaturações. A utilização cega e sem criticidade dessas IAs como ferramentas de resolução de exercícios tende a criar nos alunos barreiras epistemológicas graves, promovendo assim dificuldades de aprendizagem de conceitos futuros na química.

Palavras-chave: Ensino de Química Orgânica. Barreiras Epistemológicas. Inteligência Artificial.

Abstract

Artificial Intelligences (AIs) do not possess a deep understanding of the phenomena submitted to them. The objective of this article is to investigate the accuracy of hydrocarbon nomenclatures generated by AIs (ChatGPT and Gemini) through the visual recognition of chemical structures, in order to evaluate the emerging epistemological barriers in this interaction. To this end, ten structures were selected, and a qualitative perspective and content analysis were adopted. After analyzing the responses, verbal errors and issues with qualitative realism were identified due to the generation of terms incompatible with the structures regarding the number of carbons, presence or absence of branches, and unsaturations. The blind and uncritical use of these AIs as exercise-solving tools tends to create severe epistemological barriers in students, thereby fostering learning difficulties for future concepts in chemistry.

Keywords: Teaching Organic Chemistry. Epistemological Barriers. Artificial Intelligence.

Resumen

Las Inteligencias Artificiales (IAs) no comprenden profundamente los fenómenos que se les someten. El objetivo de este artículo es investigar la precisión de las nomenclaturas de hidrocarburos generadas por IAs (ChatGPT y Gemini) a través del reconocimiento visual de estructuras químicas, para evaluar las barreras epistemológicas emergentes en esta interacción. Para ello, se eligieron diez estructuras y se adoptó una perspectiva cualitativa junto con el análisis de contenido. Tras el análisis de las respuestas, se percibieron

¹Doutorando em Ensino pelo Programa de Pós-Graduação em Educação (PPGE) do Instituto de Educação (IE) da Universidade Federal de Mato Grosso (UFMT). Professor da área de Química no Instituto Federal de Mato Grosso (IFMT), Campus Pontes e Lacerda – Fronteira Oeste. E-mail: gabriel.mateus@ifmt.edu.br.

²Doutora em Educação pela Universidade de São Paulo (2003). Professora do Instituto de Química da Universidade Federal de Mato Grosso (UFMT), onde coordena o Laboratório de Pesquisa e Ensino de Química (LabPEQ). Docente permanente dos Programas de Pós-Graduação em Educação da UFMT e em Educação em Ciências e Matemática da REAMEC. E-mail: irene.mello@ufmt.br.

errores verbales y del realismo cualitativo debido a la generación de términos incompatibles con las estructuras en cuanto a la cantidad de carbonos, la presencia o ausencia de ramificaciones e insaturaciones. El uso ciego y acrítico de estas IAs como herramientas de resolución de ejercicios tiende a crear barreras epistemológicas graves en los estudiantes, promoviendo así dificultades en el aprendizaje de conceptos futuros en la química.

Palabras clave: Enseñanza de la química orgánica. Barreras epistemológicas. Inteligencia artificial.

1. Introdução

As inteligências artificiais generativas (IAs) têm sido tema de muitas discussões em âmbito educacional. Sobre elas, tem se investigado a veracidade, profundidade e confiabilidade do discurso quando conceitos ligados à química são analisados (Pereira *et al.*, 2025; Rodrigues, 2023; Olczewski *et al.*, 2025; Costa Junior, 2025). Esses trabalhos mostram que as IAs conseguem gerar explicações de maneira satisfatória, porém, ainda são geradas lacunas de informações, visto que as respostas geradas estão ausentes na interpretação dos aspectos microscópicos e estruturais da matéria.

As respostas que as IAs geram estão baseadas em padrões estatísticos e não na compreensão real do problema que nelas é inserido (Leite, 2023). Com isso, erros acabam sendo propagados e geram-se lacunas nas informações e, por sua vez, não ocorre contribuição na construção do conhecimento dos usuários. Isso só reforça a necessidade de o professor assumir um papel de formador de criticidade em seus alunos. Ele é fundamental na promoção de uma posição reflexiva quanto à interpretação dos conceitos que são gerados pelas IAs, principalmente reconhecendo erros, lacunas e profundidade nas respostas.

Além disso, as IAs têm possibilidade de formar barreiras epistemológicas quando os estudantes falham em revisar, compreender e interpretar os conceitos por elas gerados. Para Bachelard (1938), os obstáculos epistemológicos são hábitos de pensamento, preconceitos e formas de raciocínio cotidianas que impedem o surgimento do verdadeiro conhecimento científico. Essas barreiras, quando não são combatidas durante o processo de formação do estudante, causam dúvidas, erros na compreensão de conceitos e dificuldades nos processos formativos.

Por esse motivo, a proposta de estudo busca investigar a precisão das nomenclaturas de hidrocarbonetos geradas por IAs (*ChatGPT-4.5* e *Gemini 1.5 Flash*, ambas nas versões gratuitas) por meio do reconhecimento visual de estruturas químicas, de modo a avaliar as respostas geradas e quais as possíveis barreiras epistemológicas emergentes nessa interação. Assim, surge a questão norteadora: quais nomenclaturas são geradas pelo *ChatGPT-4.5* e *Gemini 1.5 Flash*, quando estruturas da função orgânica hidrocarbonetos são enviadas, por meio de fotos, para essas IAs e quais possíveis barreiras epistemológicas surgem nessa perspectiva? Alinhado a isso, essa pesquisa busca contribuir na elucidação de problemas enfrentados ao utilizar a inteligência artificial generativa sem uma base de conteúdo para analisar as informações que nela são geradas, mais específico, nomenclatura de hidrocarbonetos.

