

PENSAMENTO COMPUTACIONAL NA BNCC COMPUTAÇÃO EM TEMPOS DE INTELIGÊNCIA ARTIFICIAL GENERATIVA: AVALIAR, DEPURAR E RECONSTRUIR SOLUÇÕES NA EDUCAÇÃO BÁSICA

Willian Grecillo dos Santos¹

¹Professor da Educação Básica e pesquisador, Florianópolis, Brasil

Resumo: Este artigo analisa como a inteligência artificial generativa amplia e tensiona as finalidades formativas do pensamento computacional previstas na BNCC Computação. Com base em estudo teórico, bibliográfico e documental, sustenta que a produção automatizada de respostas, códigos e explicações desloca o ensino da simples construção de algoritmos para a avaliação, a depuração e a reconstrução crítica de soluções, com mediação docente e atenção às desigualdades da Educação Básica.

Palavras-chave: Pensamento computacional; Inteligência artificial generativa; BNCC Computação; Educação Básica; Depuração

INTRODUÇÃO

A difusão recente da inteligência artificial generativa introduziu uma alteração qualitativa na relação entre educação e tecnologias digitais. Sistemas acessíveis por interfaces conversacionais passaram a produzir textos, imagens, códigos, explicações e propostas de atividades em poucos segundos, deslocando uma parte da ação escolar para artefatos cuja aparência de completude antecede a compreensão dos processos que os originaram. A questão educacional deixa, assim, de se concentrar exclusivamente no acesso a informações ou na execução de comandos. Ela alcança a capacidade de julgar o que foi produzido, localizar fragilidades, explicitar critérios e reelaborar soluções com autoria e fundamento.

A inteligência artificial generativa diferencia-se de muitas aplicações educacionais anteriores porque produz novas combinações simbólicas a partir de regularidades estatísticas aprendidas em grandes conjuntos de dados, em lugar de apenas classificar dados, recomendar percursos ou executar regras previamente delimitadas. A resposta é construída probabilisticamente, ainda que se apresente ao usuário na forma de uma explicação unitária, segura e linguisticamente bem acabada. Essa diferença técnica possui consequência epistemológica: coerência discursiva e conhecimento validado não são propriedades equivalentes. Na escola, a facilidade de geração precisa ser acompanhada pela aprendizagem dos critérios que permitem distinguir plausibilidade, correção e valor formativo (Giannakos *et al.*, 2025; Lima; Serrano, 2024).

A mudança também altera a unidade de análise do trabalho pedagógico. Em sistemas convencionais, o professor pode examinar uma sequência relativamente

estável de telas, regras e respostas. Em modelos generativos, o produto varia segundo a formulação do pedido, o contexto fornecido, a versão do sistema e a própria natureza probabilística da geração. O mesmo comando pode produzir resultados distintos, e pequenas alterações linguísticas podem modificar significativamente a saída. O artefato educacional deixa de ser apenas o texto final e passa a incluir a cadeia formada por problema, prompt, resposta, critérios de análise e sucessivas intervenções humanas. É nessa cadeia que se localiza a aprendizagem que este artigo procura teorizar.

Esse deslocamento ocorre em um campo internacional já consolidado. A revisão de Wang *et al.* (2024), construída a partir de análise bibliométrica de 2.223 estudos e análise de conteúdo de 125 trabalhos, identifica aplicações de inteligência artificial voltadas à aprendizagem adaptativa e à tutoria personalizada, à avaliação e à gestão, à elaboração de perfis e previsões e a produtos emergentes. O panorama também revela uma concentração de pesquisas no Ensino Superior, enquanto a Educação Básica recebe atenção proporcionalmente menor. A inteligência artificial generativa aparece, nesse quadro, como uma frente que requer investigações orientadas por teorias educacionais, critérios éticos e maior participação humana na concepção e no uso dos sistemas.

A estrutura identificada por Wang *et al.* (2024) mostra que a inteligência artificial na educação não constitui uma tecnologia única, mas um campo heterogêneo de sistemas, finalidades e contextos. Aprendizagem adaptativa, tutoria, avaliação inteligente, gestão, predição e produtos emergentes respondem a problemas educacionais distintos e requerem critérios igualmente distintos de efetividade. Essa

heterogeneidade impede que resultados obtidos com uma aplicação sejam transferidos automaticamente para outra. Também exige separar desempenho técnico, aceitação do usuário e aprendizagem, pois um sistema pode gerar respostas rápidas ou ser bem avaliado sem produzir compreensão conceitual, autonomia ou capacidade de transferência para novas situações.

A revisão internacional revela ainda um problema de fundamentação. Embora diferentes teorias de aprendizagem apareçam no campo, Wang *et al.* (2024) apontam a necessidade de elevar a contribuição teórica e orientar os desenhos de pesquisa por referenciais capazes de explicar como e por que determinada aplicação produz efeitos. Essa exigência torna-se mais importante diante da inteligência artificial generativa, cuja novidade pode favorecer estudos centrados no recurso e não no processo formativo. Situar a IA em uma teoria da aprendizagem significa perguntar quais ações intelectuais permanecem com o estudante, quais são automatizadas, que mediações se tornam necessárias e que evidências autorizam afirmar que houve aprendizagem.

A especificidade da inteligência artificial generativa amplia essa agenda. Giannakos *et al.* (2025) reconhecem possibilidades relacionadas ao planejamento educacional, à regulação da aprendizagem, à produção de conteúdos, ao feedback e à avaliação, ao mesmo tempo que destacam problemas de confiabilidade, transparência, privacidade, viés e adequação pedagógica. A diferença entre usuários experientes e iniciantes é decisiva: profissionais podem dispor de conhecimentos para examinar sugestões de código ou explicações, enquanto estudantes tendem a encontrar maior dificuldade para reconhecer respostas simultaneamente plausíveis e incorretas. Por isso, a formação para interpretar, verificar e corroborar resultados automatizados integra o próprio problema pedagógico.

Giannakos *et al.* (2025) interpretam a difusão dos grandes modelos de linguagem como um processo simultâneo de requalificação, ampliação de competências e possível enfraquecimento de práticas anteriormente necessárias. A comparação histórica com outras tecnologias educacionais indica que a automação não elimina simplesmente habilidades, mas redistribui sua importância. Formular solicitações, selecionar dados confiáveis, acompanhar respostas, testar soluções e reconhecer usos inadequados ganham centralidade. Essa redistribuição não deve ser tratada como adaptação inevitável ao mercado tecnológico. Cabe à educação decidir quais conhecimentos não podem ser delegados porque sustentam a capacidade de compreender, avaliar e contestar a própria automação.

A autorregulação da aprendizagem oferece outra chave para esse problema. Conforme a discussão reunida por Giannakos *et al.* (2025), aprender envolve ciclos de planejamento, execução, monitoramento e reflexão, individualmente e em colaboração. A IA pode fornecer feedback, exemplos e apoio adaptativo, mas também pode ocupar prematuramente etapas que deveriam ser realizadas pelo estudante. Quando a definição do problema, a escolha da estratégia e o julgamento do resultado são terceirizados ao sistema, a rapidez da resposta encobre uma redução da agência metacognitiva. O valor educacional da ferramenta depende, portanto, de sua inserção em tarefas que preservem planejamento, monitoramento e reflexão como responsabilidades do aprendiz.

No campo do pensamento computacional, Hsu (2025) propõe compreender a interação com grandes modelos de linguagem como uma forma de programação em linguagem natural. A elaboração e o refinamento de prompts mobilizariam abstração, pensamento algorítmico, decomposição, depuração, generalização e iteração. A formulação é relevante porque reconhece que a atividade computacional pode ocorrer em interfaces distintas das linguagens de programação tradicionais e que os prompts podem funcionar como objetos sobre os quais os estudantes pensam, discutem e realizam sucessivos aperfeiçoamentos.

A passagem da programação ao prompting, contudo, precisa ser interpretada como ampliação das formas de expressão computacional, em vez de uma sucessão na qual uma prática torna a outra dispensável. Um prompt bem estruturado pode produzir uma resposta inadequada, enquanto um texto linguisticamente convincente pode ocultar erros de conteúdo, premissas frágeis e critérios ausentes. O domínio de fórmulas de comando oferece pouco amparo quando o estudante carece de conhecimento para decidir se o resultado responde ao problema, se os procedimentos são válidos e se a solução merece ser mantida. O centro formativo situa-se, portanto, na relação entre formular, produzir, examinar e transformar.

A aproximação entre prompting e pensamento computacional adquire maior consistência quando interpretada pelo construcionismo mobilizado por Hsu (2025). Nessa perspectiva, aprende-se ao construir artefatos significativos, passíveis de observação, compartilhamento, teste e revisão. Prompts e respostas podem funcionar como objetos sobre os quais se pensa, desde que o estudante não seja reduzido a operador de comandos eficientes. O objeto relevante não é a frase que obtém a melhor resposta, mas o conjunto de decisões que relaciona conhecimentos prévios, propósito, representação do problema, análise da saída e reconstrução. A dimensão construcionista desloca o foco da eficiência comunicativa para a construção de conhecimento e para a agência do aprendiz.

