



# CADERNO DO PROFESSOR

Orientações Didático-Pedagógicas  
para o 2º Ano do Ensino Médio

CC BY-NC-SA 4.0



Este material está sob licença Creative Commons  
Atribuição-NãoComercial-Compartilhalgual (CC BY-NC-SA).

VICARI, Rosa Maria; GALAFASSI, Cristiano; BRACKMANN, Christian; MIZUSAKI, Lucas.  
IA@Escola. 2024. Disponível em: [www.IAnaEscola.com.br](http://www.IAnaEscola.com.br).

# ÍNDICE

<b>APRESENTAÇÃO</b>	<b>3</b>
<b>MÓDULO 1: FUNDAMENTOS LÓGICOS DA IA</b>	<b>6</b>
A IA SIMBÓLICA	7
ÁRVORES DE DECISÃO AVANÇADAS	15
REDES SEMÂNTICAS	25
<b>MÓDULO 2: REDES NEURAIS ARTIFICIAIS</b>	<b>63</b>
NEURÔNIO ARTIFICIAL E REDES DE NEURÔNIOS	63
ÉTICA E TREINAMENTO DE REDES NEURAIS ARTIFICIAIS	67
<b>MÓDULO 3: APRENDIZADO DE MÁQUINA</b>	<b>69</b>
<b>MÓDULO 4: SEGURANÇA DOS DADOS NA IA</b>	<b>71</b>
SEGURANÇA DOS DADOS NA IA	72
SEGURANÇA DOS DADOS NA IA	77
<b>MÓDULO 5: MODELOS DE LINGUAGENS</b>	<b>80</b>
CONSUMO ENERGÉTICO E IMPACTO AMBIENTAL	81
ENGENHARIA DE PROMPT	86
PROMPTS MULTIMODAIS	96
<b>MÓDULO 6: IA PARA ACESSIBILIDADE</b>	<b>113</b>
INTELIGÊNCIA ARTIFICIAL PARA ACESSIBILIDADE	114
INTELIGÊNCIA ARTIFICIAL PARA A ACESSIBILIDADE NA APRENDIZAGEM	119
<b>MÓDULO 7: PROGRAMAÇÃO PARA IA</b>	<b>125</b>
PROGRAMAÇÃO PARA IA COM ORANGE DATA MINING	126
<b>MÓDULO 8: REDES NEURAIS ARTIFICIAIS AVANÇADAS</b>	<b>139</b>
<b>REFERÊNCIAS</b>	<b>141</b>

## APRESENTAÇÃO

Prezado/a Professor(a).

O caderno de orientações didático-pedagógicas está alinhado a BNCC, ao Complemento da Computação e ao Referencial Curricular IA no Ensino Médio<sup>1</sup>. Assim, visa contribuir para o planejamento, o desenvolvimento e a avaliação de suas práticas pedagógicas de sala de aula no componente previsto, oferecendo-lhe um suporte técnico e pedagógico.

Este caderno está organizado em módulos. Em cada módulo constam os conteúdos necessários para execução dos planos de aula disponibilizados nos site e trabalhados na formação dos professores, além de materiais e orientações extras sobre cada tema/conteúdo a serem utilizados em sala de aula.

Os planos de aula fornecidos junto com este material, são acompanhados da descrição de um planejamento que especifica os objetivos de aprendizagem, traz a proposta para o encaminhamento em sala de aula, bem como sugere possibilidades de ampliação e de mediação do professor. Os planos de aula consistem em exemplos de como o tema/conteúdo pode ser implementado em aula que – acreditamos – possam ser motivadoras e atraentes para os alunos.

Nosso objetivo é que este material não apenas auxilie no planejamento com seus alunos, mas, principalmente, que este ano escolar seja um período de sucesso, onde alunos se sintam confiantes em seu aprendizado e professores seguros em suas competências de ensino.

Cabe destacar que o caderno não se configura como um livro didático, mas como um recurso que traz subsídios que contribuem com a ação docente e atividades a serem desenvolvidas em sala de aula, o que amplia, ainda mais, as possibilidades de desenvolvimento pedagógico relacionadas à aprendizagem dos conceitos teóricos e práticos da Inteligência Artificial nas escolas. Entendemos, assim, que as escolas têm autonomia didático-pedagógica e que os professores são protagonistas dos processos que ocorrem nas salas de aulas.