Com o intuito de examinar o cenário proposto, o percurso metodológico envolveu a seleção de dez cadeias carbônicas da referida função orgânica, classificadas como ramificadas, insaturadas, abertas, cíclicas e poli-insaturadas. Posteriormente, tais estruturas foram apresentadas aos modelos de inteligências artificiais generativas Gemini e ChatGPT via registros fotográficos de um material

impresso. O instrumento original havia sido aplicado a uma amostra de treze estudantes matriculados na disciplina de Química III, pertencentes ao terceiro ano do Curso Técnico em Controle Ambiental Integrado ao Ensino Médio do Instituto Federal de Mato Grosso, Campus Pontes e Lacerda – “Fronteira Oeste”.

2. Fundamentação teórica

As IAs se desenvolvem principalmente por duas abordagens: a discriminativa, voltada à classificação de dados, e a generativa, capaz de criar novas saídas a partir de padrões aprendidos. O tipo chamado de generativa, como ChatGPT e Gemini, tem ganhado destaque social justamente por incorporar comportamentos que simulam características humanas, como pausas na fala e reações contextualizadas; esse movimento torna as interações mais naturais e empáticas. Nesse contexto, o conceito de empatia artificial surge para descrever a capacidade dos sistemas de reconhecer e simular estados emocionais, para a criação de sensação de vínculo afetivo com o usuário, especialmente em robôs sociais voltados a áreas como saúde, educação e atendimento ao cliente (Rodrigues, 2025).

Ao analisar as respostas do ChatGPT para cinco conceitos químicos fundamentais, sendo eles o átomo, ligação química, equilíbrio químico, isomeria e ácido-base, Leite (2023) verificou que a ferramenta é capaz de produzir definições razoavelmente coerentes com a literatura especializada. Para verificar isso, utilizou como base de comparação o Compêndio de Terminologia Química da União Internacional de Química Pura e Aplicada (IUPAC). Contudo, as respostas apresentaram lacunas e imprecisões relevantes. Um desses casos está nas ligações químicas: o ChatGPT respondeu, na investigação, que as forças intermoleculares são um tipo de ligação, o que pode induzir erros conceituais nos estudantes. Já na definição de ácido-base, o sistema misturou sem distinção as teorias de Arrhenius e de Brønsted-Lowry (Leite, 2023).

Em concordância com Leite (2023), ao avaliar as respostas do ChatGPT sobre ácidos e bases no contexto do Novo Ensino Médio, verificou-se que a ferramenta tende a privilegiar a Teoria de Arrhenius em detrimento das demais abordagens teóricas, apresentando as definições de Brønsted-Lowry e Lewis de forma superficial ou, em alguns casos, omitindo-as completamente (Olczewski *et al.*, 2025). Além disso, foram identificadas confusões conceituais recorrentes, como a mistura entre os fundamentos das Teorias de Arrhenius e Brønsted-Lowry em uma mesma definição, o que pode consolidar obstáculos epistemológicos nos estudantes e comprometer a construção de um entendimento científico adequado (Olczewski *et al.*, 2025).

Diante dessas limitações, Olczewski (2025) defende que o ChatGPT não deve ser proibido no ambiente educacional, mas sim utilizado com a mediação ativa do professor. Essa ferramenta pode ser um ponto de partida interessante para familiarizar o estudante com determinado conteúdo, porém não substitui o processo reflexivo de construção do conhecimento. As IAs baseiam suas respostas em métodos estatísticos, e não em interpretações reais do problema posto a elas. Diante disso, podem ser gerados erros quando o conceito não está bem fundamentado no usuário, ainda mais quando ocorre simples reprodução desses erros, sem interpretação profunda e crítica do que foi gerado como resposta.

Outro trabalho investigativo é de Pereira *et al.* (2025). O estudo comparou as respostas das

versões gratuita (GPT-3.5) e *plus* (GPT-4) do ChatGPT sobre o conceito de solubilidade em meio aquoso. Para comparar as respostas da IA foi utilizado como referência dois livros de química amplamente adotados no Brasil. As perguntas foram submetidas cinco vezes cada, sem comandos orientadores, a fim de avaliar tanto a coerência quanto a consistência das respostas geradas.

Os resultados mostraram que ambas as versões descrevem corretamente os fenômenos em nível macroscópico, reconhecendo, por exemplo, que sais se dissolvem em água e que a gasolina não se mistura com ela. Contudo, nenhuma das versões avança de forma satisfatória para os níveis submicroscópico e simbólico, deixando de explicitar mecanismos moleculares detalhados, representações estruturais e fundamentos termodinâmicos como o conceito de espontaneidade da dissolução (Pereira *et al.*, 2025).

A versão *plus* demonstrou maior detalhamento conceitual ao incorporar termos como interações íon-dipolo e hidratação dos íons, aproximando-se mais da literatura científica de referência. Ainda assim, não eliminou limitações estruturais importantes, como a ausência de equações químicas e a tendência à simplificação explicativa. Os autores concluem que a ferramenta pode ser útil como ponto de partida para a aprendizagem ou para instigar discussões iniciais sobre conceitos sistematizados, mas que seu uso isolado é insuficiente para promover uma compreensão química genuína e estruturada. Nesse sentido, a atuação do docente é indispensável para que o estudante desenvolva pensamento crítico, questione as respostas geradas pela IA e as articule com materiais didáticos validados, evitando a cultura da resposta pronta e o chamado determinismo tecnológico (Pereira *et al.*, 2025).