Esse deslocamento permite diferenciar alfabetização operacional e formação computacional. A primeira pode restringir-se ao conhecimento de interfaces e fórmulas de prompt. A segunda requer compreender problemas, abstrair aspectos relevantes, decompor tarefas, formular procedimentos, testar resultados e generalizar aprendizagens. Um estudante pode produzir um comando detalhado sem reconhecer a inadequação conceitual da resposta, assim como pode seguir uma sequência sugerida sem compreender por que ela funciona. A competência de interagir com IA só se converte em pensamento computacional quando o diálogo com o sistema mobiliza operações de resolução de problemas que permanecem intelectualmente apropriadas pelo sujeito (Hsu, 2025).

Diante desse cenário, o problema que orienta este artigo é: em que medida a inteligência artificial generativa tensiona, amplia ou reconfigura as finalidades formativas do pensamento computacional previstas na BNCC Computação, especialmente no que se refere à capacidade de avaliar, depurar e reconstruir soluções automatizadas na Educação Básica? A pergunta articula dois movimentos históricos próximos. O primeiro decorre da institucionalização da Computação como direito de aprendizagem na estrutura curricular brasileira. O segundo nasce da popularização de sistemas que geram produtos computacionais e simbólicos sem tornar transparentes todos os procedimentos envolvidos.

O objetivo geral consiste em analisar teoricamente como a inteligência artificial generativa tensiona, amplia e reconfigura as finalidades formativas do pensamento computacional previstas na BNCC Computação, com ênfase na avaliação, na depuração e na reconstrução crítica de soluções automatizadas.

ASPECTOS METODOLÓGICOS

Metodologicamente, o texto configura-se como estudo teórico, bibliográfico e documental, de abordagem qualitativa e caráter interpretativo. O corpus reúne o documento Computação: complemento à BNCC e doze estudos selecionados intencionalmente por sua relação com inteligência artificial na educação, pensamento computacional e implementação curricular. A análise toma o documento como eixo normativo e examina suas competências, habilidades e finalidades formativas diante das transformações produzidas pela inteligência artificial generativa. O percurso analítico concentra-se na extrapolação das formulações relacionadas à resolução de problemas, à comparação de estratégias, à avaliação de soluções, à identificação de erros e à revisão de processos. A partir desse movimento, busca-se explicitar as potencialidades da BNCC Computação para sustentar uma formação voltada à capacidade de avaliar, depurar e reconstruir criticamente soluções produzidas por sistemas automatizados.

A extrapolação documental não consiste em atribuir à BNCC Computação enunciados sobre uma tecnologia que ainda não ocupava o atual espaço social quando o documento foi elaborado. Seu propósito é identificar estruturas formativas capazes de orientar a interpretação de situações novas. A análise aproxima as competências e habilidades curriculares de problemas recorrentes associados à inteligência artificial generativa, especialmente a opacidade dos processos, a variabilidade das respostas, a inadequação linguística, o erro conceitual, a autoria e a desigualdade de acesso. Desse confronto derivam três operações analíticas. Avaliar reúne critérios de julgamento sobre a pertinência, a correção e a adequação das soluções; depurar investiga a origem das falhas e os processos que as produziram; reconstruir transforma o resultado, reorganiza o percurso de resolução e explicita a responsabilidade assumida pela solução apresentada. Essas operações constituem categorias interpretativas formuladas neste artigo a partir da progressão curricular estabelecida pela BNCC Computação e dos problemas educacionais relacionados à geração automatizada de conteúdos.

A exposição preserva quatro núcleos articulados. Esta introdução situa a emergência do problema e explicita o objetivo do artigo. A seção seguinte examina como as investigações desenvolvidas no contexto brasileiro registram potencialidades e limites da geração automatizada de explicações, atividades e itens de avaliação. O desenvolvimento aproxima essas situações do pensamento computacional e das competências e habilidades da BNCC Computação, formulando consequências curriculares e pedagógicas. As conclusões retomam a pergunta de pesquisa e indicam implicações para a prática docente, para a avaliação da aprendizagem e para a implementação da Computação na Educação Básica.

A construção teórica opera em três níveis relacionados. No nível técnico, considera as características que distinguem a geração probabilística de outros recursos digitais. No nível pedagógico, examina como essas características interferem na agência dos sujeitos, na mediação docente, nos processos de representação e na avaliação da aprendizagem. No nível curricular, investiga quais direitos de aprendizagem previstos na BNCC Computação oferecem recursos para interpretar essa nova situação. A passagem entre os três níveis evita dois movimentos reducionistas: derivar finalidades educacionais diretamente das capacidades da ferramenta e discutir princípios curriculares sem considerar o comportamento concreto dos sistemas que já circulam nos espaços escolares.

IA NA EDUCAÇÃO BRASILEIRA

A literatura brasileira recente revela que a inteligência artificial generativa já participa de práticas ligadas ao

planejamento, à produção de materiais, à Educação Matemática e à avaliação. Esse conjunto de estudos afasta o debate de uma expectativa puramente futura e permite observar problemas concretos da Educação Básica. Essas experiências e discussões convergem em um ponto: a utilidade pedagógica dos resultados automatizados depende da capacidade humana de contextualizá-los, submetê-los a critérios e transformá-los de acordo com os objetivos de aprendizagem.

A apropriação brasileira da inteligência artificial generativa ocorre em condições diferentes daquelas pressupostas por parte da literatura internacional. Conectividade instável, compartilhamento de dispositivos, desigualdades de leitura, formação docente descontínua e diferenças regionais não constituem elementos externos ao uso da tecnologia; eles definem quem consegue formular solicitações, interpretar respostas e corrigir falhas. Por isso, a análise da IA na Educação Básica pública precisa articular dimensão cognitiva, mediação pedagógica e condições materiais. A mesma plataforma pode ampliar possibilidades para quem possui repertório disciplinar e produzir dependência ou exclusão para quem não dispõe dos recursos necessários à verificação (Oliveira; Andrade, 2026; Izidio *et al.*, 2025).

A revisão desenvolvida por Lima e Serrano (2024) identifica potencial para a geração de conteúdos, explicações e avaliações personalizadas. Os estudos examinados também registram lógica falha, imprecisão, desatualização, vieses e riscos relacionados à integridade acadêmica. A fluidez textual do ChatGPT, nesse sentido, produz uma ambivalência pedagógica: a ferramenta facilita o acesso a uma resposta, mas sua forma linguística pode conferir autoridade a informações que exigem verificação. A integração educacional responsável demanda estratégias que promovam pensamento crítico, criatividade, autoria e atenção às fontes.

A fluidez do texto automatizado cria uma assimetria entre produção e validação. Gerar uma explicação demanda poucos segundos e pouco conhecimento do usuário; validá-la pode exigir domínio conceitual, consulta a fontes, comparação entre representações e tempo de análise. Quanto mais convincente a formulação, maior o risco de que sinais linguísticos de autoridade substituam evidências. Essa assimetria ajuda a compreender por que a mera advertência de que a IA pode errar é insuficiente. A escola precisa ensinar procedimentos de corroboração e criar situações nas quais a falibilidade seja examinada concretamente, sem transformar a desconfiança em rejeição indiscriminada da tecnologia (Lima; Serrano, 2024).

Também é necessário distinguir personalização pedagógica e customização superficial. A inclusão do

ano escolar no prompt, a redução do vocabulário ou a geração de exemplos com nomes familiares podem modificar a forma da resposta sem alterar sua estrutura cognitiva. Uma explicação é pedagogicamente adequada quando considera os conhecimentos prévios, as representações acessíveis, os obstáculos previsíveis e as intervenções necessárias para que o estudante avance. Esses elementos não podem ser inferidos apenas pela idade ou pelo rótulo da etapa escolar. A promessa de personalização precisa, assim, ser avaliada pelo modo como a resposta participa de um percurso de aprendizagem, e não pela aparência de texto individualizado.

A criação de uma atividade sobre simetria com Gemini e Midjourney torna essa ambivalência visível em uma situação didática. Ribeiro *et al.* (2024) observaram que a estrutura do prompt influencia diretamente a precisão dos produtos e que a análise crítica do professor determina sua aplicabilidade em atividades com os estudantes. As plataformas ampliaram possibilidades de representação gráfica e articulação entre Matemática e Arte, mas também exigiram conhecimentos técnicos específicos e sucessivas tentativas. A atividade adquiriu sentido pedagógico por meio da seleção, da adaptação e da discussão dos resultados, e não pela geração tomada isoladamente. A produção visual torna-se recurso matemático quando é submetida a critérios disciplinares e integrada a uma atividade de análise, e não quando é exibida como ilustração autossuficiente (Ribeiro *et al.*, 2024).

