

Capítulo

2

Desmistificando a Caixa Preta: Computação, Física e Dados no Letramento em Inteligência Artificial para Educadores

Cibele Nunes Cabral, Hodara Cristina Nobre Ferreira e Léia Sousa de Sousa

Abstract

Artificial Intelligence is increasingly present in school life through search engines, recommender systems, generative tools, adaptive platforms, and automated assessment practices. However, many teacher education initiatives still approach AI as a set of tools, without discussing its physical infrastructure, data dependence, statistical reasoning, social consequences, and ethical limits. This material presents a didactic proposal for a JAIE short course grounded in the PISA 2029 Media and Artificial Intelligence Literacy framework and in recent AI literacy frameworks for Basic Education. The material is organized as a training handbook for educators, researchers, and professionals working in education, computing, and technologies, with investigation stations, unplugged alternatives, demonstrations using Teachable Machine, PhET simulations, data visualization, and the gamified activity called the AI Trial. The aim is to show that AI is not magic: it is a sociotechnical system constituted by infrastructure, data, algorithms, human decisions, and educational contexts.

Resumo

A Inteligência Artificial está cada vez mais presente na vida escolar por meio de buscadores, sistemas de recomendação, ferramentas generativas, plataformas adaptativas e práticas automatizadas de avaliação. Entretanto, muitas formações docentes ainda tratam a IA como um conjunto de ferramentas, sem discutir sua infraestrutura física, dependência de dados, raciocínio estatístico, consequências sociais e limites éticos. Este material apresenta uma proposta didática de minicurso para a JAIE fundamentada no modelo Media and Artificial Intelligence Literacy do PISA 2029 e em referenciais recentes de letramento em IA para a Educação Básica. O material foi organizado como um caderno de formação para educadores, pesquisadores e profissionais que atuam com educação, computação e

tecnologias, com estações de investigação, alternativas desplugadas, demonstrações com Teachable Machine, simulações PhET, visualização de dados e a dinâmica gamificada Tribunal da IA. O objetivo é mostrar que a IA não é mágica: é um sistema sociotécnico constituído por infraestrutura, dados, algoritmos, decisões humanas e contextos educacionais.

2.1. Introdução

A pergunta que orienta este material formativo é: como apoiar professores, pesquisadores e profissionais da educação a compreenderem a Inteligência Artificial sem reduzi-la a uma lista de ferramentas, a um modismo tecnológico ou a uma “caixa preta” inacessível? A popularização da Inteligência Artificial Generativa levou *chatbots*, geradores de imagem, sistemas de recomendação, plataformas adaptativas e assistentes de escrita para a vida escolar, ampliando dúvidas sobre autoria, avaliação, privacidade, confiabilidade das respostas, reprodução de preconceitos, sustentabilidade e desigualdades de acesso.

O minicurso propõe um percurso teórico-prático, interdisciplinar e de reduzida barreira tecnológica. A IA é abordada como sistema sociotécnico, isto é, como uma cadeia formada por infraestrutura física, dados, algoritmos, interfaces, decisões humanas e contextos educacionais. Essa perspectiva evita tratar a IA apenas como ferramenta ou apenas como tema ético abstrato: a Física evidencia dispositivos, redes, servidores, energia, refrigeração e *data centers*; a Computação explica modelos, padrões, treinamento, erro e generalização; e a Matemática/Dados apoia a análise de amostras, variáveis, *proxies*, correlações, vieses e visualizações.

A proposta ancora-se no domínio *Media and Artificial Intelligence Literacy* (MAIL) do PISA 2029, apresentado em versão preliminar como uma das inovações previstas para a avaliação internacional de 2029 (OECD, 2026). O MAIL busca avaliar se estudantes conseguem compreender, usar, analisar, criar e agir responsavelmente em ambientes digitais mediados por mídias e sistemas de IA. Ao integrar letramento midiático e letramento em IA, esse referencial desloca a formação do simples uso de ferramentas para perguntas críticas: quem produziu esta informação? que evidências sustentam esta resposta? que papel a plataforma ou o algoritmo teve no que aparece para mim? que riscos existem para privacidade, autoria, participação, inclusão e justiça?

O material também dialoga com o *AI Literacy Framework for Primary and Secondary Education*, publicado pela OECD e pela União Europeia, que organiza o letramento em IA em dimensões como engajar-se com IA, criar com IA, gerenciar IA e moldar IA (OECD & European Union, 2026). No contexto brasileiro, relaciona-se à Base Nacional Comum Curricular (BNCC), ao complemento Computação da BNCC (Brasil. Ministério da Educação, 2018, 2022) e a diretrizes recentes de educação digital e midiática (Brasil. Conselho Nacional de Educação, 2025; Brasil. Ministério da Educação, 2025). A Nota Técnica do Instituto Palavra Aberta sobre MAIL é mobilizada como documento de mediação pública produzido por uma organização brasileira dedicada à educação midiática, ajudando a traduzir a relevância do tema para o debate nacional (Ochs, 2026).

Assim, o minicurso parte de um pressuposto central: *a escola brasileira não precisa esperar que a IA se torne uma disciplina isolada para começar a trabalhar esse tema.*

A IA pode ser integrada às áreas já existentes, desde que professores tenham repertório conceitual, experiências formativas concretas e materiais didáticos adaptáveis a diferentes contextos educacionais.

2.1.1. Público-alvo e objetivos de aprendizagem

O minicurso foi planejado para uma audiência heterogênea: docentes da Educação Básica e Superior, profissionais que atuam em formação docente, pesquisadores das áreas de Educação, Computação, Informática na Educação e Tecnologias, bem como participantes interessados em compreender a IA para além do uso instrumental de ferramentas. Ao final, espera-se que os participantes sejam capazes de:

1. explicar, em linguagem acessível, por que a IA deve ser compreendida como um sistema sociotécnico, e não como mágica, consciência artificial ou ferramenta neutra;
2. reconhecer relações entre IA, infraestrutura física, energia, redes, dispositivos, data centers e sustentabilidade;
3. descrever o ciclo básico de uma atividade de aprendizagem de máquina, incluindo coleta de exemplos, treinamento, teste, erro, acurácia e viés de coleta;
4. analisar criticamente dados educacionais, identificando amostras incompletas, variáveis, *proxies*, correlações indevidas e riscos de interpretação;
5. aplicar critérios éticos para avaliar usos pedagógicos de IA, considerando autoria, privacidade, inclusão, transparência, revisão humana e possibilidade de contestação;
6. elaborar um plano de aula ou roteiro de oficina replicável, com alternativa desplugada e adequação ao contexto de atuação.

2.1.2. Como utilizar este material no minicurso

Este material foi escrito como caderno de formação para apoiar a participação no minicurso e a posterior replicação das atividades em contextos educacionais. Por isso, combina fundamentação teórica, roteiros de demonstração, atividades mão na massa, alternativas de baixa conectividade, rubricas e exemplos de transposição didática. Ao longo do percurso, o participante encontrará:

- uma síntese didática do modelo MAIL e de sua relação com letramento em IA, educação midiática, pensamento computacional e letramento em dados;
- quatro Estações de Investigação, cada uma com objetivos, materiais, passo a passo, perguntas orientadoras, erros comuns e alternativas desplugadas;
- uma dinâmica gamificada, intitulada *Tribunal da IA*, para analisar um caso fictício de uso de IA preditiva em uma rede escolar;
- exemplos de demonstrações com Google Teachable Machine, simuladores PhET, RAW-Graphs, Datawrapper, Flourish e ferramentas de IA generativa;
- modelos de rubrica, checklist de uso ético e roteiro de plano de aula para que os participantes saiam do minicurso com um produto replicável.

Ao longo das estações, as pessoas participantes serão convidadas a observar essas camadas sociotécnicas em situações concretas de ensino, análise de dados, uso de ferramentas e tomada de decisão educacional. Em vez de apresentar a IA como uma ferramenta única, o minicurso a decompõe em infraestrutura física, dados, modelos, interfaces, usos

pedagógicos e impactos sociais. Essa organização ajuda os participantes a compreenderem que toda resposta produzida por IA depende de uma cadeia de elementos interdependentes.

2.2. Fundamentação: do letramento midiático ao letramento em IA

O letramento midiático historicamente envolve acessar, analisar, avaliar, criar e participar em ambientes de mídia, considerando autoria, propósito, público, linguagem, representação e credibilidade (Hobbs, 2020; National Association for Media Literacy Education, 2023). O avanço da IA altera esse cenário porque muitos conteúdos que circulam nas plataformas são produzidos, filtrados, recomendados, resumidos ou reorganizados por sistemas automatizados. O desafio aqui é encontrar respostas para questões como: que dados alimentaram esta recomendação? Que critérios de ranqueamento foram usados? Como a plataforma personalizou o que aparece para mim? Que padrões históricos foram aprendidos pelo sistema?