Na mesma intenção de investigar, Costa Junior (2025) submeteu cinco enunciados conceituais ao *ChatGPT* sobre o tema Matéria e Energia, com o intuito de verificar se a IA era capaz de produzir respostas com linguagem acessível e razoavelmente coerentes com as definições encontradas na literatura especializada. A definição de matéria, por exemplo, trouxe, de maneira correta, a ideia de substância que possui massa e ocupa espaço, mas introduziu de forma inesperada o conceito de matéria escura, tema que não integra o Currículo da Educação Básica e pode gerar confusão nos estudantes. Já as definições de energia e de conservação energética foram consideradas mais bem elaboradas, com a descrição dos principais tipos de energia e menção ao primeiro princípio da termodinâmica, o que se aproxima do que é estabelecido pela literatura de referência (Costa Junior, 2025).

Por outro lado, algumas respostas revelaram lacunas e imprecisões conceituais relevantes. A definição das propriedades da matéria, por exemplo, misturou propriedades gerais com propriedades específicas sem fazer essa distinção, além de classificar o estado físico como uma propriedade, o que não é tecnicamente adequado. De modo geral, as definições geradas pelo ChatGPT foram parcialmente coerentes, mas exigiram revisão antes de qualquer uso em contexto escolar ou acadêmico; isso reforça que a ferramenta produz informações, não conhecimento, e que sua utilização demanda supervisão docente para evitar que os estudantes internalizem conceitos equivocados ou incompletos (Costa Junior, 2025).

Quando os estudantes concordam e aceitam as respostas geradas pelas IAs sem refletir sobre a veracidade e profundidade no que foi respondido aos *prompts*, lacunas na aprendizagem podem acabar sendo formadas. Essas são caracterizadas por Bachelard (1938) como barreiras epistemológicas,

definidas como concepções errôneas ou limitações cognitivas que dificultam ou impedem a construção e o avanço do conhecimento científico.

Essas barreiras podem ser classificadas em sete maneiras: 1) experiência primeira, ou senso comum: é a confiança cega na observação imediata e no que os nossos sentidos nos dizem à primeira vista; 2) conhecimento geral: consiste na tendência humana de generalizar precipitadamente; 3) obstáculo verbal: ocorre quando usamos palavras, metáforas ou analogias familiares para "explicar" um fenômeno, mas, na realidade, estamos apenas rotulando-o; 4) obstáculo substancialista: tendência de acreditar que os objetos possuem uma "substância" íntima, profunda ou mágica que explica suas propriedades; 5) animista: trata-se de projetar características biológicas, vontades, desejos ou intenções humanas em fenômenos físicos inanimados; 6) Conhecimento Utilitarismo: quando algo só é valorizado se tiver utilidade prática imediata, desconsiderando o valor do conhecimento teórico; 7) obstáculo do conhecimento anterior: são ideias já aprendidas e cristalizadas que impedem novas compreensões, bloqueando a construção do novo conhecimento (Bachelard, 1938).

O professor tem papel central em orientar os alunos a questionar, comparar e avaliar criticamente as respostas geradas pela IA, além de transformar a informação recebida em conhecimento. Os resultados evidenciaram que a integração intencional da IA generativa na formação de professores de Química fortalece a autoria docente, amplia o repertório de exemplos explicativos e favorece a mediação entre os diferentes níveis de representação química. Para tanto, o docente precisa atuar como curador crítico, definindo objetivos claros e conduzindo processos estruturados de avaliação formativa. Por outro lado, a pesquisa também apontou limitações importantes associadas ao uso dessa tecnologia, como o risco de dependência tecnológica, a geração de respostas superficiais, a presença de vieses nos modelos e questões de natureza ética, aspectos que demandam o desenvolvimento de políticas de uso responsável e de um letramento crítico em IA nos cursos de formação docente (Das Graças Cleophas, 2025).


3. Metodologia

A pesquisa constitui-se como qualitativa, pois valoriza o universo de significados, motivos e atitudes, focando em aspectos da realidade que não podem ser quantificados (Minayo; Deslandes, 2024). Essa abordagem é orientada pela natureza do objeto investigado, permitindo compreender como os sujeitos atribuem sentidos às suas experiências em contextos educacionais e socioculturais (Creswell, 2014).

O *locus* da pesquisa se caracteriza pelo IFMT Campus Pontes e Lacerda – “Fronteira Oeste”. Nele utilizou-se o espaço da aula da disciplina de Química III, da 3ª série do ensino médio, do curso técnico de controle ambiental integrado ao ensino médio. O conteúdo programático desta turma tem como tema central a química orgânica e o recorte adotado para a investigação foi analisar as mais diversas cadeias carbônicas da função orgânica hidrocarbonetos. Para realizar essa análise, escolheram-se duas IAs, ChatGPT e Gemini. A escolha delas não foi por acaso, visto serem as duas ferramentas mais utilizadas e disseminadas pelos alunos, fazendo-se necessária essa investigação para entender as limitações e erros gerados na geração de nomenclaturas. A Figura 1 mostra como as nomenclaturas foram geradas

para cada uma das dez estruturas.

Figura 1: Percurso metodológico utilizado para obter a nomenclatura das cadeias carbônicas



Fonte: Pereira (2026).

Foram escolhidas dez estruturas para realizar a investigação e cada uma delas foi destinada a um estudante. Os discentes participantes foram orientados a escrever a nomenclatura com o fito de utilizar os conhecimentos construídos em sala nos momentos formativos prévios à investigação. Após esse momento, foi solicitado que eles realizassem o segundo passo, o qual consistia em enviar uma foto para cada uma das IAs utilizando o *prompt*: Para a figura em anexo escreva sua nomenclatura seguindo as regras da IUPAC.