Nesse processo, o prompt pode ser compreendido como artefato pedagógico. Ele materializa decisões sobre objetivo, conteúdo, público, representação, restrições e formato da resposta. A qualidade do comando depende, portanto, de conhecimentos que não são fornecidos pela interface: domínio da Matemática, compreensão curricular e antecipação das formas pelas quais os estudantes podem interpretar o material. As sucessivas tentativas relatadas por Ribeiro *et al.* (2024) não representam simples aperfeiçoamento técnico. Elas mostram um processo de design didático no qual o resultado do sistema retroage sobre as escolhas do professor e exige que os critérios inicialmente implícitos se tornem explícitos.

A necessidade de mediação aparece com maior nitidez na pesquisa de Carvalho *et al.* (2026), realizada com estudantes do sexto ano. As atividades apresentavam explicações geradas pelo ChatGPT sobre potências e áreas de quadrados e foram realizadas sem intervenção docente direta, de modo a investigar a compreensão das respostas automatizadas. A extensão e a complexidade textual dificultaram a passagem do registro verbal para representações matemáticas operacionais. A disponibilidade da explicação produziu, assim, uma situação paradoxal: o conteúdo estava diante dos estudantes, mas a forma de

apresentação elevava o custo cognitivo e limitava a construção de significado.

Esse resultado impede que personalização seja confundida com a simples emissão de uma resposta dirigida a determinado ano escolar. A adequação requer linguagem compatível com a competência leitora, articulação entre representações, exemplos significativos e acompanhamento das interpretações construídas pelos estudantes. Quando esses elementos faltam, a inteligência artificial pode atuar como obstáculo semiótico, reforçando dificuldades que a escola já enfrenta. A mediação docente organiza as condições para que a resposta seja interrogada, convertida em outras linguagens e reconstruída no ritmo da turma (Carvalho *et al.*, 2026).

A Teoria dos Registros de Representação Semiótica, mobilizada por Carvalho *et al.* (2026), permite aprofundar essa dificuldade. A compreensão matemática não decorre da exposição a uma representação isolada; ela exige tratamentos realizados dentro de um registro e conversões entre registros verbal, simbólico, numérico e figural. Uma resposta extensa pode descrever corretamente uma potência e, ainda assim, não oferecer ao estudante condições para convertê-la em multiplicação sucessiva ou relacioná-la à área de um quadrado. Quando a conversão não se realiza, a explicação permanece linguisticamente disponível, mas não se transforma em objeto matemático operável.

Essa perspectiva mostra que o problema não está apenas na extensão do texto. A resposta automatizada pode concentrar definições, procedimentos, exemplos e conclusões em um mesmo bloco, sem identificar os pontos em que o estudante precisa agir sobre cada representação. A mediação docente interrompe essa continuidade aparente: solicita um desenho, recupera um cálculo, compara símbolos, pergunta o significado de uma operação e regula o ritmo. Em termos teóricos, mediar significa organizar passagens entre registros e produzir condições para que a atividade cognitiva não seja substituída pela leitura passiva de um procedimento já concluído (Carvalho *et al.*, 2026).

A elaboração de itens de Matemática oferece outra evidência importante. Silva e Tanaka Filho (2025) compararam questões produzidas com auxílio de inteligência artificial e itens elaborados por especialistas. Parte dos itens gerados apresentou indicadores satisfatórios e poder discriminativo semelhante, demonstrando que a tecnologia pode apoiar o trabalho docente. O processo também produziu comandos genéricos, alternativas problemáticas, ausência de gabarito em alguns casos e indicação incorreta da alternativa correta. A qualidade final dependeu do domínio do conteúdo, do currículo e das boas práticas de elaboração e revisão.

No campo avaliativo, a experiência de Silva e Tanaka Filho (2025) exige separar qualidade psicométrica e validade pedagógica. Índices de dificuldade, discriminação e consistência interna informam como um item funcionou em determinado teste, mas não substituem a análise do conteúdo, do comando e do processo cognitivo mobilizado. Um item pode distinguir grupos de desempenho e, ao mesmo tempo, avaliar uma operação mais simples do que aquela prevista na habilidade curricular. Também pode conter contexto pouco funcional ou alternativas que não representam erros plausíveis. A validação requer reunir evidências estatísticas, curriculares, matemáticas e linguísticas.

O modelo de elaboração analisado pelos autores atribui à IA a geração dos itens e ao professor a definição da habilidade, do contexto, das orientações e das revisões. Essa distribuição evidencia que a automação não retira a complexidade do trabalho; ela a desloca para a especificação e para a curadoria. Quanto mais rápida a produção de itens, maior pode ser o volume de materiais que precisa ser examinado. O ganho de eficiência só possui sentido educacional quando o tempo liberado na redação inicial é convertido em análise de validade, melhoria dos distratores, adequação cognitiva e interpretação das respostas dos estudantes (Silva; Tanaka Filho, 2025).

As pesquisas nacionais permitem distinguir qualidade aparente e validade educacional. Coerência gramatical, organização visual e rapidez constituem propriedades úteis, mas oferecem evidência insuficiente sobre correção conceitual, pertinência curricular, acessibilidade cognitiva ou capacidade avaliativa. O produto automatizado inaugura uma dupla tarefa: resolver o problema educacional e auditar a solução oferecida. Essa auditoria mobiliza critérios que antecedem a ferramenta e que dependem de conhecimentos disciplinares, pedagógicos e computacionais.

A discussão sobre integridade acadêmica precisa acompanhar essa mudança de unidade de análise. Se a avaliação se concentra exclusivamente no produto, a instituição tende a oscilar entre presumir autoria integral e tentar detectar marcas de geração automática. Uma abordagem processual pergunta que conhecimentos foram mobilizados, que partes vieram do sistema e como foram verificadas e transformadas. A transparência do percurso não legitima qualquer uso, pois cada tarefa pode estabelecer limites específicos. Ela permite, contudo, avaliar a contribuição humana por evidências mais consistentes do que o estilo textual e transforma autoria em responsabilidade pelas decisões apresentadas (Giannakos *et al.*, 2025).

A possível economia de tempo docente também precisa ser analisada criticamente. Gerar planos, explicações ou itens reduz o esforço da primeira

redação, mas pode ampliar o trabalho invisível de conferência, adaptação e acompanhamento. Professores responsáveis por muitas turmas não dispõem necessariamente de condições para auditar grandes volumes de material automatizado. A adoção institucional deve prever critérios comuns, espaços de colaboração e formação, em vez de transferir individualmente ao professor toda a responsabilidade por riscos produzidos por sistemas complexos. Eficiência pedagógica não é apenas produzir mais em menos tempo, mas concentrar trabalho onde ele melhora efetivamente as condições de aprendizagem.

A avaliação crítica assume, nesse quadro, um sentido produtivo. Ela envolve formular o que se espera da solução, verificar sua consistência, confrontá-la com outras representações e decidir quais elementos podem ser aproveitados. A depuração amplia esse movimento ao localizar a origem de uma falha, distinguindo problemas do prompt, dos dados, das premissas, dos procedimentos e da própria capacidade do sistema. A reconstrução completa o percurso quando professor ou estudante transforma o resultado e responde por sua forma final.

A noção de coletivos formados por seres humanos e mídias, retomada por Oliveira e Andrade (2026), impede descrever a IA como instrumento neutro colocado entre um sujeito pronto e um conhecimento igualmente pronto. A tecnologia participa da formulação das questões, oferece representações, reorganiza tempos e induz estratégias. Contudo, participação na produção não significa simetria de responsabilidade. O sistema não responde pedagogicamente pelos efeitos de uma explicação, não conhece a trajetória da turma e não assume as consequências de uma decisão curricular. A agência pode ser distribuída no processo, mas a responsabilidade educacional permanece humana e institucional.

Na proposição de problemas matemáticos, a capacidade de interrogar a resposta mostrou-se dependente do conhecimento que o estudante já possuía. Quem reconheceu uma inconsistência pôde confrontar o sistema, produzir novo enunciado e testar outra solução; quem ainda não compreendia a linguagem algébrica encontrou dificuldades até para formular a dúvida. Esse contraste revela uma circularidade importante: a IA é apresentada como apoio para superar lacunas, mas o aproveitamento do apoio exige parte do repertório que se pretende construir. A mediação docente rompe essa circularidade ao fornecer critérios, traduções e perguntas intermediárias (Oliveira; Andrade, 2026).

DESENVOLVIMENTO

O pensamento computacional pode ser compreendido como uma forma humana de formular e resolver problemas por meio de abstração, decomposição,


reconhecimento de padrões, construção de algoritmos, generalização, teste e aperfeiçoamento. Sua dimensão formativa ultrapassa o aprendizado de uma linguagem específica porque envolve modos de representar situações, tornar procedimentos comunicáveis e examinar a qualidade das soluções. A inteligência artificial generativa insere-se nesse campo como novo meio de produção e interação, ao lado de atividades desplugadas, linguagens em blocos e programação textual.

Os elementos do pensamento computacional não operam como lista de técnicas independentes. Abstrair pressupõe decidir quais aspectos do problema são relevantes; decompor exige reconhecer relações entre partes; formular um algoritmo transforma uma estratégia em sequência comunicável; generalizar identifica o que pode ser reutilizado; testar e depurar confrontam a solução com seu comportamento. Cada operação modifica as demais e produz um ciclo de representação, execução e revisão. Hsu (2025) sistematiza seis elementos centrais, abstração, pensamento algorítmico, decomposição, depuração, generalização e iteração, cuja articulação permite compreender o pensamento computacional como processo de conhecimento, e não como treinamento procedimental.