Equipe do grupo de Pesquisa em Inteligência Artificial (PIÁ)



---

<sup>1</sup> Disponível em <http://ianaescola.com.br/referencial>

---

## AUTORES

**Dr<sup>a</sup>. Rosa Maria Vicari:** Doutora em Engenharia Electrotécnica e Computadores pela Universidade de Coimbra e Pós Doutora em Cognitive Science na Universidade de Leeds, UK (1997) e na Universidade Joseph Université Joseph Fourier, Grenoble França (2011). É professora titular da Universidade Federal do Rio Grande do Sul e coordenadora da Cátedra UNESCO em Tecnologias de Comunicação e Informação na Educação, desde 2010. Atua na área de Ciência da Computação e Inteligência Artificial aplicada à Educação. Currículo Lattes: <http://lattes.cnpq.br/5098313138514050>

**Dr. Cristiano Galafassi:** Tem doutorado em Informática na Educação pela UFRGS. É professor adjunto da Universidade Federal do Pampa, atuando na área de Inteligência Artificial na Educação e Aprendizado de Máquina. Membro da Cátedra UNESCO em Tecnologias da Informação e Comunicação na Educação. Currículo Lattes: <http://lattes.cnpq.br/7555705724716780>

**Dr. Christian Brackmann:** Tem doutorado em Informática na Educação pela UFRGS. Pós-doutorando em Inteligência Artificial na Educação Básica. Atua na área da Computação, Computação na Educação Básica e Inteligência Artificial. É professor do Instituto Federal Farroupilha (IFFAR). Membro da Cátedra UNESCO em Tecnologias da Informação e Comunicação na Educação. É coautor do “Currículo de Referência em Tecnologia e Computação” do CIEB e desenvolvedor/validador da norma “Computação – Complemento à BNCC”. Currículo Lattes: <http://lattes.cnpq.br/3440794204799048>

**Dr. Lucas Eishi Pimentel Mizusaki:** Tem bacharelado em Engenharia de Computação, mestrado em computação aplicada e doutorado em Informática na Educação. É professor do Instituto Federal Sul-rio-grandense (IFSUL). Membro da Cátedra UNESCO em Tecnologias da Informação e Comunicação na Educação. Atua nas áreas de tecnologia no ensino, robótica educativa e formação de professores. Currículo Lattes: <http://lattes.cnpq.br/3809451840989859>

**Dr. Flávio Oliveira:** Tem doutorado em Computação pela Universidade Federal do Rio Grande do Sul (1994), graduação em Tecnólogo em Processamento de Dados pela Universidade Federal do Rio Grande do Sul (1984) e mestrado em Computação pela Universidade Federal do Rio Grande do Sul (1987). Professor da Escola Politécnica da Universidade do Vale do Rio dos Sinos desde 2024. Foi Professor Adjunto da Pontifícia Universidade Católica do Rio Grande do Sul de 1992 a 2017. Tem experiência na área de Ciência da Computação, com ênfase em Sistemas de Informação, atuando como docente, gestor e consultor, principalmente nos seguintes temas: Inteligência Artificial, Engenharia de Software e Teste de Software. Currículo Lattes: <https://lattes.cnpq.br/5361212899275268>


**Dr<sup>a</sup>. Claudia Camerini Corrêa Pérez:** Possui graduação em Informática pela Universidade Federal de Pelotas (1999), especialização em Informática na Educação (ênfase em Educação a Distância) pela Universidade Federal do Rio Grande do Sul (2001), mestrado em Computação no Programa Interdisciplinar em Computação Aplicada pela Universidade do Vale do Rio dos Sinos (2004), e doutorado em Informática na Educação pela Universidade do Rio Grande do Sul (UFRGS). É professora Associada da Universidade Federal do Pampa (UNIPAMPA) dos cursos de

Letras EaD e Pedagogia. Trabalha com a formação de professores para a educação a distância, Tecnologias da Informação e Comunicação, Letramento Digital, Inteligência Artificial na Educação, Acessibilidade e Inclusão, Tecnologia Assistiva e Comunicação Alternativa. Currículo Lattes: <http://lattes.cnpq.br/6081469722279977>


**Dr<sup>a</sup>. Fabiane Flores Penteado Galafassi:** Doutora em Informática na Educação pela Universidade Federal do Rio Grande do Sul (UFRGS). É professora na Universidade Federal do Pampa (UNIPAMPA), campus Itaqui, e coordenadora do curso de Licenciatura em Pedagogia EAD. Sua atuação e formação abrangem as áreas de informática na educação, software educativo, educação a distância e sistemas inteligentes. Currículo Lattes: <http://lattes.cnpq.br/5263172314646839>

---

## Entenda os Ícones

 GLOSSÁRIO: indica definição mais detalhada de um termo, palavra ou expressão utilizada no texto.