Para cada nomenclatura gerada, foi solicitado que os alunos abrissem um novo *chat* de conversa com cada IA, evitando interferências de conversas anteriores, e comparassem com a que eles já haviam escrito no passo anterior. Ademais, quando houvesse divergência nas respostas, foi instruído aos estudantes que eles usassem o *prompt*: melhore sua resposta, no máximo quatro vezes, a fim de que a IA chegasse na nomenclatura correta, assim como foi utilizado por Leite (2023). Esse modelo de resposta foi escolhido como forma de padronização para início das tentativas subsequentes, com o intuito de, após geradas as outras tentativas de nomenclaturas, identificar quais os possíveis erros pelas IAs generativas poderão ser cometidos.

As respostas das IAs para cada estrutura foram submetidas à análise de conteúdo (Bardin, 2016), que se constitui como uma metodologia de pesquisa voltada para descrever e interpretar o conteúdo de documentos e textos de forma sistemática, podendo ser qualitativa ou quantitativa. Ela vai além da leitura comum, pois permite reinterpretar mensagens e compreender seus significados em maior profundidade (Rocha; Deusdará, 2005).

Sua matéria-prima pode ser qualquer forma de comunicação verbal ou não-verbal, entrevistas, jornais, filmes, cartas, fotografias, entre outros. Um ponto central destacado é que um texto comporta múltiplos significados, o sentido pretendido pelo autor pode diferir do captado pelo leitor, e até o próprio autor pode não ter plena consciência do que sua mensagem expressa (Valle; Ferreira, 2025). Por isso, toda leitura é, em essência, uma interpretação.

O *corpus* da pesquisa foi constituído pelas interações textuais, respostas geradas, por duas IAs generativas: ChatGPT e Gemini. O material analisado englobou os retornos fornecidos por essas IAs a partir do envio, via celulares, de imagens correspondentes a 10 estruturas de cadeias carbônicas da função hidrocarboneto, tendo como comando a solicitação de suas respectivas nomenclaturas segundo os parâmetros da IUPAC.

Definiu-se como unidade de registro a nomenclatura química específica gerada pelas IAs para cada estrutura analisada, avaliada sob o critério de acerto ou erro. Por sua vez, a unidade de contexto, que serviu de base para a compreensão do dado, compreendeu o turno de interação completo referente a cada uma das 10 estruturas, abarcando desde o *prompt* inicial e a primeira resposta da IA até as interações subsequentes necessárias para que a ferramenta atingisse a resposta correta.

A codificação do material consistiu na extração e sistematização estrita das nomenclaturas geradas pelas IAs nos diálogos, cujo preenchimento do material entregue ficou sob responsabilidade dos discentes. Os dados foram codificados registrando-se o desempenho na primeira tentativa (acertos ou erros) e a evolução das nomenclaturas propostas nas tentativas subsequentes, até o momento em que a ferramenta obteve êxito, permitindo rastrear o padrão de resolatividade das IAs.

No quadro 1, estão descritas as categorias e critérios de análise para as informações geradas pelas IAs:

Quadro 1: Categorias e critérios de análise das informações geradas pelas IAs.

Categorias	Crítérios
Acertos na nomenclatura	Acertou na primeira tentativa
Erros seguidos de acerto e alucinação	Acertou em alguma tentativa ou alucinou

Fonte: Pereira (2026).

Além de classificar quais foram os erros gerados, mesmo após outras tentativas referente a mesma estrutura, os critérios permitem atribuir sentido às possíveis barreiras epistemológicas geradas. A construção das categorias ocorreu pelo método *a posteriori*. Conforme preconizado por Bardin, o sistema categorial não foi imposto previamente à análise, mas emergiu do próprio material após a leitura e codificação das respostas. O critério de agrupamento baseou-se na similaridade e convergência dos dados, reunindo os padrões de acertos, erros e as características das nomenclaturas geradas em eixos analíticos que refletem o comportamento das ferramentas testadas.

4. Resultados e discussão

Antes de se detalhar cada nomenclatura gerada, será exposta a resposta para o questionamento destinado a cada IA estudada: você tem capacidade de informar corretamente a nomenclatura de compostos orgânicos somente enviando uma foto? A motivação para isso vem de entender se as IAs estudadas têm em seu arcabouço ferramentas para gerar respostas para essa investigação, sendo as respostas:

ChatGPT: Sim, consigo ajudar com a nomenclatura de compostos orgânicos a partir de uma foto, desde que a imagem esteja legível. Funciona melhor quando: A estrutura está nítida e bem iluminada; as ligações e átomos estão claramente desenhados; não há partes cortadas ou borradas; com isso, posso: 1) Identificar a estrutura; 2) aplicar as regras da Química Orgânica; 3) fornecer o nome segundo a IUPAC; 4) explicar o




raciocínio, se você quiser (útil para ensino). Mas vale um alerta honesto: se a imagem estiver confusa ou ambígua (por exemplo, estereoquímica mal definida), posso pedir confirmação ou dar mais de uma possibilidade. Se quiser, pode enviar a imagem que eu analiso.