O PISA 2029 propõe o MAIL justamente para integrar essas duas dimensões. O próprio documento preliminar do PISA destaca a interdependência entre letramento midiático e letramento em IA: sem compreender IA, o letramento midiático corre o risco de não perceber como algoritmos geram, filtram e amplificam conteúdos; sem letramento midiático, o letramento em IA pode ficar excessivamente técnico e desconectado de narrativas, representações, valores e poder (OECD, 2026).

O modelo MAIL possui cinco competências. No minicurso, cada competência é traduzida para perguntas simples que podem orientar uma aula, uma oficina ou uma discussão com estudantes. A Tabela 2.1 sintetiza essa tradução.

Tabela 2.1. Competências MAIL traduzidas em perguntas pedagógicas.

Competência MAIL	Perguntas para a sala de aula
Refletir e agir ética e responsavelmente	Que consequências esta ação digital pode ter para mim, para outras pessoas e para a comunidade? Há privacidade, segurança, respeito, inclusão e sustentabilidade?
Acessar e usar	Como localizar, consultar, organizar e usar informações, mídias e ferramentas de IA sem aceitar automaticamente as configurações da plataforma?
Analisar e avaliar	Quem ou o que produziu esta mensagem? Que evidências sustentam a resposta? Há erro, viés, interesse comercial, conteúdo sintético ou omissão relevante?
Participar e colaborar	Como interagir com pessoas e sistemas de IA de modo respeitoso, transparente e responsável? Como colaborar sem terceirizar a aprendizagem?
Criar	Como produzir mensagens, dados, imagens, modelos ou soluções com IA mantendo autoria humana, finalidade pedagógica, revisão crítica e responsabilidade?

Essa matriz ajuda a deslocar a discussão da pergunta restrita “pode ou não pode usar IA?” para perguntas mais ricas: para quê usar? com que dados? com que limites? quem revisa? quem é afetado? o que se aprende nesse processo? Essa mudança é coerente com a orientação da UNESCO de tratar IA na educação a partir de uma perspectiva centrada no humano, com atenção à ética, à pedagogia, à inclusão, à privacidade, à agência docente e ao desenvolvimento profissional (Miao & Cukurova, 2024; Miao & Holmes, 2023).

Para orientar as atividades do minicurso, este material trabalha com quatro ideias fundamentais:

1. **IA não é humana.** Sistemas de IA geram saídas com base em procedimentos computacionais, dados e inferências estatísticas. Podem produzir respostas úteis, mas não possuem intenção, consciência ou compreensão humana (Bender *et al.*, 2021; Russell & Norvig, 2022).
2. **IA aprende padrões, não verdades.** Modelos ajustam parâmetros a partir de exemplos. Se os exemplos são incompletos, enviesados ou pouco representativos, os resultados podem reproduzir ou ampliar desigualdades (Barocas *et al.*, 2023; Buolamwini & Gebu, 2018).
3. **IA depende de infraestrutura.** O funcionamento de modelos envolve dispositivos, redes, servidores, energia, água, minerais, refrigeração e descarte eletrônico. A sustentabilidade precisa fazer parte da discussão escolar (Luccioni *et al.*, 2024; Strubell *et al.*, 2019).
4. **IA exige responsabilidade humana.** Decisões sobre adoção, avaliação, autoria, privacidade, explicação e contestação devem permanecer sob supervisão humana, especialmente em contextos educacionais (Miao & Cukurova, 2024; Miao & Holmes, 2023).

2.2.1. Relações com Computação, Física e Matemática/Dados

A proposta é interdisciplinar porque cada área revela uma parte diferente da caixa preta. A Computação explicita algoritmos, dados, classificação, generalização, erro e pensamento computacional. A Física revela energia, calor, eletricidade, sensores, redes e materialidade da nuvem. A Matemática e os Dados permitem analisar amostras, proporções, probabilidade, correlação, visualização e viés. A Tabela 2.2 apresenta essa articulação.

Tabela 2.2. Articulação interdisciplinar do minicurso.

Área	Contribuição para desmistificar a IA	Exemplo didático
Física	Mostra que a IA depende de infraestrutura material, energia, transmissão de dados, aquecimento, refrigeração e dispositivos.	Estimar o consumo energético de uma sequência de usos de IA e discutir alternativas mais sustentáveis.
Computação	Mostra que modelos aprendem padrões por meio de dados, parâmetros, regras de treinamento, teste e generalização.	Treinar um classificador simples no Teachable Machine e testar como a qualidade dos exemplos afeta o resultado.
Matemática/Dados	Mostra que decisões automatizadas dependem de amostras, categorias, correlação, probabilidade e visualização.	Analisar uma base sintética de risco de evasão e identificar proxies sociais, lacunas e vieses.
Educação Midiática	Mostra que mensagens e recomendações são produzidas para públicos, propósitos e contextos específicos.	Comparar uma notícia, um resumo gerado por IA e uma postagem de rede social sobre o mesmo tema.

2.2.2. IA como sistema sociotécnico

Este material trata a Inteligência Artificial como um sistema sociotécnico, isto é, como uma integração indissociável entre componentes técnicos, como infraestrutura, dados, algoritmos e modelos, e componentes sociais, como decisões humanas, políticas institucionais, relações de poder, contextos culturais e práticas educacionais. Um sistema de IA

não produz efeitos apenas porque executa cálculos estatísticos. Ele produz efeitos porque pessoas e instituições escolhem quais dados coletar, quais variáveis registrar, quais limites definir, como comunicar resultados e como agir a partir deles.

Essa perspectiva dialoga com o eixo Cultura Digital da BNCC Computação, que situa a reflexão sobre impactos éticos, sociais e ambientais das tecnologias digitais como parte constitutiva do letramento computacional (Brasil. Ministério da Educação, 2022). Dialoga também com a competência MAIL de refletir e agir de forma ética e responsável, que pressupõe reconhecer que consequências digitais atravessam pessoas, comunidades e instituições (OECD, 2026).

Adotar essa moldura sociotécnica tem uma implicação pedagógica direta para a formação de professores. Se a IA fosse compreendida apenas como artefato técnico, a formação docente se restringiria ao funcionamento de ferramentas. Se fosse compreendida apenas como fenômeno social, correria o risco de discutir ética sem base técnica suficiente para identificar em que ponto da cadeia de funcionamento do sistema as decisões humanas operam. O minicurso articula as quatro estações justamente para evitar essa dissociação: a Estação 1 evidencia a camada material; as Estações 2 e 3 evidenciam as camadas algorítmica e de dados; e a Estação 4 evidencia que toda essa cadeia técnica é atravessada por decisões humanas passíveis de responsabilização. O Tribunal da IA retoma esse conceito ao pedir que os participantes identifiquem em que elo da cadeia sociotécnica uma falha ocorreu e quem, entre pessoas e instituições, deveria responder por ela.

2.3. Desenho pedagógico do minicurso

O minicurso foi desenhado para três horas, podendo ser ampliado para quatro horas. A organização prioriza uma experiência formativa que seja compreensível para participantes de diferentes áreas e, ao mesmo tempo, suficientemente estruturada para ser replicada em cursos, escolas e ações de formação docente. Ele combina exposição dialogada, aprendizagem ativa, estações de investigação, trabalho colaborativo, análise de caso, produção de material didático e avaliação formativa. Essa escolha é coerente com a literatura sobre aprendizagem ativa, que mostra ganhos quando os participantes deixam de ser ouvintes passivos e passam a resolver problemas, discutir evidências, testar hipóteses e explicar decisões (Hmelo-Silver, 2004; Kolb, 1984; Prince, 2004).

A Figura 2.1 apresenta o fluxo geral. A abertura cria uma pergunta comum: “por que a IA não é mágica?”. Em seguida, os participantes passam pelas estações. Depois, aplicam o que aprenderam no Tribunal da IA. O fechamento transforma a experiência em plano de aula.

Para tanto, pretende-se seguir a programação descrita da Tabela 2.3:

2.3.1. Papéis da equipe formadora

O minicurso será conduzido pelas três autoras, em papéis complementares. *Hodara Cristina Nobre Ferreira* conduzirá o eixo de Física, com foco em materialidade da IA, energia, sensores, infraestrutura e sustentabilidade. *Cibele Nunes Cabral* conduzirá o eixo de Computação e formação docente, com foco em aprendizagem de máquina sem programação, pensamento computacional e transposição para a Educação Básica. *Léia*




Figura 2.1. Fluxo didático do minicurso.

Tabela 2.3. Cronograma para uma versão de 3 horas.

Tempo	Momento	Estratégia
15 min	Abertura	Pergunta disparadora, apresentação do MAIL e contrato ético de uso das ferramentas.
25 min	Estação 1: Física/infraestrutura	Mapa físico da IA, energia, conectividade e sustentabilidade.
30 min	Estação 2: Computação/modelos	Treinamento de classificador simples ou simulação desplugada.
30 min	Estação 3: Dados/evidência	Visualização crítica de base sintética e discussão de vieses.
20 min	Estação 4: Ética e autoria	Checklist de uso responsável e análise de resposta gerada por IA.
45 min	Tribunal da IA	Investigação de evidências, parecer, veredito e recomendações.
25 min	Transposição didática	Produção de plano de aula ou oficina.
10 min	Síntese	Socialização dos produtos e avaliação formativa.