 SALA DE AULA: Dicas para a sala de aula

 SAIBA MAIS: traz sugestões de conhecimentos relacionados ao tema abordado, facilitando a aprendizagem do aluno

MÓDULO 1: FUNDAMENTOS LÓGICOS DA IA

# MÓDULO 1

## FUNDAMENTOS LÓGICOS DA INTELIGÊNCIA ARTIFICIAL

**Objetivo do Módulo:**

Ao final do módulo os professores participantes deverão compreender os princípios e as lógicas por trás da IA simbólica

**Contempla:**

AULA 01: IA Simbólica - Árvores de Decisão Avançadas

AULA 02: Redes Semânticas

---

## A IA SIMBÓLICA

A **IA simbólica** é uma linha da inteligência artificial (IA) que trabalha com o conhecimento e sua representação. O conhecimento é representado por meio de símbolos, como palavras, frases ou conceitos, sendo organizado em uma estrutura lógica que permite ao sistema manipulá-lo para realizar tarefas, como resolução de problemas, raciocínio e tomada de decisões. Ela trabalha com a hipótese do mundo fechado, ou seja, o que não estiver representado não é considerado. Logo, a IA simbólica requer um conhecimento completo e bem definido para funcionar corretamente. Em domínios em que o conhecimento é incompleto, faltam dados, ela pode não ser eficaz. Ou seja, além da **IA simbólica** existem, hoje, outras linhas, como a **IA do Aprendizado de Máquina** com muitos dados, a **IA dos grandes modelos de linguagem** e a **IA orientada por objetivos**.

Os algoritmos de IA simbólica funcionam processando símbolos, que podem representar objetos, indivíduos ou conceitos no mundo e suas relações. A principal abordagem da IA simbólica é usar a programação em lógica, em que as regras e os axiomas são usados para fazer inferências e deduções.


Para exemplificar uma IA simbólica, trabalharemos com indivíduos e suas relações familiares: *progenitor (maria,josé)* que se lê como “maria é progenitor de josé” (convenção). Estamos estabelecendo uma relação de parentesco (progenitor) entre a Maria e o José. Vamos explorar mais sobre a história da família Pinheiro.

### História da família Pinheiro


Pouco se sabe da história passada da família Pinheiro. Existem alguns registros antigos que indicam que:

- O casal José e Maria criou dois filhos, o João e a Ana.
- A Ana teve duas filhas, a Helena e a Joana. Além disso, o Mário é filho do João, que muito se orgulha disso.
- Estranho também, foi constatar que o Carlos nasceu da relação entre a Helena, muito formosa, e o Mário.

Veja que já na descrição da história da família Pinheiro, o texto inicia com “pouco se sabe...” ou seja, já coloca o fato de que a IA pode trabalhar com informações incompletas. Isso é uma das características da IA, que a diferenciam da Computação clássica.



Para representar as relações e resolver o problema de alguns parentescos presentes na família Pinheiro, vamos utilizar a **lógica de predicados**

 **Predicado:** O nome lógico de predicados vem da linguística e quer dizer (sentenças). Por exemplo, Maria é bonita. “*Maria*” é o sujeito e “*é bonita*” o predicado.

### Lógica de predicados

A lógica de predicados utiliza conectivos lógicos como o (^) que significa o conectivo e para fazer as ligações entre os predicados. Vejamos um exemplo:

$$(\text{progenitor}(x,p) \wedge \text{progenitor}(p,y) \wedge \text{gênero}(x,\text{masculino})) \rightarrow \text{avo}(x,y).$$

Nesta fórmula temos que: se **x** é progenitor de **p** e **p** é progenitor de **y** e **x**, possui o gênero masculino, então **x** é avô de **y**. Ou seja, **avo(x,y)** só será verdadeiro (provado) se todas as suas premissas forem verdadeiras. A lógica de predicados utiliza variáveis. No exemplo, as variáveis estão representadas pelas letras **x**, **y** e **p**.

## A Linguagem Prolog

Prolog (Programação Lógica) é uma linguagem de programação que se enquadra no paradigma de Programação em Lógica Matemática. É uma linguagem de uso geral que é especialmente associada com a inteligência artificial e linguística computacional. Uma das primeiras linguagens voltadas à IA, o Prolog prioriza a declaração de fatos e regras, permitindo que o sistema alcance conclusões por meio de inferência lógica. Os dados são representados como um conjunto de fatos organizados em um banco de dados estruturado, que serve de base para as inferências do sistema.