O construcionismo acrescenta a esse processo uma teoria sobre as condições da aprendizagem. A construção de um artefato público torna ideias manipuláveis, permite observar efeitos das decisões e cria oportunidades de diálogo. Na programação, o erro não é apenas ausência de acerto: ele informa a diferença entre a intenção e o comportamento do artefato. A depuração pode produzir metacognição porque obriga o estudante a explicitar o que esperava, localizar onde o percurso se desviou e rever sua própria representação do problema. Autoria, nesse referencial, não se resume a assinar o produto, mas a manter relação intelectual com as decisões que o constituem (Hsu, 2025).

A experiência com ScratchJr relatada por Lima *et al.* (2024) ajuda a reconhecer o que está em jogo. Ao enfrentar um problema relacionado à degradação ambiental, crianças construíram sequências, identificaram padrões, elaboraram algoritmos e produziram soluções em um ambiente visual. O percurso tornava as decisões observáveis: blocos podiam ser reorganizados, execuções podiam ser repetidas e o efeito de cada alteração aparecia no artefato. Colaboração, criatividade, autonomia e pensamento crítico emergiram associados à construção progressiva de uma solução.

A aprendizagem baseada em problemas reforça essa dimensão ao iniciar a atividade por uma situação que precisa ser compreendida e transformada. No relato de Lima *et al.* (2024), o ScratchJr não funciona como finalidade isolada. O ambiente de blocos oferece uma



linguagem para representar respostas construídas coletivamente diante de um problema ambiental. A criatividade emerge ligada a restrições, escolhas e revisões, e não como produção espontânea sem critérios. Essa relação entre problema significativo e artefato editável constitui um parâmetro para avaliar práticas com IA: a geração só adquire valor construcionista quando participa de um projeto cujo sentido, decisões e critérios pertencem aos aprendizes.

Sistemas generativos alteram a visibilidade desse percurso. O estudante fornece uma instrução em linguagem natural e recebe um produto que pode reunir, em uma única resposta, decomposição, explicação, código e conclusão. Os passos intermediários deixam de ser diretamente observáveis, e a execução pode parecer encerrada antes que o problema tenha sido compreendido. A atividade formativa precisa, então, criar meios para reabrir a solução: explicitar critérios, solicitar justificativas, produzir casos de teste, comparar estratégias e registrar as modificações realizadas.

A opacidade dos modelos generativos não impede toda investigação, mas modifica aquilo que pode ser observado. Estudantes não têm acesso direto aos dados, pesos e operações internas que produziram cada palavra. Podem, entretanto, examinar as condições de entrada, comparar saídas, variar restrições, criar casos de teste e avaliar a estabilidade das respostas. O processo formativo desloca-se de uma tentativa de explicar integralmente o modelo para a construção de evidências sobre seu comportamento. Essa postura aproxima a interação com IA de uma investigação empírica: hipóteses sobre a solução são confrontadas com resultados e revisadas conforme os dados produzidos.

A natureza probabilística da geração também altera o significado de correção. Um algoritmo determinístico, nas mesmas condições, tende a produzir a mesma saída; um modelo generativo pode apresentar formulações ou estratégias diferentes. A variabilidade não é, por si, um erro, mas exige critérios que ultrapassem a coincidência textual entre respostas. É preciso verificar invariantes conceituais, testar casos particulares, identificar contradições e examinar se conclusões permanecem válidas sob diferentes formulações. O pensamento computacional contribui ao transformar a resposta variável em objeto de comparação sistemática, evitando que uma única interação seja tratada como prova suficiente.

A educação sobre inteligência artificial pode começar antes do uso intensivo de plataformas. Conti *et al.* (2025) descrevem atividades desplugadas com estudantes do quinto ano voltadas à compreensão de padrões, algoritmos, decisões e implicações éticas da inteligência artificial. As tarefas combinaram narrativas, rubricas, comparação de respostas e mediação docente. A experiência demonstra que a

compreensão de aspectos da IA e o desenvolvimento do pensamento computacional podem ocorrer sem infraestrutura avançada em todos os momentos da aula. O trabalho pode partir de situações em que as decisões se tornam discutíveis e os critérios são construídos coletivamente.

As atividades desplugadas analisadas por Conti *et al.* (2025) indicam que a compreensão da inteligência artificial não começa necessariamente pela operação de um modelo. Classificar, reconhecer padrões, representar decisões e discutir consequências permitem tornar visíveis ideias que sustentam sistemas automatizados. Essa opção é teoricamente relevante porque separa educação sobre IA de consumo de plataformas. O estudante pode investigar como uma decisão depende de dados e critérios antes de interagir com um serviço comercial. O pensamento computacional atua, assim, como fundamento da alfabetização em IA, articulando compreensão de processos, julgamento crítico e possibilidade de intervenção.

A proposição de problemas matemáticos mediada pelo ChatGPT acrescenta outro elemento. Oliveira e Andrade (2026) observaram que a IA favoreceu a exploração inicial de equações e a formulação de estratégias, porém suas contribuições foram condicionadas ao letramento matemático, à competência leitora, à conectividade e à mediação docente. Um estudante identificou inconsistências, confrontou o sistema e passou a questionar sua confiabilidade, revelando potencial metacognitivo. A maioria encontrou dificuldades para interpretar os textos e julgar as respostas, e a tecnologia explicitou ou ampliou lacunas já existentes.

O episódio é teoricamente relevante porque a detecção de erro exige conhecimento sobre o objeto e disposição para desconfiar da forma pronta. O sistema pode oferecer um contraexemplo, uma solução alternativa ou um feedback, mas a aprendizagem depende da possibilidade de o estudante justificar por que uma afirmação deve ser mantida ou recusada. A mediação organiza essa passagem da reação intuitiva para a análise baseada em critérios. O pensamento computacional fornece operações para decompor a resposta, testar partes, relacionar entradas e saídas e recompilar uma solução mais consistente.

O episódio estudado por Oliveira e Andrade (2026) mostra que o erro automatizado pode assumir funções pedagógicas opostas. Sem repertório para reconhecê-lo, o estudante pode incorporá-lo como resposta autorizada. Quando dispõe de conhecimentos e espaço para confrontar o sistema, a inconsistência converte-se em problema investigável. O potencial formativo não reside no erro em si, mas na organização de uma atividade em que ele possa ser detectado, explicado e corrigido. Isso requer que o professor trate a saída como hipótese e garanta uma fonte independente de

validação, como cálculo, execução, representação gráfica, documento curricular ou discussão coletiva.

A noção de seres-humanos-com-IA permite interpretar esse processo como cognição distribuída sem dissolver o sujeito. O estudante formula perguntas a partir de sugestões recebidas, a interface reorganiza o campo de possibilidades, os colegas oferecem interpretações e o professor produz intervenções. O conhecimento resulta da coordenação desse coletivo. Porém, a formação escolar deve garantir que a distribuição não se converta em expropriação das operações intelectuais centrais. Definir o problema, compreender os critérios e justificar a solução precisam permanecer acessíveis ao aprendiz, ainda que cálculos, exemplos ou versões intermediárias sejam produzidos com apoio tecnológico (Oliveira; Andrade, 2026).

A proposta de Hsu (2025) aproxima prompting e pensamento computacional ao tratar a interação com modelos de linguagem como processo iterativo. Prompts podem materializar abstrações, orientar decomposições, ordenar etapas e ser aprimorados com base nas respostas. Essa correspondência oferece uma via promissora para atividades em diferentes componentes curriculares. Seu alcance formativo cresce quando o foco abrange, além da clareza do comando, a análise daquilo que o sistema devolve e a fundamentação das mudanças realizadas ao longo da interação.

O quadro construcionista de Hsu (2025) organiza a interação em cinco princípios mutuamente dependentes. O prompting significativo vincula a tarefa a problemas e experiências que importam para os estudantes. A análise metacognitiva da relação entre prompt e resposta exige refletir sobre a própria formulação e sobre o produto recebido. O aperfeiçoamento iterativo transforma cada resposta em informação para a versão seguinte. O prompting social torna comandos e resultados objetos de colaboração e crítica entre pares. O prompting dirigido pelo aprendiz preserva autonomia e responsabilidade nas decisões. Juntos, esses princípios descrevem condições pedagógicas, e não apenas técnicas de comunicação com o modelo.

A distinção entre prompt significativo e prompt eficiente é decisiva. Um comando pode ser conciso, explícito e capaz de obter o formato solicitado sem mobilizar qualquer compreensão relevante do estudante. Inversamente, um prompt inicialmente incompleto pode tornar-se formativo se sua revisão obriga a explicitar pressupostos, selecionar informações e comparar alternativas. A qualidade educacional não pode ser aferida somente pela proximidade entre saída e expectativa. Deve considerar o tipo de raciocínio produzido no percurso e o grau em que o estudante consegue explicar por que

modificou o comando, aceitou parte da resposta e recusou outra (Hsu, 2025).