Sousa de Sousa conduzirá o eixo de Dados, evidência social e tecnologias sociais, com foco em viés algorítmico, visualização crítica e educação midiática.

2.4. Abertura: “IA não é mágica”

A abertura do minicurso tem uma função pedagógica importante: identificar concepções prévias dos participantes. Em formações docentes, é comum que a IA apareça em dois extremos. Em um extremo, é vista como solução automática para planejamento, correção, tutoria e personalização. Em outro, é vista como ameaça absoluta à autoria, à aprendizagem e ao trabalho docente. O minicurso evita os dois extremos. A IA pode apoiar práticas pedagógicas quando há finalidade clara, revisão humana e cuidado ético; também pode produzir erros, vieses, dependência cognitiva, violações de privacidade e exclusões quando adotada sem critério (Miao & Holmes, 2023; OECD & European Union, 2026).

2.4.1. Dinâmica inicial: três cartões

Cada participante recebe três cartões ou responde em formulário digital: *i) Cartão 1:* uma coisa que eu já fiz com IA; *ii) Cartão 2:* uma preocupação que tenho sobre IA na educação; e, *iii) Cartão 3:* uma pergunta que meus estudantes fariam sobre IA.

As respostas são organizadas no quadro em três colunas: uso, medo e curiosidade. A equipe formadora destaca que todas as respostas serão revisitadas ao longo das estações. Essa dinâmica cria pertencimento e evidencia que o minicurso parte da experiência docente.

Demonstração no minicurso. A formadora projeta uma resposta gerada por IA para a pergunta: “Explique, em linguagem simples, o que é inteligência artificial”. Os participantes analisam a resposta usando três perguntas: a explicação diferencia IA de inteligência humana? menciona dados e probabilidade? apresenta limites ou riscos? Em seguida, a mesma pergunta é reformulada: “Explique IA para professores da Educação Básica, destacando infraestrutura física, dados, modelos estatísticos, vieses e limites éticos”. A comparação mostra que o *prompt* direciona a resposta, mas não elimina a necessidade de revisão crítica.

2.5. Estação 1: a Física por trás da IA

A primeira estação tem como objetivo tornar visível a materialidade da IA. A expressão “nuvem” costuma sugerir algo leve, invisível e sem lugar. Na prática, a nuvem é uma rede de data centers, cabos, roteadores, dispositivos, sistemas de refrigeração e fluxos contínuos de energia. O letramento em IA precisa incluir essa dimensão porque decisões pedagógicas também têm impactos ambientais e infraestruturais. O *framework AILit* inclui explicitamente sustentabilidade e impacto ambiental entre os conhecimentos e atitudes necessários ao letramento em IA (OECD & European Union, 2026). Estudos recentes também indicam que a implantação de sistemas generativos pode ter custos energéticos relevantes, especialmente quando se compara modelos multiuso e generativos com sistemas específicos para uma tarefa (Luccioni *et al.*, 2024; Strubell *et al.*, 2019).

2.5.1. Conceitos físicos mobilizados

A estação trabalha quatro conceitos fundamentais:

1. **Potência e energia.** A potência indica a taxa de consumo de energia. A energia consumida por um dispositivo pode ser estimada por $E = P \times t$, em que E é energia, P é potência e t é tempo.
2. **Efeito Joule e aquecimento.** Dispositivos eletrônicos dissipam parte da energia em forma de calor. Quanto maior a demanda computacional, maior a necessidade de alimentação elétrica e refrigeração.
3. **Transmissão de dados.** Uma interação com IA envolve envio de dados de entrada, processamento remoto ou local e retorno de uma saída. Isso depende de infraestrutura de rede.
4. **Pegada ambiental.** O impacto depende de energia, matriz elétrica, equipamentos, água para refrigeração, minerais e descarte eletrônico. Não há um número único para todo uso de IA; há contextos, modelos e infraestruturas diferentes.

2.5.2. Demonstração 1: onde fica a nuvem?

Demonstração no minicurso. A formadora inicia a atividade com uma pergunta simples: “quando fazemos uma pergunta a um chatbot, para onde essa pergunta vai?”. Em seguida,

pede que os participantes desenhem, em dois minutos, o caminho percorrido por uma pergunta feita a uma ferramenta de IA generativa. A intenção é identificar concepções iniciais sobre a ideia de “nuvem” e tornar visível que a interação com IA depende de uma infraestrutura física. Depois, a formadora projeta ou distribui cartões com os elementos: celular, tela do usuário, rede *Wi-Fi*, roteador, provedor de Internet, cabos de fibra óptica, data center, servidor, processador, sistema de refrigeração, banco de dados, modelo e resposta. Em grupos, os participantes reorganizam os cartões em uma cadeia física, representando o caminho percorrido pela informação desde o envio do prompt até o retorno da resposta ao usuário.

A discussão deve evitar uma descrição técnica excessiva. O objetivo não é transformar o minicurso em uma aula avançada de redes ou arquitetura de computadores, mas ajudar professores a explicarem aos estudantes que a “nuvem” não é algo abstrato, invisível ou sem localização material. Quando uma pessoa escreve um prompt, sua pergunta não desaparece na nuvem: ela percorre dispositivos, redes, cabos, servidores, processadores, sistemas de armazenamento e sistemas de refrigeração, consumindo energia e mobilizando recursos físicos até retornar como uma resposta calculada por sistemas computacionais.

Essa demonstração permite conectar a Estação 1 a conteúdos de Física presentes na Educação Básica. Cada elemento da cadeia da IA pode ser relacionado a conceitos físicos que os estudantes já estudam ou podem estudar de forma contextualizada. O celular envolve circuitos elétricos, eletrônica e transformação de energia. A rede Wi-Fi envolve ondas eletromagnéticas, frequência e comunicação sem fio. Os cabos de fibra óptica permitem discutir óptica, propagação da luz e reflexão interna total. Servidores e processadores mobilizam eletricidade, eletrônica, semicondutores, transistores e Física do Estado Sólido. Já os sistemas de refrigeração e os data centers permitem abordar termodinâmica, transferência de calor, potência elétrica, eficiência energética e sustentabilidade.

Tabela 2.4. A Física por trás de cada etapa da IA.

Etapa da infraestrutura	Conceitos de Física	Possibilidades de abordagem no Ensino de Física
Celular	Circuitos elétricos, eletrônica e transformação de energia	Funcionamento de circuitos, potência elétrica e consumo energético.
Rede Wi-Fi	Ondas eletromagnéticas	Propagação de ondas, frequência e comunicação sem fio.
Cabos de fibra óptica	Óptica e reflexão interna total	Propagação da luz e transmissão de dados.
Servidor	Eletricidade e eletrônica	Alimentação elétrica e funcionamento de sistemas computacionais.
CPU/GPU	Semicondutores e Física do Estado Sólido	Silício, transistores e processamento eletrônico.
Sistema de refrigeração	Termodinâmica e transferência de calor	Dissipação térmica, convecção e eficiência térmica.
Data center	Potência elétrica, eficiência energética e sustentabilidade	Consumo de energia, impactos ambientais e eficiência energética.

A Tabela 2.4 evidencia que a infraestrutura da Inteligência Artificial pode ser utilizada como contexto para o ensino de diversos conteúdos de Física. Em vez de tratar eletricidade, ondas, óptica, termodinâmica e sustentabilidade como temas isolados, a estação propõe integrá-los a uma tecnologia presente no cotidiano dos estudantes. Essa

abordagem favorece a contextualização, a aprendizagem significativa e a compreensão crítica de que todo sistema digital depende de recursos materiais.

Durante a mediação, a formadora conduzirá a discussão com perguntas como: que partes dessa cadeia dependem de energia elétrica? Onde ocorre transmissão de dados? Onde há produção de calor? Por que um data center precisa de refrigeração? O que acontece quando uma escola ou comunidade não possui boa conectividade? Essas perguntas ajudam a aproximar o conceito de IA da realidade física, ambiental e territorial dos estudantes.

A ideia é entender o relacionamento entre a infraestrutura utilizada pela IA e os conceitos das aulas de Física. A Figura 2.2 mostra à esquerda (Geração e Processamento) que o data center engloba o maquinário pesado, através do qual é possível discutir Termodinâmica (sistemas de refrigeração visíveis) e a Física do Estado Sólido rodando nas CPUs e GPUs. No centro, os cabos subterrâneos ilustram as fibras ópticas. Visualizar a luz presa no cabo é um ótimo gancho para introduzir a Óptica Geométrica (reflexão interna total). À direita, o roteador emitindo o sinal invisível materializa o estudo do eletromagnetismo (as ondas eletromagnéticas do Wi-Fi), culminando no notebook ou celular, onde fechamos o ciclo falando sobre circuitos elétricos e o consumo de bateria na palma da mão.