Para executá-lo você deve instalar um interpretador Prolog e entrar com os **algoritmos** e os **dados**. Um dos interpretadores offline gratuitos mais utilizados se chama SWI-Prolog e pode ser baixado em <https://www.swi-prolog.org/download/stable>. Existe também uma versão online que pode ser executada diretamente no navegador chamado SWISH. Ele está disponível em <https://swish.swi-prolog.org/>.

### Mão na Massa!

Vamos retomar o exemplo:

```
(progenitor(x,p) ^ progenitor(p,y) ^ genero (x,masculino)) -> avo(x,y)
```

Se você quiser transformar essa fórmula lógica, que é um algoritmo em um programa em lógica (linguagem de programação PROLOG) é muito simples. No exemplo acima, os dados são o conjunto de proposições do tipo `progenitor(maria,joao)` e o conjunto de proposições de `genero(maria, feminino)`. Assim, do nosso exemplo acima, teríamos a seguinte representação:

```
avo(x,y):- progenitor(X,P), progenitor(P,Y), genero(X,masculino).
```

Mas, da mesma forma, ela só será verdadeira se as premissas o forem. Ou seja, para que a relação `avô x de y` seja verdadeira, todos os predicados do axioma lógico precisam ser verdadeiros. Aqui temos um algoritmo em linguagem lógica.

Da figura da família Pinheiro é possível retirar algumas informações. A relação é lida da seguinte forma: Maria é progenitor de João

```
progenitor(maria,joao).
progenitor(jose,joao).
progenitor(maria,ana).
progenitor(jose,ana).
progenitor(joao,mario).
progenitor(ana,helena).
progenitor(ana,joana).
progenitor(helena,carlos).
progenitor(mario,carlos).
genero(ana,feminino).
genero(maria,feminino).
genero(joana,feminino).
genero(helena,feminino).
genero(mario,masculino).
genero(joao,masculino).
genero(jose,masculino).
genero(carlos,masculino).
```

E alguns algoritmos

```
(progenitor(X,P), progenitor(P,Y), genero(X,masculino)) -> avo(X,Y).
```

Relação de **x** é avô de **y**.

Na linguagem prolog, como você pode ver, é necessário substituir o acento circunflexo (^) por vírgula (.). As variáveis também devem estar em letra maiúscula e no final é obrigatório colocar um ponto final (.) para indicar que o algoritmo acabou.

Para resolver esta relação é preciso fazer inferência, pois não temos os dados referentes à relação de avós diretamente. Mas, temos dados dos progenitores. Assim é possível chamar o dado progenitor x de A e novamente chamar os dados de progenitor A de y. Agora já demos dados para todas as nossas variáveis.

E, se o desejo for avô ou avó, temos ainda que conferir os dados sobre gênero de x.

Como funciona:

Algoritmo:

```
(progenitor(X,P), progenitor(P,Y), genero(X,masculino)) -> avo(X,Y).
```

Dados:

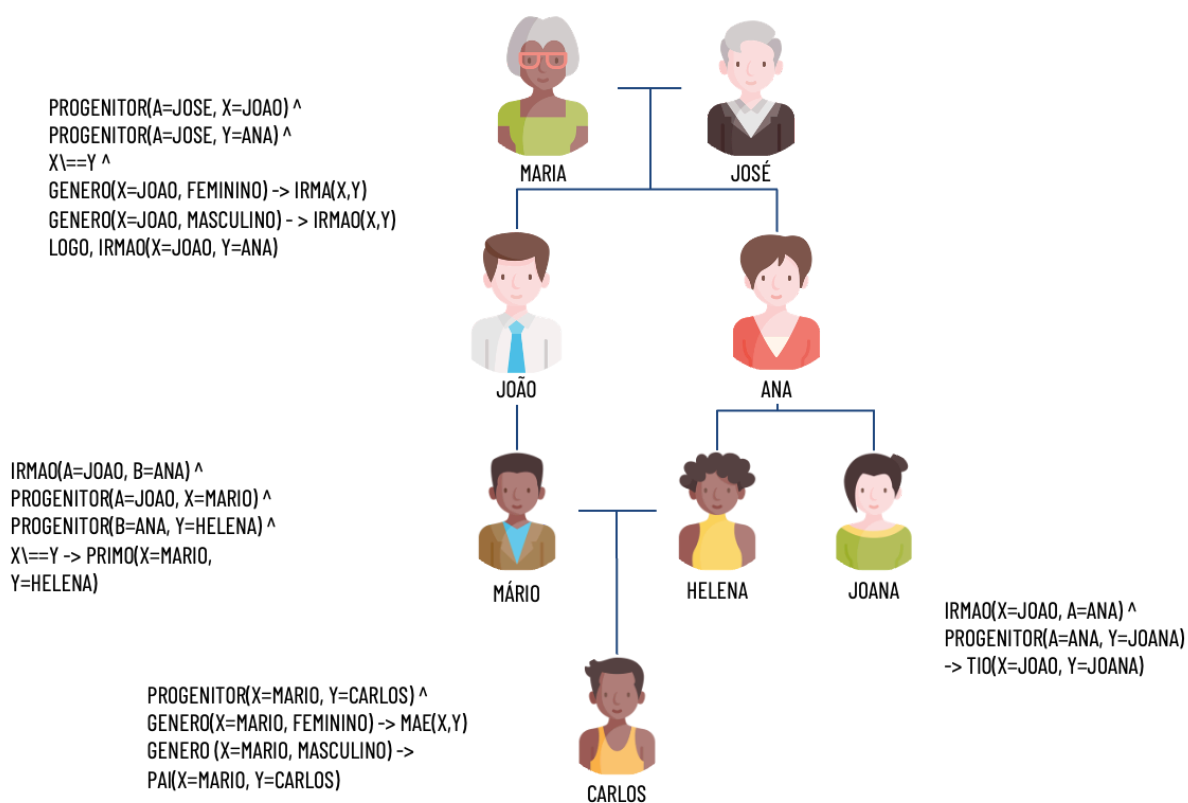
```
progenitor(maria,joao).
progenitor(jose,joao).
progenitor(maria,ana).
progenitor(jose,ana).
progenitor(joao,mario).
progenitor(ana,helena).
progenitor(ana,joana).
progenitor(helena,carlos).
progenitor(mario,carlos).
```

```
progenitor(maria,joao), progenitor(joao,mario), genero(maria,masculino).
Falha
```

```
progenitor(jose, joao), progenitor(joao,mario), genero(jose, masculino).
Verdadeiro
```

```
avo(jose, mario).
Verdadeiro
```

Veja o algoritmo associado à figura da família Pinheiro



- O algoritmo deduziu a relação de Avô a partir dos dados que possuía. Avô é um novo conhecimento.
- Outras relações podem ser inferidas:

$(progenitor(x, p) \wedge descendente(p, y)) \rightarrow descendente(x, y)$

Prolog:  $(progenitor(X, P), descendente(P, Y)) \rightarrow descendente(X, Y)$

Você pode, a partir das informações que possui sobre a família pinheiro e sobre a linguagem lógica matemática, construir outros algoritmos como, por exemplo *irmão, irmã, tio e primo*:

$progenitor(A, X), progenitor(A, Y), X \neq Y \wedge genero(X, feminino) \rightarrow irma(X, Y).$

$genero(X, masculino) \rightarrow irmao(X, Y).$

$progenitor(X, Y), genero(X, feminino) \rightarrow mae(X, Y).$

$genero(X, masculino) \rightarrow pai(X, Y).$

$irmao(X, A), progenitor(A, Y) \rightarrow tio(X, Y).$

$irmao(A, B), progenitor(A, X), progenitor(B, Y), X \neq Y \rightarrow primo(X, Y).$

Deduz conceitos de irmã, irmão, mãe, pai, tio, primo a partir de progenitor onde:  $\neq$  significa diferente.

Este sistema de IA simbólica projetado para estabelecer as relações de parentesco da família Pinheiro tem um conjunto de regras e axiomas que ele usa para fazer inferências e deduções sobre as relações de parentescos apresentadas no problema.

Essa abordagem é altamente explicável, pois é possível rastrear o processo de raciocínio até as regras lógicas que foram aplicadas e os dados utilizados. Ele também nos permite modificar e atualizar facilmente as regras do sistema à medida que novas informações se tornam disponíveis. Na nossa aula, vamos acrescentando algoritmos que podem chamar os antecedentes, para resolver problemas relacionados com relações de parentesco presentes na família Pinheiro.