A ideia de programação em linguagem natural amplia o acesso à expressão computacional, mas introduz ambiguidades próprias da linguagem humana. Palavras dependem de contexto, termos podem assumir sentidos diferentes e instruções aparentemente claras podem omitir condições essenciais. Na programação tradicional, erros sintáticos frequentemente interrompem a execução; na interação generativa, o sistema tende a produzir alguma resposta mesmo diante de especificações incompletas. Essa tolerância favorece a experimentação, mas pode ocultar falhas na definição do problema. Ensinar prompting como pensamento computacional requer trabalhar a precisão conceitual e a explicitação de critérios, sem reduzir linguagem natural a pseudocódigo rígido (Hsu, 2025).

Os cinco princípios também convergem com a autorregulação discutida por Giannakos *et al.* (2025). O estudante planeja ao definir objetivo e critérios, monitora ao comparar prompt e resposta, regula a ação ao introduzir mudanças e reflete ao justificar a versão obtida. Em grupos, a regulação torna-se compartilhada quando decisões, dúvidas e estratégias são negociadas. Essa convergência oferece um indicador teórico para o desenho de atividades: a IA deve produzir oportunidades de regulação, e não apenas respostas personalizadas. Quanto mais o sistema antecipa decisões sem torná-las discutíveis, menor é o espaço para que o aprendiz desenvolva controle sobre o próprio processo.

A passagem da programação ao prompting adquire, assim, sentido de expansão. Programar torna explícita uma sequência formal de instruções; elaborar prompts permite expressar problemas em linguagem natural e negociar resultados com o sistema. As duas práticas podem coexistir e se esclarecer mutuamente. A primeira favorece a compreensão da lógica executável e o acompanhamento detalhado dos efeitos de cada instrução. A segunda amplia os objetos produzidos e cria situações em que a avaliação de uma saída incerta se torna parte constitutiva da resolução.

Programação e prompting distribuem de modo distinto as etapas clássicas de representação, automação e análise. A linguagem natural reduz barreiras para representar intenções e solicitar automatizações, mas parte da tradução entre intenção e procedimento passa a ser realizada pelo modelo. A análise posterior torna-se, por isso, mais exigente: o usuário precisa reconstruir relações que não formulou diretamente. A facilidade de entrada não pode ser confundida com redução da complexidade do problema. Em termos educacionais, ela só democratiza a expressão computacional quando vem acompanhada de condições para compreender e avaliar a automação produzida (Hsu, 2025).

É possível descrever essa condição como necessidade de uma fricção epistêmica produtiva. A interface foi desenhada para reduzir o intervalo entre pedido e resposta; a aprendizagem, ao contrário, frequentemente depende de suspender a aceitação, formular dúvida e procurar evidências. Inserir comparação, previsão e teste antes da visualização da solução restitui tempo ao pensamento. Essa fricção não busca tornar o uso artificialmente difícil, mas impedir que conveniência operacional e conclusão cognitiva se confundam. O professor organiza pausas nas quais o estudante antecipa o que espera, confronta o resultado e explica as diferenças.

O controle humano educacionalmente significativo ultrapassa a presença formal de uma pessoa no circuito. Clicar para aprovar uma resposta sem dispor de condições para examiná-la não constitui controle substantivo. É preciso que professor e estudante tenham informações, tempo, critérios e autoridade para modificar ou recusar a saída. Essa condição relaciona competência e poder de decisão. Atividades que exigem justificativa, permitem soluções alternativas e não penalizam a recusa fundamentada da sugestão automatizada tornam a supervisão humana parte real da aprendizagem, em vez de salvaguarda apenas declaratória.

A BNCC Computação oferece fundamentos para essa ampliação ao organizar, desde a Educação Infantil, aprendizagens relacionadas à elaboração, à testagem e à comparação de soluções algorítmicas. No Ensino Fundamental, essa progressão adquire maior complexidade, pois incorpora a análise dos processos envolvidos na resolução de problemas, a avaliação das soluções produzidas e a construção de argumentos sustentados por informações confiáveis. Dessa forma, o documento atribui ao pensamento computacional uma dimensão de julgamento que acompanha a produção de soluções desde as primeiras etapas da escolarização (Brasil, 2022).

O complemento à BNCC organiza a Computação em pensamento computacional, mundo digital e cultura digital. A IA generativa atravessa os três eixos. Como processo computacional, pode ser abordada por representação, decomposição, algoritmos, dados e testes. Como componente do mundo digital, depende de infraestrutura, armazenamento, processamento, redes e segurança. Como fenômeno de cultura digital, envolve autoria, confiabilidade, privacidade, impactos sociais e uso responsável. Restringir a discussão ao prompt concentra-se na interface e empobrece a formação curricular. A integração precisa relacionar resolução de problemas, funcionamento dos sistemas e participação ética na sociedade digital (Brasil, 2022).


Na Educação Infantil, a progressão curricular articula experiências de reconhecimento de regularidades, organização sequencial de ações, execução de procedimentos, comparação entre alternativas e

compreensão de decisões binárias. Essas aprendizagens preservam as características próprias da etapa e favorecem o desenvolvimento de atitudes investigativas diante de processos e resultados. Em situações relacionadas à inteligência artificial, essa formação inicial contribui para que a criança estabeleça relações entre instruções, ações e efeitos, examinando por que determinados procedimentos funcionam, falham ou conduzem a resultados diferentes. Atividades como comparar percursos, revisar uma sequência e reformular coletivamente uma regra introduzem a compreensão de que os resultados produzidos por artefatos tecnológicos decorrem de processos que podem ser observados, explicados e questionados (Brasil, 2022).

Nos anos finais do Ensino Fundamental, a habilidade EF07CO02 introduz de maneira mais sistemática a revisão de programas por meio da localização e da correção de falhas. A depuração passa a envolver a observação minuciosa do funcionamento do programa, a realização de testes e a modificação dos elementos responsáveis pelo comportamento inadequado. No Ensino Médio, essa orientação é ampliada pelas habilidades EM13CO01, EM13CO02 e EM13CO06, que abrangem o aproveitamento de componentes de soluções anteriores, a reformulação de problemas em diferentes níveis de abstração e o exame da qualidade de programas com base em propriedades e parâmetros definidos. A progressão curricular articula, assim, produção, análise, experimentação, revisão e julgamento fundamentado de soluções computacionais (Brasil, 2022).

No Ensino Médio, a habilidade EM13CO05 acrescenta a investigação do alcance e das limitações dos processos automatizados. Em relação à inteligência artificial generativa, essa formulação permite deslocar discussões genéricas sobre a substituição do trabalho humano para a análise das características de cada atividade. A produção de uma versão inicial de um texto, código ou explicação pode ser automatizada, enquanto a definição de sua finalidade educativa, a interpretação das particularidades do contexto e a responsabilização por seus efeitos exigem decisões que ultrapassam a geração automática. Examinar os limites da automação envolve, portanto, confrontar o desempenho do sistema com as exigências da situação e com os critérios humanos que orientam a aceitação, a revisão ou a recusa do resultado (Brasil, 2022).

A habilidade EM13CO04, voltada à compreensão de processos nos quais algoritmos manipulam ou produzem outros algoritmos, também sustenta essa aproximação. Essa formulação curricular favorece a análise de sistemas capazes de gerar códigos, procedimentos e representações computacionais. A aparência formalmente adequada de uma saída não comprova sua validade, pois o artefato produzido



precisa ser interpretado, executado e submetido a condições variadas de teste. Nesse contexto, o estudante assume uma posição analítica diante do processo automatizado: além de compreender o funcionamento do artefato gerado, precisa examinar as condições de sua produção, verificar seu comportamento e modificar os elementos que comprometem sua adequação. Essa mudança de nível reforça a articulação entre abstração, avaliação e depuração no pensamento computacional (Brasil, 2022).

A presença da inteligência artificial generativa permite extrapolar essas habilidades sem alterar seu núcleo. Um programa escrito pelo estudante e uma explicação gerada por um modelo são artefatos diferentes, mas ambos podem ser analisados a partir do problema, das entradas, dos procedimentos, dos resultados e dos critérios de qualidade. A extrapolação consiste em aplicar operações curriculares já previstas a produtos cujo processo de produção é menos transparente e cuja linguagem plausível pode dificultar a identificação de falhas.

A extrapolação pode ser refinada por três perguntas complementares. Verificar indaga se a solução executa corretamente o procedimento especificado; validar examina se o procedimento responde ao problema e ao contexto; avaliar julga sua qualidade diante de critérios mais amplos, incluindo clareza, eficiência, segurança e efeitos sociais. Uma resposta pode ser internamente coerente e falhar na validação porque resolve outro problema. Pode também ser correta e inadequada ao público por exigir conhecimentos não disponíveis. Separar essas perguntas impede que um único sinal, como obter o resultado numérico esperado, seja tomado como evidência suficiente de qualidade.