Figura 2.2. Relação entre infraestrutura de IA e os conceitos de Física

Ao final da demonstração, espera-se que os participantes consigam formular uma explicação simples para uso em sala de aula: “a IA não mora apenas na tela do computador; ela depende de celulares, redes, cabos, servidores, processadores, bancos de dados, energia elétrica e sistemas de refrigeração. Por isso, usar IA também envolve infraestrutura, consumo de recursos e decisões sobre sustentabilidade”.

2.5.3. Demonstração 2: estimativa simplificada de energia

A estação utiliza uma conta simples, não para produzir uma medição exata, mas para desenvolver raciocínio físico. A formadora apresenta a equação:

$$E = P \times t \quad (1)$$

Em seguida, propõe um cenário hipotético: uma escola realiza uma atividade em que 100 estudantes usam uma ferramenta de IA durante 20 minutos. O consumo total depende de dispositivos, rede e servidores externos, mas a turma pode estimar apenas o consumo local dos computadores. Se cada computador consome, em média, 60 W durante 20 minutos, a energia local estimada por computador é:

$$E = 60\text{ W} \times \frac{20}{60}\text{ h} = 20\text{ Wh} = 0,02\text{ kWh} \quad (2)$$

Para 50 computadores em duplas:

$$E_{total} = 50 \times 0,02 = 1\text{ kWh} \quad (3)$$

A formadora explica que essa conta não inclui servidores remotos, refrigeração do data center nem transmissão de dados. Justamente por isso, ela abre uma pergunta importante: o que fica invisível quando a escola só vê a tela?

2.5.4. Demonstração 3: PhET e relações entre energia, calor e sistemas digitais

A ferramenta sugerida é o PhET, especialmente simulações de energia, eletricidade e circuitos. O PhET oferece simulações interativas de ciências e matemática baseadas em pesquisa educacional, com ambiente intuitivo de exploração (PhET Interactive Simulations, 2026). A Figura 2.3 mostra o simulador *Circuit Construction Kit: AC*, do PhET, usado para montar e observar circuitos elétricos com corrente alternada. Na tela há um circuito fechado formado por fios, uma fonte de tensão alternada, duas lâmpadas, instrumentos de medição e gráficos. As bolinhas azuis no fio representam o movimento dos elétrons. Esse experimento serve para mostrar que toda infraestrutura digital depende de eletricidade. Mesmo quando falamos de “nuvem”, “IA” ou “data center”, há circuitos, corrente elétrica, tensão, potência, aquecimento e necessidade de refrigeração. No minicurso, a formadora utilizará uma simulação de circuito simples para discutir corrente, resistência, potência e dissipação térmica, ou uma simulação de formas de energia para discutir transformação de energia elétrica em calor.




Figura 2.3. Simulação PhET de circuito elétrico. Fonte: PhET Interactive Simulations.

Atividade prática. Em duplas, os participantes manipulam uma simulação de circuito e respondem: o que acontece quando aumenta a resistência? O que acontece quando aumenta a tensão? Como isso se relaciona ao aquecimento de dispositivos? Depois, cada dupla escreve uma analogia curta para estudantes: “um data center precisa de energia e refrigeração porque...”.

Transposição didática. Em escolas sem Internet, a atividade pode ser realizada com cartões representando fonte, fios, resistência, dissipação de calor e ventilação. Os estudantes simulam o caminho da energia com barbante ou setas no quadro. O foco não é calcular com precisão, mas compreender que a IA depende de sistemas físicos e que toda escolha tecnológica tem custo.

2.6. Estação 2: a lógica da caixa preta

A segunda estação trabalha aprendizagem de máquina de forma visual e acessível. O objetivo é desfazer a ideia de que a máquina “entende” objetos, textos ou imagens como uma pessoa. Um modelo de aprendizagem de máquina ajusta padrões a partir de exemplos. Se os exemplos são bons para uma tarefa, o modelo pode generalizar razoavelmente. Se os exemplos são pobres, enviesados ou insuficientes, o modelo erra de forma previsível. Essa compreensão é um dos núcleos do letramento em IA (Long & Magerko, 2020; Ng *et al.*, 2021; Touretzky *et al.*, 2019).

Os conceitos mobilizados nesta estação dialogam diretamente com o Pensamento Computacional, eixo estruturante da BNCC (Brasil. Ministério da Educação, 2022). Ao treinar um classificador simples, o participante exercita, na prática e antes de qualquer nomeação técnica, os quatro pilares do Pensamento Computacional: a decomposição, ao separar o problema em classes distintas; o reconhecimento de padrões, ao identificar o que diferencia uma classe da outra; a abstração, ao ignorar detalhes irrelevantes da imagem e focar na característica que importa; e os algoritmos, ao observar o ciclo de treinar, testar e corrigir que estrutura toda a atividade. Essa aproximação evita que o letramento em IA

seja tratado como um conteúdo à parte, desconectado do que a Educação Básica brasileira já prevê para o ensino de Computação.

2.6.1. Conceitos computacionais mobilizados

A estação trabalha os seguintes conceitos:

- **Classe:** categoria que o modelo deve reconhecer, como “copo”, “caneta”, “livro”.
- **Exemplo de treinamento:** dado usado para ensinar o modelo.
- **Teste:** dado novo usado para verificar se o modelo generaliza.
- **Acurácia:** proporção de acertos em relação ao total de testes.
- **Erro:** diferença entre saída prevista e saída esperada.
- **Sobreajuste:** quando o modelo aprende detalhes dos exemplos de treino, mas não generaliza bem.
- **Viés de coleta:** quando os exemplos não representam adequadamente a diversidade do mundo real.

2.6.2. Demonstração com *Google Teachable Machine*

O *Google Teachable Machine* é uma ferramenta *Web* que permite criar modelos de aprendizagem de máquina de modo rápido e acessível, sem programação (Google, 2026). Para o minicurso, será usado o projeto de imagem. A demonstração será preparada previamente para evitar perda de tempo com câmera, permissões ou instabilidade de rede.

A Figura 2.4 mostra, de forma visual, como o *Teachable Machine funciona*¹. A ferramenta recebe exemplos, aprende padrões e depois tenta classificar um novo caso. À esquerda está a entrada (*input*), onde a pessoa aparece na câmera fazendo um gesto. Esse é o novo exemplo que a ferramenta vai tentar reconhecer. No centro está a parte de aprendizagem (*learning*). A ferramenta foi treinada com várias imagens de exemplo, separadas em classes. Na imagem aparecem três classes: verde, roxa e laranja. Cada classe tem uma quantidade de exemplos: 30, 45 e 50 imagens. Depois de treinar, o modelo compara a imagem da câmera com aquilo que aprendeu. Ao lado de cada classe aparece a confiança (*confidence*), que indica o quanto o modelo acredita que a imagem atual pertence àquela classe. Na imagem, a classe roxa aparece com 99% de confiança, ou seja, o modelo avaliou que o gesto da pessoa se parece muito com os exemplos usados para treinar a classe roxa. À direita está a saída (*output*). A ferramenta transforma a previsão do modelo em uma resposta. Nesse exemplo, a saída é um GIF de um cachorro girando. Isso mostra que o modelo pode ser usado para acionar alguma ação: mostrar uma imagem, tocar um som, exibir uma mensagem ou controlar outro recurso.

¹Ferramenta disponível em <https://teachablemachine.withgoogle.com/>.




Figura 2.4. Demonstração de uso do Google Teachable Machine. Fonte: Google Teachable Machine.

Demonstração no minicurso. A formadora acessa o *Teachable Machine*, escolhe *Image Project*, cria duas classes, por exemplo “objeto A” e “objeto B”, coleta cerca de 30 imagens por classe, treina o modelo e testa com novos objetos. Em seguida, provoca um erro: treina a classe A sempre com fundo claro e a classe B sempre com fundo escuro. Quando testa um objeto da classe A em fundo escuro, o modelo pode se confundir. A discussão mostra que o modelo pode aprender pistas indesejadas, como iluminação, fundo, posição ou cor, em vez da característica relevante.

A Tabela 2.5 sintetiza a relação entre cada conceito e o momento em que ele se torna visível durante a demonstração com o *Teachable Machine*, funcionando como roteiro de leitura para quem acompanha a atividade pela primeira vez.

Tabela 2.5. Conceitos computacionais e sua correspondência na demonstração prática.

Etapas na demonstração	Conceito mobilizado	Pergunta de mediação
Criar as categorias que o modelo vai aprender	Classe	O que estou pedindo para a máquina distinguir?
Coletar as imagens de cada categoria	Exemplo de treinamento	Esses exemplos representam a diversidade real da categoria?
Apresentar um objeto novo à câmera	Teste	Esse caso é diferente o suficiente dos exemplos de treino para valer como teste?
Comparar acertos e erros do modelo	Acurácia e erro	O modelo generalizou o padrão ou apenas decorou os exemplos?
Testar em condição diferente da treinada, como fundo, luz ou ângulo	Sobreajuste e viés de coleta	Que pista indesejada o modelo pode ter aprendido no lugar da característica relevante?