Gemini: Sim, eu tenho essa capacidade! Como um modelo de inteligência artificial multimodal, eu consigo analisar e interpretar imagens. Você pode me enviar uma foto com a estrutura química do composto orgânico (seja a fórmula em bastão/linhas, estrutural plana ou condensada), e eu farei a análise visual para fornecer a nomenclatura IUPAC correta. Para garantir a maior precisão possível na minha resposta, aqui estão algumas dicas úteis na hora de enviar a sua foto: Clareza e Iluminação: Certifique-se de que a foto esteja nítida, focada e sem sombras que atrapalhem a visualização das ligações. Legibilidade do Desenho: Estruturas impressas (de livros ou provas) ou desenhadas digitalmente são excelentes. Se for um desenho feito à mão no caderno, tente fazê-lo da forma mais limpa possível, destacando bem os átomos diferentes de carbono e hidrogênio (heteroátomos) e o número de ligações (duplas ou triplas). Estereoquímica: Se o composto exigir a identificação de isômeros (como geometria cis/trans, E/Z ou centros quirais R/S), certifique-se de que os indicadores (como as cunhas cheias e tracejadas) estejam bem visíveis no desenho. Pode enviar a foto do composto assim que quiser e eu te ajudarei com a nomenclatura! (Gemini, 2026)

Por meio das respostas das duas IAs é percebido que elas se colocam na posição de conseguir responder corretamente a nomenclatura de compostos orgânicos quando é enviada uma imagem da estrutura. Todavia, elas deixam claro que existem fatores que podem gerar erros e dúvidas na análise, tais como: iluminação ambiente, desenhos mal elaborados e rabiscos em cima da impressão. Assim, os alunos foram orientados a evitar rasuras perto das cadeias, a fim de que as respostas não sofressem essas influências externas.

O quadro 2 mostra as dez estruturas que foram analisadas neste estudo. Percebe-se que, de forma intencional, foram escolhidos compostos com estruturas diversas, desde cadeias mais simples, classificadas como normais e saturadas, até as cadeias mais complexas, apresentando poli-insaturações e mais de uma ramificação e sequência possíveis para escolha da cadeia principal:

Quadro 2: Hidrocarbonetos utilizados para realizar a investigação

1		2	
3		4	

5		6	
7		8	
9		10	

Fonte: Pereira (2026).

Um dos passos principais para escrever corretamente a nomenclatura de compostos orgânicos é encontrar a cadeia principal de carbonos, entendida como a que possui a maior sequência de carbonos, presença de insaturações e maior quantidade de ramificações. Além disso, enumerar a cadeia principal se faz um passo importante, visto que é necessário localizar as ramificações e o carbono inicial das insaturações quando a nomenclatura é escrita. Em sala de aula, foi comentado aos estudantes que esse movimento se assemelha à escrita de um endereço residencial. Nele, é importante localizar o bairro, rua, número da casa, CEP, complemento e, até mesmo, pontos de referência.

O primeiro momento foi destinado para os alunos escreverem as nomenclaturas de cada uma das estruturas. Nesse, os alunos ficaram à vontade para tirar dúvidas a respeito das respostas elaboradas por eles. Isso se faz relevante para que, no momento de investigar as nomenclaturas das IAs, eles pudessem comparar corretamente com as próprias respostas. Além de simplesmente fixar o conteúdo, esse passo serviu para o professor verificar em quais situações os estudantes estavam tendo dificuldade no processo de aprendizagem do conteúdo. Tanto para os discentes quanto para o professor, o primeiro passo se faz elucidador.






No próximo passo, foi solicitado aos estudantes que enviassem uma foto de sua respectiva cadeia para cada IA estudada, a fim de extrair a imagem do próprio material fornecido a eles, pedindo que ela gerasse, por meio dos anexos, a nomenclatura. Para isso, foi escolhido um *prompt* específico, com intuito de padronizar a informação de entrada para a IA. Entende-se que cada uma das IAs

estudadas possui uma forma específica de geração de dados, consulta e utilização de suas bibliotecas de dados, visto que entende e utiliza parâmetros diferentes. Escolheu-se utilizar um *prompt* padrão para que ficasse evidente, e sem distinções, o que foi solicitado como tarefa.

4.1 Acertos na nomenclatura

As respostas corretas geradas para cada estrutura estão presentes no quadro 3:

Quadro 3: Nomenclaturas geradas pelas IAs

	Estrutura	Nomenclatura Gemini:	Nomenclatura ChatGPT:
1		1) pentano	1) pentano
2		1) 3-metil pentano	1) 3-metil pentano
3		1) 3-etil pent-1-eno	1) 3-etil pent-1-eno
5		1) ciclohexano	1) ciclohexano
6		1) 1-metil ciclopenteno	1) 1-metil ciclopenteno






Fonte: Pereira (2026).

Para as estruturas mais simples, ou seja, as que não possuem cadeias principais com grandes quantidades de carbono e sem muitas ramificações, cadeias um, dois, três, cinco e seis, ambas as IAs conseguem gerar respostas corretas na primeira tentativa, acertando as nomenclaturas sem errar a quantidade de carbonos ou mesmo a posição de insaturações. Na cadeia três, de maneira intencional, foi adicionada a dupla ligação nos carbonos da parte inferior da cadeia. Isso foi pensado com o intuito de verificar se as IAs conseguem identificar a cadeia principal quando o composto possui mais de uma alternativa. Nela, o parâmetro de desempate utilizado por ambas as IAs foi assertivo, sendo ele a presença da dupla ligação quando se comparam duas sequências com a mesma quantidade de carbonos (cinco carbonos).

4.2 Erros seguidos de acerto e alucinação

As respostas incorretas geradas na primeira tentativa para cada estrutura estão presentes no Quadro 4:

Quadro 4: Nomenclaturas geradas pelas IAs

	Estrutura	Nomenclatura Gemini:	Nomenclatura ChatGPT:
4		1) 3-metil hexa-1,3-dieno Repetiu por 4 vezes até alucinar.	1) 3-metil 1,4-hexadieno 2) 3-metil hex-1,4-dieno
7		1) sec-butil ciclohexano 2) 1-secbutil ciclohexano	1) 1-(butan-2-il) ciclohexano 2) butan-2-il ciclohexano Repetiu por 3 vezes.
8		1) 2-metil hex-1-en-4-ino	1) 3-metil hex-2-en-4-ino 2) 2-metil hex-1-en-4-ino
9		1) 4Z 6-metil hept-1,4-dieno 2 e 3) repetição da anterior 4) 4E 6-metil hept-1,4-dieno 5) repetiu a nomenclatura anterior.	1) 3-(butan-2-il) hepta-1,5-dieno Repetiu por 4 vezes até alucinar.
10		1) 3,4-dimetil hept-2-eno	1) 4,5-dimetil oct-2-eno 2) 4-etil-3-metil hept-2-eno 3) 3,4-dimetil hex-2-eno 4 e 5) 3,4-dimetil hept-3-eno

Fonte: Pereira (2026).