Essa distinção evidencia o papel do conhecimento de domínio. Nenhuma técnica genérica de checagem substitui a compreensão necessária para formular bons critérios. Em Matemática, validar pode exigir demonstração, estimativa, representação gráfica ou análise de casos; em uma atividade pedagógica, requer ainda examinar currículo, linguagem e obstáculos de aprendizagem. A dependência de especialistas não é defeito ocasional que versões futuras da tecnologia necessariamente eliminarão. Ela decorre do caráter situado dos critérios e da responsabilidade de justificar por que determinada solução merece ser aceita em um contexto educacional (Giannakos *et al.*, 2025; Silva; Tanaka Filho, 2025).

Avaliar significa estabelecer critérios antes de aceitar a resposta. Correção, pertinência, clareza, eficiência, segurança, confiabilidade, adequação ao público e responsabilidade ética constituem dimensões possíveis, selecionadas conforme o problema. Na interação com sistemas generativos, a avaliação inclui verificar se a saída atende ao pedido, se as

informações podem ser corroboradas, se há omissões relevantes, se as representações são compatíveis e se a solução produz consequências aceitáveis. A avaliação transforma impressão de qualidade em julgamento argumentado.

Os critérios de avaliação podem ser agrupados em dimensões. A dimensão epistêmica examina correção, fontes, coerência e limites da afirmação. A dimensão computacional considera eficiência, robustez, segurança e comportamento sob diferentes entradas. A dimensão pedagógica analisa objetivo de aprendizagem, adequação da linguagem, representações e possibilidade de participação do estudante. A dimensão ética e social inclui privacidade, vieses, autoria, acessibilidade e consequências do uso. Nenhuma lista funciona como protocolo universal; sua função é obrigar a explicitação do que conta como qualidade em cada tarefa e tornar o julgamento comunicável e contestável.

Depurar significa localizar e compreender falhas por meio de análise e testes. O erro pode estar na formulação vaga do problema, em dados incompletos, em uma decomposição inadequada, em inferências inválidas, no código produzido ou na explicação final. Reformular o prompt constitui uma etapa possível, mas a depuração alcança também o conteúdo e a estrutura da solução. Casos-limite, contraexemplos, execução de código, cálculos independentes, comparação com fontes e mudança de representação ajudam a identificar onde a resposta deixa de sustentar-se.

A depuração de uma resposta generativa exige uma taxonomia mais ampla do erro. A falha pode originar-se na definição do problema, na seleção de dados, na ambiguidade do prompt, em uma inferência do modelo, na conversão entre representações, na inadequação ao público ou na ausência de critérios de validação. Identificar o nível da falha evita o ritual de apenas reescrever o comando até obter uma saída agradável. Se o problema está mal definido, um prompt mais detalhado pode apenas tornar mais convincente uma solução irrelevante. Depurar significa construir uma explicação para o erro e escolher uma intervenção correspondente à sua origem.

Reconstruir significa assumir responsabilidade pela solução final. A operação reúne partes válidas, substitui procedimentos frágeis, modifica representações e explicita a justificativa das escolhas. Seu produto pode ser um novo texto, um algoritmo corrigido, uma atividade adaptada, uma imagem comentada ou um problema reformulado. A reconstrução distingue uso autoral de simples apropriação, pois torna visíveis as intervenções humanas e devolve ao estudante a posição de sujeito que formula, decide e responde pelo artefato.

Reconstruir difere de editar superficialmente. Correções locais podem retirar um erro sem rever a estrutura que o produziu. A reconstrução pergunta quais partes são sustentáveis, quais premissas precisam ser substituídas e que nova organização torna o artefato coerente com os critérios. Ela pode resultar na recusa integral da saída, decisão tão formativa quanto seu aproveitamento. Ao documentar fontes, testes, alterações e justificativas, o estudante converte um produto de origem parcialmente opaca em solução pela qual pode responder. A autoria é recuperada não pela ocultação do uso da IA, mas pela transparência das decisões humanas que definiram a versão final.

Tabela 1. Operações formativas diante de soluções produzidas com IA generativa.

Operação	Desdobramento formativo
Avaliar	Definir critérios, comparar soluções e julgar correção, pertinência, confiabilidade e efeitos da resposta automatizada.
Depurar	Decompor a solução, testar partes e localizar falhas no problema, no prompt, nos dados, nos procedimentos ou no resultado.
Reconstruir	Reutilizar elementos válidos, substituir trechos frágeis e produzir uma versão final justificada, com autoria responsável.

Fonte: elaboração própria com base em Brasil (2022) e Hsu (2025).

A articulação das três operações configura um ciclo pedagógico. Primeiro, a turma formula o problema e define critérios de qualidade antes de consultar a IA. Em seguida, registra o prompt e a resposta, identifica as partes da solução e compara o produto com uma resolução independente, outra fonte ou um conjunto de testes. Depois, localiza inconsistências, altera comandos e procedimentos e produz nova versão. Por fim, apresenta a solução reconstruída acompanhada de justificativa sobre o que foi mantido, corrigido ou recusado. O registro do percurso preserva o processo cognitivo que a geração imediata tende a apagar.

O ciclo não deve ser compreendido como sequência rígida. A avaliação inicial pode revelar que o próprio problema precisa ser redefinido; a depuração pode exigir novos critérios; a reconstrução pode gerar falhas que reabrem os testes. Essa recursividade aproxima as três operações da iteração do pensamento computacional. Seu valor pedagógico reside em tornar visível a mudança de entendimento ao longo das versões. Uma atividade bem-sucedida não é necessariamente aquela que alcança rapidamente uma resposta correta, mas aquela em que os estudantes conseguem explicar como as evidências modificaram sua representação do problema e suas decisões sobre a solução.

Os registros do ciclo constituem evidências de aprendizagem. Versões de prompts, anotações sobre trechos recusados, casos de teste, fontes consultadas e justificativas permitem observar operações que desaparecem no produto final. Esses rastros não devem transformar a atividade em burocracia documental. Podem ser selecionados conforme o objetivo, por exemplo, uma tabela de erros em programação, um comentário comparando explicações matemáticas ou uma breve defesa oral da solução reconstruída. O princípio é deslocar a avaliação da posse da resposta para a qualidade do raciocínio que relaciona problema, evidência e decisão.

Na Educação Infantil e nos anos iniciais, esse ciclo pode assumir formas desplugadas e coletivas. O professor apresenta duas sequências, rotas ou explicações curtas, uma delas com falha planejada, e convida as crianças a comparar resultados, testar possibilidades e reconstruir a ordem das ações. Histórias, jogos de regras, receitas e classificações permitem discutir como instruções produzem efeitos. O contato eventual com uma resposta gerada por IA deve ocorrer com linguagem acessível e forte mediação, de modo que o julgamento seja mais importante que a operação da interface.

Nos anos finais do Ensino Fundamental, as atividades podem combinar linguagem em blocos, textos e respostas automatizadas. Estudantes podem pedir à IA que explique um algoritmo, produza uma solução ou gere casos de teste, comparando o resultado com a execução real. Podem também anotar trechos duvidosos, criar contraexemplos, corrigir códigos e reescrever explicações para outra faixa etária. O objetivo é produzir rastros de raciocínio que evidenciem decomposição, abstração, escolha de critérios e depuração.

No Ensino Médio, a análise das soluções computacionais pode mobilizar critérios mais complexos, relacionados ao desempenho, ao uso de recursos, à proteção de dados, à segurança, à presença de vieses, à qualidade das informações utilizadas e ao alcance dos processos automatizados. Nesse nível de ensino, os estudantes podem confrontar produções humanas e automatizadas, verificar o funcionamento de códigos gerados, examinar os dados que condicionam os resultados e reaproveitar componentes de soluções já existentes. A reconstrução passa a envolver o registro das escolhas realizadas, a justificativa das alterações introduzidas e o reconhecimento das limitações técnicas e contextuais dos sistemas, em articulação com as competências de análise crítica de artefatos computacionais previstas para essa etapa (Brasil, 2022).

A progressão entre etapas precisa evitar uma alfabetização instrumental em prompts. Na infância, critérios podem assumir a forma de perguntas

concretas sobre sequência, resultado e comparação. Nos anos finais, os estudantes podem formular testes, identificar fontes e analisar conversões entre representações. No Ensino Médio, podem incorporar métricas, limites da automação, segurança, privacidade e impactos sociais. O que progride não é apenas a complexidade do comando dirigido à IA, mas a capacidade de justificar critérios e compreender o sistema em diferentes níveis. Essa organização mantém a interface subordinada aos direitos de aprendizagem definidos curricularmente.

A avaliação escolar precisa acompanhar esse deslocamento. Quando se considera apenas o produto final, uma resposta gerada e pouco compreendida pode receber o mesmo valor de uma solução construída e justificada. Critérios processuais permitem observar formulação do problema, qualidade dos testes, identificação de erros, comparação entre estratégias, fundamentação das alterações e capacidade de explicar a versão final. A pesquisa de Silva e Tanaka Filho (2025) mostra, no campo dos itens, que o resultado automatizado demanda revisão criteriosa; a mesma exigência pode constituir objeto de aprendizagem para os estudantes.