A Figura 2.5 mostra o fluxo simplificado de uma atividade de classificação: coletar exemplos, treinar o modelo, testar com novos dados, analisar erros e melhorar a base. Esse ciclo se repete em qualquer projeto de aprendizagem de máquina, independentemente da complexidade da tarefa, e é o mesmo raciocínio que orienta a leitura da Tabela 2.5.




Figura 2.5. Ciclo didático de aprendizagem de máquina usado na estação de Computação.

2.6.3. Acurácia e matriz de confusão em linguagem simples

Após o teste, os participantes registram acertos e erros em uma matriz simples. A Tabela 2.6 apresenta um exemplo com duas classes.

Tabela 2.6. Exemplo de matriz de confusão para um classificador com duas classes.

	Previsto: Classe A	Previsto: Classe B
Real: Classe A	8	2
Real: Classe B	1	9

Nesse exemplo, o modelo acertou 17 de 20 testes. A acurácia é:

$$\text{Acurácia} = \frac{\text{número de acertos}}{\text{total de testes}} = \frac{17}{20} = 0,85 = 85\%. \quad (4)$$

A formadora irá enfatizar que acurácia não é sinônimo de justiça. Um modelo pode ter boa acurácia geral e, ainda assim, errar muito para um grupo específico. Essa distinção prepara a Estação 3 e o Tribunal da IA. Ao final desta etapa, espera-se que os participantes consigam explicar a um colega, em uma frase: “um modelo pode acertar 85% das vezes e, ainda assim, errar sistematicamente com um grupo específico de casos; por isso, acurácia alta não significa decisão justa”.

2.6.4. Versão desplugada: classificadores humanos e regras invisíveis

Atividade prática. Cada grupo recebe 20 cartões com desenhos de objetos. Dez cartões são rotulados como “classe 1” e dez como “classe 2”. O grupo deve inferir a regra de classificação olhando exemplos. A regra pode ser simples, como “objetos com linhas curvas” versus “objetos com linhas retas”, mas alguns cartões são ambíguos. Depois, a formadora revela que a regra usada pelo grupo nem sempre coincide com a regra original. A atividade mostra que aprender padrões depende dos exemplos disponíveis e que diferentes critérios podem produzir classificações diferentes, exatamente o mesmo princípio observado na demonstração com o *Teachable Machine*, mas sem depender de nenhum dispositivo digital.

Transposição didática. A atividade desplugada pode ser usada em turmas sem laboratório para ensinar classificação, padrão, abstração, erro e generalização. Em turmas de anos iniciais, os cartões podem ser figuras geométricas. Em turmas de Ensino Médio, podem ser notícias, imagens, textos curtos ou dados ambientais.

2.7. Estação 3: dados e evidência social

A terceira estação parte de uma pergunta central para sistemas de IA aplicados à educação: quais dados foram usados e o que esses dados deixam de fora? Decisões automatizadas dependem de registros históricos que podem conter ausências, desigualdades, categorias mal definidas, *proxies* sociais e interpretações equivocadas. Por isso, modelos treinados com dados enviesados ou incompletos podem reproduzir desigualdades já existentes (Barocas *et al.*, 2023; Buolamwini & Gebru, 2018; Noble, 2018).

A estação trabalha cinco conceitos articulados: **amostra**, que indica quem entrou ou ficou fora da base; **variável**, que corresponde ao que foi registrado, como frequência, nota, bairro ou acesso à Internet; **proxy**, quando uma variável substitui indiretamente outra, como usar participação em plataforma online para inferir engajamento; **correlação**, que indica associação entre variáveis, mas não prova causa; e **visualização**, que organiza padrões em gráficos, tabelas ou matrizes, mas também seleciona, simplifica e enquadra a realidade.

Esses conceitos serão analisados em cadeia. Uma amostra incompleta limita o que pode ser interpretado; variáveis mal escolhidas podem funcionar como *proxies* problemáticos; correlações podem gerar conclusões apressadas; e visualizações podem tornar desigualdades mais visíveis ou ocultar ausências, contextos e causas sociais. Assim, a estação mostra que dados educacionais devem servir como ponto de partida para perguntas críticas, e não como justificativa automática para decisões sobre estudantes.

2.7.1. Base sintética para análise

A Tabela 2.7 apresenta uma versão reduzida de uma base sintética. Ela não representa estudantes reais. Foi construída apenas para fins didáticos. A amostra reúne apenas os estudantes registrados pelo sistema. As variáveis disponíveis incluem frequência, território, acesso à Internet e uso da plataforma. O uso da plataforma pode funcionar como *proxy* de engajamento, mas essa interpretação é perigosa, pois o mesmo dado pode refletir desigualdade de acesso. Ao comparar território, conectividade e uso da plataforma, pode surgir uma correlação entre estudantes da zona rural e baixo acesso ao ambiente online. Entretanto, essa correlação não autoriza concluir que esses estudantes têm menor interesse escolar. Uma visualização, como um gráfico de barras ou uma matriz de calor, pode ajudar a perceber o padrão, mas a interpretação crítica precisa considerar o que não aparece nos dados: transporte, trabalho familiar, distância da escola, disponibilidade de dispositivos e qualidade da conexão.

A pergunta não é “qual estudante deve ser punido?”. A pergunta é: que tipo de decisão seria injusta se a escola usasse apenas esses dados? Por exemplo, um sistema que trate baixo uso da plataforma como sinal de desinteresse pode classificar injustamente estudantes sem Internet em casa. Nesse caso, a variável “uso da plataforma” não mede apenas engajamento. Ela também mede acesso, dispositivo, tempo, conectividade, renda e organização familiar.

Tabela 2.7. Exemplo reduzido de base sintética para discussão de risco de evasão.

ID	Território	Internet em casa	Frequência	Uso da plataforma	Observação
E01	Centro	Sim	Alta	Alto	Participa de atividades online.
E02	Centro	Sim	Média	Alto	Fez atividades, mas faltou em dias de prova.
E03	Bairro A	Não	Alta	Baixo	Entrega tarefas impressas.
E04	Bairro A	Não	Média	Baixo	Acesso por celular compartilhado.
E05	Bairro B	Instável	Alta	Baixo	Participa presencialmente.
E06	Bairro B	Instável	Baixa	Baixo	Transporte escolar irregular.
E07	Zona rural	Não	Média	Baixo	Longo deslocamento.
E08	Zona rural	Não informado	Alta	Ausente	Dados incompletos.

2.7.2. Demonstração desplugada e plugada de visualização de dados

A demonstração será realizada em duas etapas complementares: uma versão desplugada, com malha quadriculada impressa, e uma versão plugada, com ferramentas digitais de visualização. O objetivo é mostrar que construir gráficos não depende apenas de *softwares*, mas da compreensão de variáveis, categorias, escala, legenda, título, interpretação e limites dos dados.

Na versão desplugada, os participantes receberão uma base sintética inspirada na Tabela 2.7 e uma folha quadriculada para construir manualmente gráficos de barras, colunas, pictogramas ou uma matriz de calor simplificada. Essa estratégia é útil em contextos de baixa conectividade, poucos dispositivos ou quando se deseja enfatizar o raciocínio sobre os dados antes do uso da ferramenta digital. As folhas de apoio serão disponibilizadas em Zenodo: <https://doi.org/10.5281/zenodo.21969375>.

Na versão plugada, a mesma base poderá ser visualizada em ferramentas Web, como *RAWGraphs*, *Datawrapper* ou *Flourish*, que permitem criar gráficos, mapas e narrativas visuais sem programação (Datawrapper, 2026; Flourish, 2026; RAWGraphs, 2026). A escolha da ferramenta dependerá do acesso, da familiaridade da formadora e dos objetivos da atividade.

Demonstração no minicurso. A formadora entrega uma base CSV sintética com colunas como território, conectividade, frequência, uso de plataforma e classificação automática de risco. Cada grupo constrói uma visualização, como barras por território, dispersão entre frequência e uso da plataforma ou matriz de calor simplificada. Em seguida, responde: o que o gráfico mostra? o que ele esconde? que decisão seria perigosa se tomada apenas com esse gráfico?

2.7.3. Visualização crítica: quatro perguntas

Toda visualização de dados usada no minicurso deve ser analisada com quatro perguntas:

1. **Origem:** de onde vieram os dados e quem ficou fora da coleta?
2. **Categoria:** as categorias fazem sentido para a realidade local?
3. **Escala:** a escala do gráfico aumenta ou reduz visualmente uma diferença?
4. **Uso:** que decisão alguém poderia tomar a partir desse gráfico e quem seria afetado?

Essas perguntas aproximam letramento em dados e educação midiática. Um gráfico também é uma mensagem. Ele possui autoria, escolhas, enquadramento, omissões e possíveis efeitos sobre a audiência.

Transposição didática. Em turmas sem laboratório, os estudantes podem construir gráficos em papel quadriculado, usando dados impressos ou coletados em sala. A atividade pode ser articulada a Matemática, Geografia, Sociologia ou Projeto de Vida. O importante é que os estudantes discutam o significado social dos dados, não apenas o formato do gráfico.