Na cadeia quatro, ocorreu algo de interessante: ambas as IAs escreveram em suas primeiras tentativas, respostas incorretas, porém, erraram em categorias diferentes. O Gemini apesar de encontrar corretamente a sequência principal de carbonos e posição da ramificação, posicionou incorretamente a posição das duplas ligações, caracterizado como um erro posicional. Na resposta dela, as insaturações começariam nos carbonos um e três, porém, a enumeração correta seria nos carbonos um e quatro. Percebeu-se também que ela repetiu essa resposta por todas as tentativas, não conseguindo encontrar a nomenclatura correta.

Já para o ChatGPT, na primeira tentativa, que está incorreta, são informadas corretamente a quantidade de carbonos da cadeia principal e a enumeração das duplas ligações e da ramificação, mas a organização da nomenclatura final utiliza a forma antiga aceita pela IUPAC. Essa forma coloca antes do prefixo a posição em que as duplas ligações se encontram, visto que, atualmente, a forma mais aceita e atualizada considera a enumeração das duplas entre o prefixo e o afixo da cadeia principal. Esse aspecto foi considerado na segunda alternativa, que apresenta corretamente a nomenclatura da estrutura.

A sétima estrutura também possui pontos a serem analisados pelas duas IAs. O primeiro se dá a respeito da forma como o Gemini coloca a primeira tentativa de resposta. Ela não indica o carbono ao qual a ramificação *sec* está ligada, o que conceitualmente não está incorreto, mas pode causar dúvidas nos alunos quando observam essa nomenclatura, o que se classifica como um erro de organização dos termos. De forma geral, quando a ramificação ou insaturação está no carbono 1 da estrutura, é opcional colocar a enumeração, ou seja, subentende-se que, quando não é colocado, a ramificação ou dupla está no carbono 1 da estrutura. Entretanto, quando é solicitado para a IA melhorar sua resposta, ela considera adicionar o numeral para evidenciar a posição em que essa ramificação se encontra.

A mesma estrutura, quando analisada pelo ChatGPT, não conseguiu chegar à resposta esperada,

errando não somente a primeira tentativa, como repetindo a mesma resposta para as outras quatro. As tentativas um e dois podem ser consideradas a mesma, mudando somente a forma como a grafia está sendo representada pela IA. Outro ponto que chama atenção é a própria repetição da resposta incorreta. Pode ser observado que, quando ela não consegue verificar o erro e, ao consultar seu banco de dados, não é possível identificar o que o usuário está solicitando, ela tende a repetir a resposta anterior, fenômeno esse chamado de alucinação. Isso vem do fato de que sempre é preciso gerar uma resposta para cada *prompt*, não necessariamente uma resposta “melhorada” como se está pedindo, fazendo, assim, com que erros possam permanecer, não chegando ao que se espera.

Quando se solicita que seja gerada a nomenclatura para as estruturas oito e dez, o Gemini consegue, na primeira tentativa, chegar à resposta correta; porém, isso não é verificado para o ChatGPT. Para a cadeia oito, é observado um erro de enumeração da cadeia principal, o que é resolvido quando a segunda resposta é gerada, tanto para a ramificação quanto para a ligação dupla e tripla.

A cadeia dez é um dos casos mais críticos observados nessa investigação. Nela, a IA erra por completo, tanto na enumeração quanto na identificação da cadeia principal, o que caberia encaixar em mais de uma categoria de análise. Isso pode ser observado pela primeira tentativa, na qual é informado que a cadeia principal possui uma menor quantidade de carbonos do que o observado pelos alunos. A cadeia principal dessa estrutura possui sete carbonos; sendo assim, esperava-se que a nomenclatura gerada tivesse o prefixo *hept*, porém, na primeira e terceira tentativas, isso não foi observado. Foram utilizados os prefixos *oct*, indicando oito carbonos, e *hex*, indicando seis. As duas últimas nomenclaturas geradas foram iguais, mas tanto elas quanto a segunda tentativa encontram corretamente a quantidade de carbonos da cadeia principal e erram na numeração das ramificações. Essas falhas podem ser consideradas graves, visto que, dependendo da forma como a enumeração das ramificações é feita, elas podem alterar consideravelmente a cadeia principal, nela adicionando, possivelmente, um carbono a mais, o que resulta em uma nomenclatura completamente diferente do que é expresso nas imagens.


A estrutura de número nove é a mais crítica de todas, tanto em nível de dificuldade quanto em relação ao número de tentativas de cada IA e ao fato de as respostas possuírem erros diferentes. Para o Gemini, em nenhuma das respostas se verificou que a IA encontrou corretamente a quantidade de carbonos da cadeia principal. Ademais, ela coloca na nomenclatura parâmetros de isomeria espacial geométrica do tipo E e Z, alternando entre os tipos nas respostas. Porém, é possível verificar que as enumerações para as duplas ligações, carbonos um e quatro, e a ramificação, carbono seis, foram escritas corretamente.