Rubricas processuais podem distinguir dimensões que o produto acabado tende a confundir. A formulação do problema, a pertinência dos critérios, a diversidade dos testes, a precisão na localização da falha, a qualidade da reconstrução e a justificativa das escolhas podem ser avaliadas separadamente. Uma defesa oral ou comparação entre versões ajuda a verificar se o estudante compreende o que apresenta. O uso declarado da IA deixa, então, de ser tratado apenas como indício de fraude ou facilidade e passa a integrar uma situação avaliativa em que a contribuição do sistema e a contribuição humana precisam ser identificadas e analisadas.

A mediação docente adquire uma função intelectual e curricular ainda mais expressiva. Cabe ao professor selecionar problemas com potencial formativo, antecipar critérios, organizar comparações, reconhecer dificuldades de leitura e garantir que a IA participe como recurso submetido aos objetivos educacionais. Os estudos sobre simetria e compreensão de explicações mostram que a qualidade do prompt, a linguagem da resposta e a intervenção pedagógica afetam profundamente os resultados (Ribeiro *et al.*, 2024; Carvalho *et al.*, 2026). A formação docente precisa integrar conhecimentos disciplinares, pedagógicos e computacionais.

A formação docente requerida por esse cenário articula pelo menos quatro domínios. O conhecimento disciplinar sustenta a validação do conteúdo; o pedagógico orienta linguagem, mediação e avaliação; o computacional permite decompor processos, criar testes e compreender limites técnicos; o conhecimento sobre IA aborda variabilidade, dados, vieses,


privacidade e formas de interação. Esses domínios não precisam estar concentrados em especialistas isolados, mas devem compor políticas de formação e colaboração na escola. Sem essa integração, a ferramenta tende a ser incorporada como atalho de produção ou proibida por insegurança, em vez de transformada em objeto curricular.

A efetivação desse horizonte encontra desafios políticos. Melo e Oliveira Junior (2025) identificam que o documento final da CONAE 2024 incorporou estratégias relacionadas à educação digital, à inclusão, ao letramento digital, à inteligência artificial, à conectividade e à formação dos profissionais da educação, mas não apresentou propostas específicas para a implementação da BNCC Computação. A distância entre a presença geral das tecnologias na agenda e a concretização de uma estrutura curricular de Computação pode favorecer usos instrumentais, com pouco espaço para compreender processos e avaliar artefatos.

A implementação da BNCC Computação deve ser compreendida como garantia de direito de aprendizagem, não como coleção de projetos ocasionais. Melo e Oliveira Junior (2025) mostram que a presença de temas como conectividade, inclusão e inteligência artificial na agenda nacional não equivale à definição de responsabilidades, currículos, recursos e formação para a Computação. A distância entre reconhecimento discursivo e implementação pode produzir uma escola que utiliza sistemas avançados sem oferecer aos estudantes conhecimentos para compreendê-los. Inserir avaliação, depuração e reconstrução nos currículos requer continuidade entre anos, componentes e políticas de formação.

O panorama pré e pós Resolução n.º 1/2022 reforça essa tensão. Izidio *et al.* (2025) observam crescimento de metodologias estruturadas, inserção curricular e formação de professores, enquanto persistem carências de infraestrutura e materiais acessíveis. Os estudos concentram-se em algoritmos, lógica e programação, enquanto abordagens mais amplas e tecnologias como inteligência artificial permanecem menos presentes. A reconfiguração aqui defendida amplia o campo sem abandonar seus fundamentos, pois conecta a produção algorítmica à avaliação de soluções automatizadas que já circulam na vida escolar.

A baixa presença de inteligência artificial no panorama analisado por Izidio *et al.* (2025) não autoriza substituir as práticas consolidadas por uma agenda orientada pela novidade. Ela sinaliza a necessidade de investigar como a IA se articula a metodologias já acessíveis, como computação desplugada, projetos e programação em blocos. Essa articulação favorece continuidade curricular e oferece referências independentes para comparar resultados. Um código construído em blocos, uma sequência



representada no papel ou uma solução matemática elaborada pela turma podem funcionar como contrapesos cognitivos diante da resposta generativa, permitindo que o novo recurso seja analisado a partir de conhecimentos efetivamente apropriados.

Infraestrutura e equidade precisam integrar o desenho das práticas. A formação para avaliar e depurar resultados pode combinar atividades plugadas e desplugadas, trabalho coletivo, respostas previamente impressas e uso compartilhado de dispositivos. Essa diversidade impede que o ensino da IA seja reduzido ao acesso individual a plataformas comerciais. Também permite discutir quem produz os sistemas, quais dados os alimentam, quais interesses organizam seus resultados e como a dependência de infraestruturas externas afeta a autonomia das escolas.

A dependência de plataformas comerciais acrescenta problemas de continuidade e reprodutibilidade. Modelos mudam, funções podem tornar-se pagas, respostas variam e regras de tratamento de dados são definidas fora da escola. Uma atividade não pode depender de que todos obtenham a mesma saída ou tenham acesso permanente à mesma versão. Por isso, o desenho pedagógico deve privilegiar operações transferíveis entre sistemas, como formular critérios, comparar, testar e justificar. Respostas previamente selecionadas, registros impressos e simulações desplugadas também preservam o objeto conceitual quando o acesso direto é inadequado ou indisponível.

Duas respostas recorrentes à IA, a aceitação imediata e a proibição indiferenciada, mantêm o artefato fora da análise curricular. Uma pedagogia orientada pelo pensamento computacional trabalha essa tensão de modo formativo: oferece situações controladas, torna critérios explícitos, protege dados, ajusta o uso à idade e transforma erros em objetos de investigação. O propósito consiste em formar estudantes capazes de operar tecnologias, compreender seus limites e intervir sobre as soluções que elas produzem.

O debate precisa ainda evitar dois reducionismos. O primeiro identifica pensamento computacional exclusivamente com codificação e exclui práticas de análise realizadas em outras linguagens. O segundo interpreta a facilidade do prompting como superação da programação e trata a geração como substituta da compreensão algorítmica. Entre ambos, a posição defendida reconhece uma ecologia de práticas: atividades desplugadas, programação visual ou textual, análise de dados e interação em linguagem natural oferecem diferentes formas de representar e resolver problemas. Sua integração deve ser julgada pelas operações intelectuais que possibilita, e não pela novidade da interface.

A inteligência artificial generativa tensiona o pensamento computacional porque reduz a visibilidade do processo e facilita a circulação de

respostas prontas. Ela o amplia porque multiplica artefatos, estratégias e oportunidades de comparação, feedback e iteração. Ela o reconfigura porque desloca parte do esforço da produção inicial para a avaliação, a depuração e a reconstrução. Essas três dimensões coexistem e exigem uma estrutura curricular que preserve a construção de algoritmos enquanto incorpora a análise crítica de soluções automatizadas.


CONCLUSÕES

A análise permite responder que a inteligência artificial generativa amplia e reconfigura as finalidades do pensamento computacional previstas na BNCC Computação, ao mesmo tempo que tensiona as condições pelas quais essas finalidades se realizam. A geração imediata de textos, códigos e explicações aumenta a quantidade de soluções disponíveis, mas reduz a visibilidade das operações que as produziram. Por isso, a capacidade de construir precisa articular-se, de forma sistemática, à capacidade de avaliar, depurar e reconstruir.

A principal contribuição teórica do estudo é organizar essa reconfiguração em três operações interdependentes. Avaliar converte impressões em julgamento orientado por critérios; depurar transforma a falha em objeto de investigação; reconstruir restitui ao sujeito a decisão sobre a forma final do artefato. As três operações já possuem raízes nas habilidades da BNCC Computação, mas adquirem nova centralidade diante de sistemas que produzem respostas plausíveis sem expor integralmente seu processo. O modelo proposto não constitui sequência didática universal. Ele oferece categorias para analisar currículos, tarefas e avaliações em contextos mediados por IA generativa.

O panorama internacional demonstra que a IA na educação constitui um campo amplo e que a inteligência artificial generativa introduz desafios de confiabilidade, ética e competência humana. As pesquisas brasileiras tornam esses desafios concretos: atividades visuais exigem prompts e curadoria; explicações podem tornar-se obstáculos quando desconsideram a competência leitora; itens de avaliação podem apresentar bom desempenho estatístico e, ainda assim, conter falhas que demandam revisão especializada. A forma convincente do produto automatizado oferece poucos indícios sobre sua validade.

A BNCC Computação fornece bases consistentes para enfrentar essa situação. Comparar soluções, avaliar resultados e processos, detectar e remover erros, reutilizar partes, refinar níveis de abstração e avaliar software formam uma progressão que atravessa as etapas da Educação Básica. A inteligência artificial generativa não cria do zero essas necessidades formativas; ela as reposiciona diante de artefatos



opacos, probabilísticos e linguisticamente persuasivos.

Nesse sentido, o ensino de Computação preserva a experiência de formular problemas, construir algoritmos e produzir artefatos, acrescentando situações nas quais os estudantes definem critérios, testam respostas automatizadas, localizam falhas e elaboram versões justificadas. O resultado final deixa de ser a única evidência de aprendizagem. Registros de prompts, comparações, testes, revisões e justificativas tornam-se parte do objeto avaliado.