2.8. Estação 4: ética, autoria e colaboração humano-IA

A quarta estação integra as anteriores. Se a IA depende de infraestrutura, dados e modelos, então seu uso escolar exige decisões éticas. A UNESCO recomenda que a adoção de IA generativa em educação seja acompanhada de validação pedagógica, proteção de dados, transparência, supervisão humana e consideração das necessidades dos estudantes (Miao & Holmes, 2023). O *framework* de competências em IA para professores também enfatiza mentalidade centrada no humano, ética, fundamentos de IA, pedagogia com IA e desenvolvimento profissional (Miao & Cukurova, 2024).

Para facilitar a memória dos participantes, propõe-se o checklist CONFERIR. Antes de usar, aceitar ou compartilhar uma saída de IA, o professor pergunta:

Tabela 2.8. Checklist CONFERIR para uso pedagógico de IA.

Letra	Pergunta
C – Contexto	A resposta considera idade, etapa de ensino, território e objetivos da atividade?
O – Origem	Há fontes, evidências ou possibilidade de checagem externa?
N – Necessidade	A IA é realmente necessária? Há alternativa mais simples, humana/sustentável?
F – Falhas	Quais erros, lacunas, alucinações, estereótipos ou vieses podem existir?
E – Ética	Há risco para privacidade, autoria, direitos autorais, discriminação/dependência?
R – Revisão	Quem revisará a saída antes de usá-la em contexto educativo?
I – Inclusão	É acessível a estudantes com diferentes recursos/letramentos/condições?
R – Registro	Como declarar o uso da IA e registrar decisões tomadas por humanos?

2.8.1. Demonstração: resposta aparentemente boa, pedagogicamente frágil

Demonstração no minicurso. A formadora apresenta uma resposta gerada por IA para o pedido: “Crie uma atividade sobre energia para o Ensino Médio”. A resposta é analisada com o *checklist* CONFERIR. O grupo provavelmente identificará que a atividade pode estar genérica, sem considerar contexto local, sem explicitar objetivos de aprendizagem, sem critérios de avaliação e sem alternativa para estudantes sem acesso digital. Em seguida, os participantes reescrevem o *prompt* incluindo contexto, objetivos, restrições, critérios e exigência de revisão.

Um exemplo de *prompt* mais pedagógico:

Exemplo de prompt pedagógico

Sou professora de Física do Ensino Médio em uma escola pública com acesso limitado à Internet. Quero uma atividade de 50 minutos sobre energia, potência e consumo elétrico usando exemplos de celulares, ventiladores e computadores.

A atividade deve promover letramento em IA, mostrando que data centers consomem energia. Proponha objetivos, materiais de baixo custo, passo a passo, perguntas para discussão, avaliação formativa e cuidados éticos.

Use linguagem adequada para estudantes do 1º ano do Ensino Médio.

A diferença entre os *prompts* ajuda a discutir autoria. O professor não é substituído pelo texto gerado. Ele define objetivo, contexto, critérios, limites e revisão.

2.9. Dinâmica central: Tribunal da IA

A dinâmica retoma, de forma aplicada, o conceito de sistema sociotécnico. Se a IA é compreendida como uma cadeia que articula infraestrutura, dados, modelo, política institucional e comunicação humana, investigar uma falha de IA exige examinar cada elo dessa cadeia, e não apenas o algoritmo. É esse deslocamento, do algoritmo isolado para a cadeia completa de decisões, que estrutura os papéis periciais assumidos pelos grupos.

A atividade não pergunta se a IA é “boa” ou “ruim”. Pergunta: o que falhou na cadeia sociotécnica? A resposta pode envolver dados, infraestrutura, modelo, política de uso, interpretação humana e ausência de mecanismos de contestação. No Tribunal da IA, a expressão “cadeia sociotécnica” significa que nenhum resultado automatizado nasce apenas do código. A classificação produzida pelo sistema depende da coleta de dados, da escolha das variáveis, do treinamento do modelo, dos limites de conectividade das escolas, da forma como gestores interpretam o alerta, da comunicação com famílias e dos mecanismos de revisão ou recurso oferecidos aos estudantes.

A leitura sociotécnica do caso deve orientar toda a dinâmica. Em vez de perguntar apenas se o sistema *Aurora* acertou ou errou, os grupos devem reconstruir a cadeia de decisões que tornou aquele resultado possível: que dados foram coletados, que dados ficaram ausentes, que variáveis foram transformadas em indicadores, que limiar de risco foi definido, que infraestrutura estava disponível para os estudantes, como a escola interpretou o alerta e que oportunidade de revisão foi oferecida às famílias.

Para se chegar a uma resposta, cada grupo assume um papel:

- **Perícia de infraestrutura:** analisa conectividade, dispositivos, registros ausentes e condições físicas de acesso.
- **Perícia de dados:** analisa base histórica, variáveis, proxies, lacunas e visualizações.
- **Perícia computacional:** analisa limiares, erros, falsos positivos, explicabilidade e teste do modelo.
- **Conselho pedagógico:** analisa efeitos sobre estudantes, famílias, professores e avaliação escolar.
- **Comitê ético:** propõe reparação, governança, transparência, revisão humana e política de uso.

A Tabela 2.9 apresenta exemplos de evidências distribuídas aos participantes.

Tabela 2.9. Evidências do Tribunal da IA.

Pasta	Evidência	Pergunta de investigação
Infraestrutura	Relatório mostra que 38% dos estudantes da zona rural acessam a plataforma apenas pelo celular de familiares.	O dado “uso da plataforma” mede engajamento ou mede acesso?
Dados	A base histórica inclui frequência, notas, bairro, uso da plataforma e atrasos, mas não inclui transporte, trabalho familiar ou conectividade.	Que variáveis importantes ficaram fora da base?
Modelo	O sistema classifica como alto risco estudantes com pontuação acima de 0,65, mas não explica quais fatores pesaram mais.	Como contestar uma decisão que não é explicada?
Política escolar	A escola usou a lista para restringir participação em atividades externas, sem conversa prévia com estudantes.	A intervenção foi de apoio ou punição?
Comunicação	Famílias receberam mensagem dizendo que o estudante tem “alto risco de abandono”, sem explicar limites do sistema.	Como comunicar incerteza sem produzir estigma?

Cada grupo deve produzir um parecer de até uma página com quatro partes: *i*) Achado principal (o que foi identificado como problema?); *ii*) Evidências (quais cartões, dados ou observações sustentam a análise?); *iii*) Risco educacional (quem pode ser prejudicado e como?); e *iv*) Recomendação (o sistema deve ser suspenso/revisado/limitado, auditado ou usado apenas como apoio sob supervisão humana?).

Um bom parecer evita frases como “a culpa é do algoritmo”. Em sistemas sociotécnicos, a responsabilidade é distribuída: quem escolheu os dados, quem definiu as variáveis, quem configurou o limiar, quem interpretou a saída, quem comunicou à família, quem decidiu a intervenção e quem deixou de criar mecanismos de recurso.

2.10. Materiais de apoio para replicação

Esta seção reúne materiais que podem ser copiados para slides, fichas impressas ou caderno do participante. Para garantir permanência e estabilidade, a versão final dos materiais será disponibilizada em Zenodo: <https://doi.org/10.5281/zenodo.21969375>. Alguns desses materiais serão impressos e utilizados durante o minicurso.

Um glossário mínimo será utilizado para unificar a compreensão dos participantes acerca dos principais termos e expressões adotadas na comunicação durante o encontro. A Tabela 2.10 apresenta alguns desses termos.

Serão adotados cartão de evidência para o Tribunal da IA, a serem distribuídos aos grupos de participantes. Cada cartão pode seguir o modelo:

Tabela 2.10. Glossário mínimo para educadores.

Termo	Explicação didática
Algoritmo	Sequência de instruções ou regras para resolver um problema. Em IA, pode estar combinado com modelos estatísticos.
Modelo	Sistema treinado para produzir uma saída, como classificar, recomendar, prever ou gerar conteúdo.
Treinamento	Processo em que o modelo ajusta seus parâmetros a partir de exemplos.
Inferência	Momento em que o modelo usa o que aprendeu para responder a um novo caso.
Prompt	Instrução ou pergunta dada a uma ferramenta generativa.
Alucinação	Saída plausível, mas incorreta, inventada ou sem evidência confiável.
Viés algorítmico	Erro ou tendência sistemática que pode prejudicar grupos ou favorecer determinadas interpretações.
Proxy	Variável usada como substituta de outra, muitas vezes de forma problemática.
Explicabilidade	Capacidade de oferecer razões compreensíveis para uma saída ou decisão automatizada.
Supervisão humana	Presença de pessoas responsáveis por revisar, interpretar, limitar ou contestar decisões automatizadas.

Cartão de evidência

Evidência nº: 04.

Tipo: Dados.

Descrição: A base registra “uso da plataforma”, mas não registra se o estudante possui Internet em casa.

Pergunta: a variável mede engajamento ou acesso?

Risco: estudantes sem conectividade podem ser classificados como desinteressados.

Competências MAIL: analisar e avaliar; refletir e agir eticamente.