Já o ChatGPT coloca de forma incorreta a quantidade de carbonos da cadeia principal, indicada pela nomenclatura *hept*, sendo que o esperado era o prefixo *oct*. Além disso, é informada de maneira incorreta a posição das duplas ligações, colocadas pela IA nos carbonos um e cinco, sendo que o correto são os carbonos um e quatro. Outrossim, o ponto mais crítico dessa nomenclatura está na repetição, sem alteração, da resposta gerada nas segunda e quinta tentativas.

Ao observar somente a quantidade de acertos de cada IA, poderia se aferir, de forma equivocada, que o Gemini seria mais indicado para geração de nomenclatura de compostos orgânicos por meio de envio de fotos. Ela possui um software específico para geração e edição de imagens, assim como

vídeos, conhecido como Nano Banana 2. Por conta disso, ele pode ser utilizado para identificação de possibilidades de cadeias principais, como observado na Figura 2:

Figura 2: Representação em verde da cadeia principal e em alaranjado da ramificação presente na cadeia 4



Fonte: Pereira (2026).

Ao verificar a imagem, é possível perceber alguns detalhes importantes. O primeiro refere-se ao indicado em verde, ou seja, à cadeia principal, e a cor alaranjada corresponde à ramificação da estrutura. Em contrapartida, as duplas ligações ficam mais apagadas em relação ao resto da cadeia principal e podem cair no erro visual de não serem consideradas no momento de escrita das nomenclaturas finais. Esse fato pode ser uma das explicações do porquê de serem geradas nessa IA tantas alternativas de nomenclaturas para os compostos enviados para ela.

Quando se observam as respostas, é possível perceber que as IAs podem cometer erros básicos de nomenclatura. Esses erros vão desde a enumeração de ramificações e cadeias principais até erros mais graves na atribuição do prefixo para uma cadeia. As duas conseguem, de maneira razoavelmente satisfatória, conceber o nome de estruturas mais simples, como as estruturas um, dois, três, cinco e seis, porém começam a alucinar conforme as cadeias ficam mais complexas.

Como as IAs baseiam seu funcionamento em modelos probabilísticos de linguagem, elas não interpretam os conceitos químicos propriamente ditos; elas preveem qual palavra deve ser gerada com base em vastos volumes de texto humano presentes nos bancos de dados. Isso significa que o "conhecimento" é inerentemente cumulativo e linguístico. Se Bachelard (1938) estivesse analisando os erros ou a falta de profundidade de uma IA ao resolver um problema de química avançada, ele diagnosticaria que a IA é frequentemente vítima, e perpetuadora, de várias informações que podem ocorrer na formação de barreiras epistemológicas.

Neste estudo, o obstáculo verbal é o mais perceptível na natureza das duas IAs estudadas.

Bachelard (1938) alertava contra o perigo de usar uma palavra, ou termo no caso do presente estudo, incorreto. Quando confrontada com um problema químico complexo, aqui relacionado com a nomenclatura orgânica, a IA poderia encadear respostas incorretas de forma gramaticalmente impecável. Ao utilizar os termos relacionados à nomenclatura, prefixo, afixo e sufixo, é gerado um falso sentimento de coerência nas respostas. No entanto, ela pode usar esses termos como "esponjas", principalmente por lacunas na compreensão real das características estruturais específicas de cada estrutura.

Outro erro que também pode ser atribuído às respostas das IAs é conhecido como o realismo quantitativo. Nas nomenclaturas das estruturas estão presentes vários números, com intenção de identificar a posição de início de uma insaturação, ramificação ou mesmo de grupo funcional, quando estão presentes nas outras funções orgânicas. Isso explica de maneira coerente as alucinações da IA em química, visto que o posicionamento incorreto dos números no momento de escrita das nomenclaturas atribui um significado diferente em relação ao posicionamento de determinada característica presente nas cadeias principais.

5. Considerações finais

As IAs estudadas nesse trabalho tendem a responder de forma satisfatória à nomenclatura de compostos quando são enviadas fotos para elas. Todavia, quanto mais complexas as cadeias ficam, a chance de acerto tende a reduzir, devido à presença de mais de uma ramificação, insaturação e, até mesmo, sequências de carbonos que irão constituir as cadeias principais dos compostos analisados.

Além disso, a utilização cega e sem cuidado com a avaliação das informações geradas por essas IAs, como ferramentas de resolução de exercícios, tende, se não observado com critério, a perpetuar nos alunos barreiras epistemológicas graves, o que gera, assim, possíveis dificuldades de aprendizagem de conceitos futuros na química orgânica. É sabido que os hidrocarbonetos são considerados compostos simples em relação a não estarem presentes grupos funcionais neles, já que são constituídos somente de carbonos e hidrogênios. Desse modo, ao passo que a química orgânica aumenta sua complexidade em relação aos detalhes envolvidos em identificação e atribuição de funções oxigenadas e nitrogenadas, essas ferramentas podem dificultar ainda mais o aprendizado dos estudantes.

Não obstante, ao utilizá-las como apoio para os estudos, podem ser consideradas eficientes quando os estudantes já têm um conhecimento formado e consolidado. Por conta disso, a identificação de erros fica mais clara e o aprendizado passa a ser personalizado, fazendo com que esses erros atribuídos pelas IAs sejam identificados e minimizados. Movimento este que tende a contribuir para o aprendizado, tendo em vista que reforça ainda mais a necessidade de possuir as regras de identificação e enumeração das cadeias carbônicas para escrever corretamente as nomenclaturas.