Esse deslocamento não significa transferir o trabalho intelectual do estudante para a máquina e depois acrescentar uma etapa genérica de revisão. Significa reorganizar a tarefa para que compreender o problema, estabelecer critérios, produzir evidências e justificar decisões permaneçam como ações formativas. Em algumas situações, a melhor escolha será não usar a IA; em outras, comparar saídas ou depurar um código gerado produzirá aprendizagens que não ocorreriam com a resolução convencional. A decisão pedagógica depende do que se pretende tornar observável, discutível e apropriável pelo estudante.

Esse horizonte depende de mediação docente, formação continuada, materiais adequados e políticas de infraestrutura e inclusão. A presença de uma plataforma na escola oferece uma condição técnica; a formação crítica exige tempo pedagógico para investigar e reconstruir. Atividades desplugadas e híbridas podem democratizar essa aprendizagem e evitar que a educação sobre IA fique subordinada ao consumo individual de serviços comerciais. A estrutura curricular precisa assegurar condições para que estudantes e professores mantenham autoria e soberania epistêmica.

Soberania epistêmica, neste contexto, não significa produzir todo o conhecimento sem mediação tecnológica. Significa conservar condições para compreender as bases de uma afirmação, comparar alternativas e recusar resultados quando os critérios não são satisfeitos. A escola sempre trabalhou com livros, calculadoras, softwares e outras formas de conhecimento mediado. A especificidade da IA generativa está na combinação entre escala, variabilidade e aparência conversacional. Responder a ela requer ampliar as mediações e tornar sua participação visível, não imaginar um sujeito isolado da tecnologia nem aceitar que a opacidade técnica elimine a possibilidade de julgamento.

O caráter teórico, bibliográfico e documental deste estudo delimita seu alcance. A proposta requer investigações empíricas que acompanhem estudantes de diferentes idades e componentes curriculares, examinem formas de avaliação processual e comparem práticas com e sem sistemas generativos. Também é necessário investigar como desigualdades

de infraestrutura, letramento e formação docente afetam a possibilidade de reconhecer e corrigir erros automatizados.


O corpus intencional permitiu articular pesquisas internacionais, estudos brasileiros e documentos curriculares, mas não esgota a produção sobre IA, pensamento computacional ou Educação Matemática. Além disso, sistemas generativos mudam rapidamente, o que limita generalizações sobre ferramentas específicas. A contribuição buscou concentrar-se em operações formativas menos dependentes de versões particulares. Novas pesquisas podem testar a consistência das categorias em diferentes componentes curriculares, investigar como crianças distinguem erro e variabilidade e analisar quais registros de processo oferecem evidências válidas sem aumentar excessivamente a carga de trabalho docente.

A inteligência artificial generativa reforça a necessidade de ensinar pensamento computacional na Educação Básica. Seu principal desafio educacional está menos na obtenção de uma resposta e mais na formação de sujeitos capazes de compreender o problema, contestar o resultado e responder pela solução que apresentam. Avaliar, depurar e reconstruir constituem, nesse contexto, operações de resolução de problemas, autoria e participação crítica em uma sociedade crescentemente mediada por sistemas automatizados.

A agenda resultante é simultaneamente pedagógica e política. Exige materiais que apresentem respostas automatizadas como objetos analisáveis, formação que integre conhecimento disciplinar, pedagógico e computacional, e políticas que combinem conectividade com currículo, proteção de dados e inclusão. Também requer pesquisas longitudinais capazes de verificar se avaliar, depurar e reconstruir em diferentes etapas produz autonomia transferível para novas tecnologias. O desafio não é preparar estudantes para uma plataforma específica, mas assegurar condições intelectuais e sociais para a participação crítica em processos de conhecimento cada vez mais mediados por automação.

REFERÊNCIAS

- BRASIL. Ministério da Educação. Computação: complemento à BNCC. Brasília, DF: Ministério da Educação, 2022. 75 p.
- CARVALHO, Letícia Carla; LUCIANO, Anne Maiara Seidel; SOARES, Rafael Strogenski Silva; KALINKE, Marco Aurélio. IA na educação Matemática: analisando a compreensão de explicações geradas pelo ChatGPT para o sexto ano. *Educitec - Revista de Estudos e Pesquisas sobre Ensino Tecnológico*, Manaus, v. 12, e274026, 2026. DOI: <https://doi.org/10.31417/educitec.v12.2740>.



- CONTI, Telma Aparecida Alves; LIMA, Luciene Mára de; BORGES, Marcos Augusto Francisco. Pensamento Computacional como aporte para discussão e reflexão sobre Inteligência Artificial em sala de aula na Educação Básica Pública. In: WORKSHOP DE COMPARTILHAMENTO E PRODUÇÃO DE ATIVIDADES SOBRE PENSAMENTO COMPUTACIONAL NA EDUCAÇÃO BÁSICA, 1., 2025, Curitiba. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2025. p. 32-46. DOI: <https://doi.org/10.5753/wpcnaeb.2025.16243>.
- GIANNAKOS, Michail *et al.* The promise and challenges of generative AI in education. *Behaviour & Information Technology*, v. 44, n. 11, p. 2518-2544, 2025. DOI: <https://doi.org/10.1080/0144929X.2024.2394886>.
- HSU, Hsiao-Ping. From Programming to Prompting: Developing Computational Thinking through Large Language Model-Based Generative Artificial Intelligence. *TechTrends*, v. 69, p. 485-506, 2025. DOI: <https://doi.org/10.1007/s11528-025-01052-6>.
- IZIDIO, Tállyson E. R.; ALMEIDA, Dyelle H. N. de; MEDEIROS, Igor G.; SILVA, José F. A. da; ALVES FILHO, Sebastião E.; MORAIS, Ceres G. B. Pensamento Computacional na Educação Básica Brasileira: um Panorama Pré e Pós Resolução n.º 1/2022. In: WORKSHOP SOBRE EDUCAÇÃO EM COMPUTAÇÃO, 33., 2025, Maceió. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2025. p. 539-551. DOI: <https://doi.org/10.5753/wei.2025.8319>.
- LIMA, Cleosanice Barbosa; SERRANO, Agostinho. Inteligência Artificial Generativa e ChatGPT: uma investigação sobre seu potencial na Educação. *TransInformação*, Campinas, v. 36, e2410839, 2024. DOI: <https://doi.org/10.1590/2318-0889202436e2410839>.
- LIMA, Taís Ferreira; BAIROS, Gildomiro; FRANCO, Márcia Hãfele Islabão; BERTAGNOLLI, Silvia de Castro; PERES, Andre; OKUYAMA, Fabio Yoshimitsu; NICOLAO, Mariano. Explorando o Pensamento Criativo e Computacional com Aprendizagem Baseada em Problemas: um relato de experiência com ScratchJr. In: SIMPÓSIO BRASILEIRO DE INFORMÁTICA NA EDUCAÇÃO, 35., 2024, Rio de Janeiro. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2024. p. 3246-3254. DOI: <https://doi.org/10.5753/sbie.2024.244856>.
- MELO, Adriana Almeida Sales de; OLIVEIRA JUNIOR, Rodrigo de. Base Nacional Comum Curricular de Computação (BNCC Computação) na Conferência Nacional de Educação (CONAE 2024). *Revista Brasileira de Informática na Educação*, v. 33, p. 672-691, 2025. DOI: <https://doi.org/10.5753/rbie.2025.4642>.
- OLIVEIRA, Saul Barbosa de; ANDRADE, Silvanio de. Proposição de Problemas Matemáticos e Inteligência Artificial Generativa: uma experiência em uma escola pública do Ensino Fundamental. *Educação Matemática em Revista*, Brasília, v. 31, n. 90, p. 1-15, 2026. DOI: <https://doi.org/10.37001/emr.v31i90.4502>.
- RIBEIRO, André Ricardo Antunes; ZATTI, Evandro Alberto; BALBINO, Renata Oliveira; KALINKE, Marco Aurélio. A criação de uma atividade voltada para o ensino de simetria com o uso da inteligência artificial generativa. *Educação Matemática Pesquisa*, São Paulo, v. 26, n. 4, p. 239-263, 2024. DOI: <https://doi.org/10.23925/1983-3156.2024v26i4p239-263>.
- SILVA, Andrey Camurça da; TANAKA FILHO, Mario. Elaboração de itens de Matemática com auxílio de Inteligência Artificial Generativa. *Revista Nova Paideia - Revista Interdisciplinar em Educação e Pesquisa*, v. 7, n. 1, p. 351-366, 2025. DOI: <https://doi.org/10.36732/riep.v7i1.399>.
- WANG, Shan; WANG, Fang; ZHU, Zhen; WANG, Jingxuan; TRAN, Tam; DU, Zhao. Artificial intelligence in education: a systematic literature review. *Expert Systems with Applications*, v. 252, 124167, 2024. DOI: <https://doi.org/10.1016/j.eswa.2024.124167>.