Também serão apresentados e discutidos modelos de declaração de uso de IA em atividade escolar. Uma possível proposta simples para estudantes pode ser a seguinte:

Modelo de declaração de uso de IA

Nesta atividade, usei IA para: () gerar ideias; () revisar texto; () resumir fonte; () criar imagem; () outro.

A decisão final sobre o conteúdo é minha. Revisei a resposta, conferi informações importantes e assumo responsabilidade pelo que entreguei.

As partes mais modificadas por mim foram: _____.

As fontes humanas ou materiais consultados foram: _____.

Esse registro evita tanto a proibição genérica quanto o uso invisível. Ele desloca a discussão para transparência, autoria e responsabilidade.

2.11. Discussão: contribuições para a Informática na Educação

Esta proposta contribui para a Informática na Educação em quatro sentidos: *i)* oferece uma contribuição conceitual ao tratar IA como sistema sociotécnico; *ii)* oferece uma contribuição metodológica ao organizar um minicurso por Estações de Investigação e Tribunal da IA. Esse formato permite que professores vivenciem as competências do MAIL antes de planejar como ensiná-las; *iii)* oferece uma contribuição tecnológica ao demonstrar

ferramentas de baixa barreira, sem exigir programação, mas sem reduzir o letramento em IA ao uso de ferramentas; e, *iv*) oferece uma contribuição social ao assumir que a formação docente deve considerar escolas com diferentes níveis de conectividade e públicos diversos.

A literatura brasileira em Informática na Educação já discute ensino de IA na Educação Básica (Camada & Durães, 2020), formação docente com IA generativa (Sousa & Cruz, 2024), sistemas tutores e jogos para educação midiática e identificação de fake news (Moreira, Classe *et al.*, 2024), além de implementação curricular de Computação e Cultura Digital nos anos iniciais (Czmola *et al.*, 2025; Grebogy *et al.*, 2025). O diferencial deste minicurso é articular tais discussões ao MAIL do PISA 2029 e transformá-las em atividades práticas, replicáveis e adaptáveis a diferentes contextos educacionais.

2.12. Considerações finais

Este material apresentou um percurso formativo para apoiar professores da Educação Básica na compreensão crítica da Inteligência Artificial como sistema sociotécnico. Ao articular Física, Computação, Dados, Educação Midiática e Ética, o minicurso evidencia que a IA não é mágica, neutra ou exclusivamente técnica: ela depende de infraestrutura, energia, redes, bases de dados, modelos, interfaces, decisões humanas e contextos educacionais.

A proposta busca ir além do uso instrumental de ferramentas generativas, criando condições para que professores e estudantes questionem quais dados foram usados, quem ficou fora da amostra, que padrões foram aprendidos, que grupos podem ser prejudicados e que decisões exigem supervisão humana. As Estações de Investigação e o Tribunal da IA oferecem um caminho didático para vivenciar esses conceitos, verificar os objetivos de aprendizagem e apoiar a transposição para diferentes realidades escolares.

Desse modo, o minicurso contribui para a Informática na Educação ao oferecer um material formativo replicável, alinhado ao MAIL/PISA 2029, à Computação da BNCC e às discussões contemporâneas sobre letramento em IA, justiça algorítmica, sustentabilidade e responsabilidade pedagógica.

Declaração de uso de Inteligência Artificial Generativa

As autoras declaram que utilizaram ferramentas de Inteligência Artificial Generativa como apoio ao processo de organização, revisão e produção de materiais didáticos associados a este material. O *NotebookLM* foi utilizado para organização, comparação e mineração inicial de referências bibliográficas e documentos de apoio. O *ChatGPT* foi utilizado para apoiar revisão editorial, a diagramação de materiais instrucionais e a geração de imagens didáticas utilizadas como apoio visual ao minicurso. Todas as decisões conceituais, metodológicas e pedagógicas, bem como a seleção das referências, a validação das informações, a revisão final do texto e a adequação ao escopo da JAIE, foram realizadas pelas autoras.

Referências

Barocas, S., Hardt, M., & Narayanan, A. (2023). *Fairness and Machine Learning: Limitations and Opportunities*. MIT Press. <https://fairmlbook.org/>

- Bender, E. M., Gebru, T., McMillan-Major, A., & Shmitchell, S. (2021). On the Dangers of Stochastic Parrots: Can Language Models Be Too Big? *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency*, 610–623. <https://doi.org/10.1145/3442188.3445922>
- Brasil. Conselho Nacional de Educação. (2025). Resolução CNE/CEB Nº 2, de 21 de março de 2025. Institui as Diretrizes Operacionais Nacionais sobre o uso de dispositivos digitais em espaços escolares e integração curricular de educação digital e midiática. <https://www.gov.br/mec/pt-br>
- Brasil. Ministério da Educação. (2018). *Base Nacional Comum Curricular*. Ministério da Educação. <https://basenacionalcomum.mec.gov.br/>
- Brasil. Ministério da Educação. (2022). *Computação: complemento à Base Nacional Comum Curricular*. Ministério da Educação. <https://www.gov.br/mec/pt-br/escolas-conectadas/BNCCComputaoCompletoDiagramado.pdf>
- Brasil. Ministério da Educação. (2025). *Educação digital e midiática: como elaborar e implementar o currículo nas escolas*. Ministério da Educação. <https://mecred.mec.gov.br/recurso/366316>
- Buolamwini, J., & Gebru, T. (2018). Gender Shades: Intersectional Accuracy Disparities in Commercial Gender Classification. *Proceedings of the 1st Conference on Fairness, Accountability and Transparency*, 81, 77–91. <https://proceedings.mlr.press/v81/buolamwini18a.html>
- Camada, M. Y. d. O., & Durães, G. M. (2020). Ensino da Inteligência Artificial na Educação Básica: um novo horizonte para as pesquisas brasileiras. *Anais do XXXI Simpósio Brasileiro de Informática na Educação*, 1553–1562. <https://doi.org/10.5753/cbie.sbie.2020.1553>
- Czmola, H., et al. (2025). A Computação como Componente Curricular nos anos iniciais do Ensino Fundamental: Discussões sobre a BNCC Computação e o Quadro Organizador Municipal. *Anais do XXXVI Simpósio Brasileiro de Informática na Educação*. <https://sol.sbc.org.br/index.php/sbie/article/view/38466>
- Datawrapper. (2026). Datawrapper: Create Charts, Maps, and Tables [Acesso em 9 jul. 2026]. <https://www.datawrapper.de/>
- Flourish. (2026). Flourish: Data Visualization and Storytelling [Acesso em 9 jul. 2026]. <https://flourish.studio/>
- Google. (2026). Teachable Machine [Acesso em 9 jul. 2026]. <https://teachablemachine.withgoogle.com/>
- Grebog, E. C., Santos, I., & Castilho, M. A. (2025). Computar Brincando: Cultura Digital nos Anos Iniciais do Ensino Fundamental. *Anais do XXXVI Simpósio Brasileiro de Informática na Educação*. <https://sol.sbc.org.br/index.php/sbie/article/view/38520>
- Hmelo-Silver, C. E. (2004). Problem-Based Learning: What and How Do Students Learn? *Educational Psychology Review*, 16(3), 235–266. <https://doi.org/10.1023/B:EDPR.0000034022.16470.f3>

- Hobbs, R. (2020). Propaganda in an Age of Algorithmic Personalization: Expanding Literacy Research and Practice. *Reading Research Quarterly*, 55(3), 521–533. <https://doi.org/10.1002/rrq.301>
- Kolb, D. A. (1984). *Experiential Learning: Experience as the Source of Learning and Development*. Prentice Hall.
- Long, D., & Magerko, B. (2020). What Is AI Literacy? Competencies and Design Considerations. *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*, 1–16. <https://doi.org/10.1145/3313831.3376727>
- Luccioni, A. S., Jernite, Y., & Strubell, E. (2024). Power Hungry Processing: Watts Driving the Cost of AI Deployment? *arXiv preprint arXiv:2311.16863*. <https://arxiv.org/abs/2311.16863>
- Miao, F., & Cukurova, M. (2024). *AI Competency Framework for Teachers*. UNESCO. <https://www.unesco.org/en/articles/ai-competency-framework-teachers>
- Miao, F., & Holmes, W. (2023). *Guidance for Generative AI in Education and Research*. UNESCO. <https://www.unesco.org/en/articles/guidance-generative-ai-education-and-research>
- Moreira, T. d. O., Classe, T. M. d., *et al.* (2024). Aplicação de Sistema Tutor Inteligente em Jogo Educacional Digital para Apoio à Identificação de Fake News. *Anais do XXXV Simpósio Brasileiro de Informática na Educação*. <https://sol.sbc.org.br/index.php/sbie/article/view/31271>
- National Association for Media Literacy Education. (2023). Core Principles of Media Literacy Education in the United States. <https://namle.org/resources/core-principles/>
- Ng, D. T. K., Leung, J. K. L., Chu, S. K. W., & Qiao, M. S. (2021). Conceptualizing AI Literacy: An Exploratory Review. *Computers and Education: Artificial Intelligence*, 2, 100041. <https://doi.org/10.1016/j.caeai.2021.100041>
- Noble, S. U. (2018). *Algorithms of Oppression: How Search Engines Reinforce Racism*. New York University Press.
- Ochs, M. (2026). *Media and Artificial Intelligence Literacy (MAIL) no PISA 2029: fundamentos conceituais e convergência com as diretrizes brasileiras de educação digital e midiática* (Nota técnica). Instituto Palavra Aberta. São Paulo. <https://educamidia.org.br/biblioteca/media-and-artificial-intelligence-literacy-mail-no-pisa-2029/>
- OECD. (2026). *Navigating an Evolving Digital World: First Draft of the PISA 2029 Media and Artificial Intelligence Literacy (MAIL) Assessment Framework* (Assessment framework) (Preliminary draft, subject to revisions before the final version is released). Organisation for Economic Co-operation e Development. Paris. <https://www.oecd.org/en/about/projects/pisa-2029-media-and-artificial-intelligence-literacy.html>
- OECD & European Union. (2026). *Empowering Learners for the Age of AI: An AI Literacy Framework for Primary and Secondary Education*. <https://doi.org/10.1787/65cd27d4-en>