Portanto, quanto mais são explorados os limites conceituais das IAs, mais fica evidente a necessidade de formar alunos críticos e que tenham o conhecimento químico basilar para a utilização desse mecanismo de estudo. Para isso, se faz cada vez mais importante a posição do professor em significar e ressignificar o conhecimento. Não há a necessidade de proibir tais ferramentas, visto que o movimento mais eficiente está em conscientizar os estudantes a não acreditarem de forma cega e acrítica nas respostas geradas. Assim, torna-se fundamental ensiná-los a interpretar e identificar erros,

para que possam, assim, personalizar seus estudos e atender a suas necessidades individuais.

6. Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Referências

- BACHELARD, Gaston. A formação do espírito científico. Rio de Janeiro: Contraponto. 1938.
- BARDIN, Laurence. **Análise de Conteúdo**. São Paulo: Edições 70, 2016.
- COSTA JUNIOR, Ismael Laurindo. Análise do ChatGPT como ferramenta no ensino de química: explorando o tema matéria e energia. **ACTIO: Docência em Ciências**, v. 10, n. 2, p. 1-23, 2025. Disponível em: <https://periodicos.utfpr.edu.br/actio/article/view/19066>. Acesso em: 24 abr. 2026.
- CRESWELL, John W. Investigação Qualitativa e Projeto de Pesquisa: escolhendo entre cinco abordagens. Penso Editora, 2014.
- DAS GRAÇAS CLEOPHAS, Maria. IA com intencionalidade pedagógica: percepções, limites e possibilidades na formação de professores de Química. **Educação Química em Ponto de Vista**, v. 9, p. 446-475, 2025.
- FERNANDES, Allysson Barbosa et al. A ética no uso de inteligência artificial na educação: implicações para professores e estudantes. **Revista Ibero-Americana de Humanidades, Ciências e Educação**, v. 10, n. 3, p. 346-361, 2024. Disponível em: <https://periodicorease.pro.br/rease/article/view/13056>. Acesso em: 24 abr. 2026.
- DE SOUZA MINAYO, Maria Cecília; DESLANDES, Suely Ferreira; GOMES, Romeu. Pesquisa social: teoria, método e criatividade. Editora Vozes Limitada, 2024.
- OLCZEWSKI, Elisson; MARCONDES, Renato; SENS, Larissa. ChatGPT no ensino de química: análise das explicações sobre ácidos e bases para o Novo Ensino Médio e Ensino Superior. **Ensaio Pesquisa em Educação em Ciências (Belo Horizonte)**, v. 27, p. e56809, 2025. Disponível em: <https://www.scielo.br/j/epec/a/SwtRJg5CsKsnf55XGd58Fdh/?lang=pt>. Acesso em: 24 abr. 2026.
- PEREIRA, Gabriel Mateus Arantes; FIGUEIREDO, Emerson de Oliveira; SOUZA, Gahelyka Aghta Pantano; MIRANDA, Mayker Lazaro Dantas. Avaliação comparativa das respostas do ChatGPT sobre solubilidade: uma análise educacional e conceitual. **Revista Ponto de Vista**, [S. l.], v. 14, n. 2, p. 01-16, 2025. <https://doi.org/10.47328/rpv.v14i2.22853>
- ROCHA, Décio; DEUSDARÁ, Bruno. Análise de Conteúdo e Análise do Discurso: aproximações e afastamentos na (re) construção de uma trajetória. **Alea: estudos neolatinos**, v. 7, n. 2, p. 305-322, 2005. Disponível em: <http://www.scielo.br/j/alea/a/PQWYmTntpVgYYZdrbdnQbBf/?lang=pt>. Acesso em: 24 abr. 2026.
- RODRIGUES, José Carlos. A Antropomorfização, o antropomorfismo e a empatia artificial como moduladores da aceitação e riscos na interação humano-máquina. **Leitura Flutuante**, v. 17, n. 1, 2025. Disponível em: <https://revistas.pucsp.br/leituraflutuante/article/view/70517>. Acesso em 24 abr. 2026.
- RODRIGUES, Olira Saraiva; RODRIGUES, Karoline Santos. A inteligência artificial na educação: os desafios do ChatGPT. **Texto livre**, v. 16, p. e45997, 2023. Disponível em: <https://www.scielo.br/j/tl/a/rxWn7YQbndZMYs9fpkxbVXv/?format=html&lang=pt>. Acesso em: 24 abr. 2026.
- VALLE, Paulo Roberto Dalla; FERREIRA, Jacques de Lima. Análise de conteúdo na perspectiva de Bardin: contribuições e limitações para a pesquisa qualitativa em educação. **Educação em Revista**, v. 41, p. e49377, 2025. Disponível em: <https://www.scielo.br/j/edur/a/hhywJFv7ysP5rGPn3QRFWf/?format=html&lang=pt>. Acesso em: 24 abr. 2026.

Informações do artigo

Recebido: 12 de fevereiro de 2026.

Aceito: 29 de julho de 2026.

Publicado: 23 de agosto de 2026.

Como citar esse artigo (ABNT)

PEREIRA, Gabriel Mateus Arantes; MELLO, Irene Cristina de. Inteligência artificial: análise dos obstáculos epistemológicos emergentes na leitura visual de hidrocarbonetos. **Revista Prática Docente**, Confresa/MT, v. 11, e26009, 2026.
<https://doi.org/10.23926/RPD.2026.v11.e26009.id1415>

Como citar esse artigo (APA)

Pereira, G. M. A. & Mello, I. C. D. (2026). Inteligência artificial: análise dos obstáculos epistemológicos emergentes na leitura visual de hidrocarbonetos. **Revista Prática Docente**, 11, e26009.
<https://doi.org/10.23926/RPD.2026.v11.e26009.id1415>

Editor da Seção

Dr^a. Ana Cláudia Tasinaffo Alves

Editor Chefe

Dr. Thiago Beirigo Lopes