- PhET Interactive Simulations. (2026). PhET: Free Online Physics, Chemistry, Biology, Earth Science and Math Simulations [University of Colorado Boulder. Acesso em 9 jul. 2026]. <https://phet.colorado.edu/>
- Prince, M. (2004). Does Active Learning Work? A Review of the Research. *Journal of Engineering Education*, 93(3), 223–231. <https://doi.org/10.1002/j.2168-9830.2004.tb00809.x>
- RAWGraphs. (2026). RAWGraphs: The Missing Link Between Spreadsheets and Data Visualization [Acesso em 9 jul. 2026]. <https://www.rawgraphs.io/>
- Russell, S., & Norvig, P. (2022). *Artificial Intelligence: A Modern Approach* (4^a ed.). Pearson.
- Sousa, H. d., & Cruz, D. M. (2024). Capacitando Educadores com IA Generativa: Implicações na Educação. *Anais do XXXV Simpósio Brasileiro de Informática na Educação*, 1931–1941. <https://doi.org/10.5753/sbie.2024.242665>
- Strubell, E., Ganesh, A., & McCallum, A. (2019). Energy and Policy Considerations for Deep Learning in NLP. *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*, 3645–3650. <https://doi.org/10.18653/v1/P19-1355>
- Touretzky, D., Gardner-McCune, C., Martin, F., & Seehorn, D. (2019). Envisioning AI for K-12: What Should Every Child Know about AI? *Proceedings of the AAAI Conference on Artificial Intelligence*, 33(1), 9795–9799. <https://doi.org/10.1609/aaai.v33i01.33019795>

Currículo Resumido das Autoras



Cibele Nunes Cabral é pedagoga, formada pelo Instituto Tocantinense Presidente Antônio Carlos (ITPAC), em Araguaína/TO, e especialista em Psicopedagogia. Atualmente é mestranda do Programa de Pós-Graduação Profissional em Computação em Rede Nacional (PROFCOMP/UNIFESSPA), com foco em Inteligência Artificial na Educação Básica, pensamento computacional e formação docente. Cursa especialização em Docência na Educação Profissional e Tecnológica pelo Instituto Federal do Tocantins, especialização em Educação de Jovens e Adultos do Campo pela Universidade Federal do Paraná e especialização em Direitos Humanos e Diversidades pela Universidade Federal de Goiás.

É servidora pública municipal da educação nos municípios de Xinguara/PA e Rio Maria/PA, atuando diretamente na Educação Básica. Exerce a função de Formadora Regional do Pacto Nacional pela Superação do Analfabetismo e Qualificação na Educação de Jovens e Adultos (PACTO EJA/UNDIME), na Região Araguaia, experiência que fortalece sua atuação com formação de professores, educação de jovens e adultos, diversidade, inclusão e práticas pedagógicas contextualizadas. Sua trajetória articula educação, tecnologias digitais e formação docente. Participou do V Simpósio Internacional e VIII Nacional de Tecnologias Digitais na Educação, realizado pela Universidade Federal do Maranhão (UFMA), com carga horária de 100 horas, e atuou como moderadora em palestras sobre estratégias de ensino, uso de novas tecnologias na educação e processos de cocriação com tecnologias educativas digitais. Essas experiências dialogam diretamente com a proposta deste minicurso, especialmente por aproximarem tecnologias digitais, práticas pedagógicas e reflexão crítica sobre inovação educacional.

No PROFCOMP/UNIFESSPA, pretende desenvolver como produto educacional uma metodologia de formação de professores para trabalhar pensamento computacional e uso de Inteligência Artificial de forma transversal na Educação Básica. Na presente proposta de minicurso, sua contribuição principal será liderar o eixo de Computação, explorando a lógica de funcionamento dos modelos de IA, o papel dos dados no treinamento de sistemas inteligentes, a construção de prompts, a aprendizagem de máquina em atividades sem programação e a transposição didática desses conceitos para professores de diferentes áreas.



Hodara Cristina Nobre Ferreira é licenciada em Física pela Universidade Federal do Sul e Sudeste do Pará (UNIFESSPA) e mestranda do Mestrado Nacional Profissional em Ensino de Física (MNPEF/UNIFESSPA). Atua como professora de Física no Ensino Médio, com experiência em aulas regulares, itinerários formativos, práticas experimentais, projetos escolares, feiras de ciências e atividades voltadas à contextualização do conhecimento científico na Educação Básica. Sua trajetória acadêmica e profissional é marcada pelo interesse em metodologias inclusivas e inovadoras para o ensino de Física, especialmente no uso de recursos visuais, experimentos de baixo custo,

laboratórios virtuais, plataformas educacionais, jogos didáticos e projetos de investigação. Durante a graduação, participou do Programa Residência Pedagógica, experiência que fortaleceu sua compreensão sobre os diferentes ritmos de aprendizagem e sobre a necessidade de estratégias didáticas sensíveis às trajetórias dos estudantes.

Na Educação Básica, desenvolveu atividades relacionadas aos Itinerários Formativos de Ciências da Natureza e de Matemática, abordando temas como energias renováveis, consumo e eficiência energética, sustentabilidade ambiental, conforto térmico, educação financeira e consumo consciente. Essas experiências aproximam sua atuação docente da proposta interdisciplinar deste minicurso, especialmente por articular conceitos físicos, problemas sociais, sustentabilidade e tomada de decisão baseada em evidências.

No MNPEF/UNIFESSPA, pretende desenvolver um produto educacional que una Ensino de Física e Inteligência Artificial para a Educação Básica, com foco na construção de práticas pedagógicas acessíveis, contextualizadas e críticas. Na proposta do minicurso, sua contribuição principal será liderar o eixo de materialidade da Inteligência Artificial, discutindo a infraestrutura física que sustenta os sistemas digitais, como sensores, redes, servidores, energia, data centers, consumo computacional e impactos socioambientais. A partir de sua formação em Física e de sua experiência docente, contribuirá para mostrar que a IA não é um fenômeno abstrato ou mágico, mas um sistema sociotécnico dependente de recursos físicos, energia, dados, modelos e decisões humanas.



Léia Sousa de Sousa é professora da Universidade Federal do Sul e Sudeste do Pará (UNIFESSPA), vinculada à Faculdade de Computação e Sistemas de Informação (FACSI/IGE). Possui formação interdisciplinar em Matemática e Sistemas de Informação pela Universidade Federal do Pará (UFPA), é mestre e doutora em Informática pela Universidade de Brasília (UnB).

Atua nas áreas de Computação, Sistemas de Informação, tecnologias educacionais, pensamento computacional, letramento digital, inclusão digital, educação midiática, formação de professores, visualização de dados, infraestrutura de redes e tecnologias aplicadas à transformação digital. É docente do Mestrado Profissional em Computação em Rede Nacional (PROFCOMP/ UNIFESSPA) e do Mestrado Nacional Profissional em Ensino de Física (MNPEF/UNIFESSPA, Polo 29), onde ministra componentes relacionados a Pensamento Computacional, Tecnologias Educacionais e Metodologia Científica com uso ético de Inteligência Artificial.

É idealizadora do Projeto Tecer Mulher, tecnologia social voltada à inclusão digital de mulheres idosas na Amazônia. A iniciativa tem como foco o desenvolvimento de práticas educativas situadas para letramento digital, segurança digital, cidadania digital, uso de aplicativos cotidianos e fortalecimento da autonomia de mulheres idosas. O projeto recebeu reconhecimento nacional com o Prêmio LED – Luz na Educação, da TV Globo, e alcançou o 2o lugar estadual no Prêmio Educador Transformador, promovido pelo SEBRAE, na categoria Inclusão e Sustentabilidade na Educação. Também atua como palestrante em eventos nacionais nas áreas de inclusão digital, tecnologia social, educação midiática, envelhecimento ativo e inovação educacional.