Com os dados e os algoritmos você criou um modelo que pode ser consultado através de **prompts**. Vamos utilizar prompts que exijam apenas as respostas “sim” ou “não” para as perguntas contendo apenas constantes e os dados encontrados na base de dados, quando a pergunta conter variáveis. Constantes como em `progenitor(jose, joao)` ou com variáveis como em: `mae(maria, x)`.

Geramos um modelo que pode ser consultado individualmente:

Prompt exemplo 1: `progenitor(jose, joao)`.

Prompt exemplo 2: `pai(jose, joao)`.

Prompt exemplo 3: `mae(maria, X)`.

Prompt exemplo 4: `primo(mario, X)`.

Prompt exemplo 5: `tio(Y, X)`.

Prompt exemplo 6: `descendente(X, carlos)`.

Prompt exemplo 7: `irmao(helena, X)`.

Prompt exemplo 8: `irma(helena, X)`.

A IA simbólica permitiu a criação dos chamados sistemas especialista e de vários sistemas para a tomada de decisão (ver exemplos de sistemas especialistas clássicos na linha do tempo da IA). Ela utiliza linguagens formais, como a lógica, para representar o conhecimento. Esse conhecimento é processado por mecanismos de raciocínio que usam algoritmos para manipular símbolos. Ela faz deduções e inferências com base em regras e conhecimentos predefinidos. As deduções podem gerar novos conhecimentos. Por exemplo, deduzir as relações de avô e avó (vejam que estas relações não foram pré-definidas. Existem apenas as relações de progenitor e de gênero pré-definidas).

Quando você fala em representação do conhecimento (por exemplo da família Pinheiro) e também dos raciocínios feitos, pelos algoritmos sobre estes conhecimentos pré-existentes, é importante salientar que, na IA simbólica, os objetivos e o conhecimento do programa são *explícitos*. Ou seja, estão programados. O controle é humano. Na IA da *machine learning*, isso nem sempre é assim.

---

A IA simbólica tem sido aplicada em vários campos, como, por exemplo, Processamento de Linguagem Natural, Sistemas Especializados e Robótica. Alguns exemplos são:

- A Siri e outros assistentes digitais usam a IA simbólica para entender a linguagem natural e fornecer respostas.
- Os sistemas de diagnóstico médico usam a IA simbólica para fornecer recomendações aos médicos com base nos sintomas do paciente (conforme demonstrado anteriormente).
- Os carros autônomos usam a IA simbólica para tomar decisões com base no ambiente, como o reconhecimento de sinais de parada e semáforos.
- Os sistemas de visão computacional podem usar a IA simbólica para reconhecer objetos e padrões em imagens.

Você pode também comparar as diferentes linhas da IA com exemplos como:

- A IA simbólica difere de outras técnicas de IA, como a aprendizagem automática e aprendizagem profunda, pois não exige grandes quantidades de dados de treinamento. Em vez disso, ela se baseia na representação do conhecimento e no raciocínio, o que a torna mais adequada para domínios em que o conhecimento é bem definido (dados estruturados) e pode ser representado em regras lógicas.
- O aprendizado de máquina, por outro lado, requer grandes conjuntos de dados para aprender padrões e fazer previsões. A aprendizagem profunda usa redes neurais para aprender diretamente dos dados, o que a torna adequada para domínios com dados complexos e não estruturados. Ela pode aprender objetivos implícitos (não programados pelos programadores).

A decisão de quando usar cada técnica da IA depende do domínio do problema e dos dados disponíveis. A IA simbólica é adequada para domínios com conhecimento bem definido e estruturado, enquanto o aprendizado de máquina e a aprendizagem profunda são adequadas para domínios com grandes quantidades de dados e padrões complexos.

Embora exista uma linha da IA chamada de aprendizado de máquina, **não significa que na IA simbólica não exista aprendizado**. Ele existe e é realizado com base em poucos dados. Técnicas como árvores de decisão, regras de produção, redes semânticas, etc. que são típicas da IA simbólica podem aprender. Mas, é necessária a programação manual o que torna difícil o aprendizado e a adaptação em tempo real.

A IA simbólica tem várias vantagens, como **explicabilidade**, ela oferece transparência no processo de raciocínio, facilitando a compreensão de como um sistema chegou a uma conclusão, ou seja, todos os seus objetivos são explícitos. Logo, é possível rastrear o raciocínio e os dados utilizados para chegar a uma decisão. **Flexibilidade**, esta IA é altamente flexível e pode ser adaptada a diferentes domínios, modificando as regras e a base de conhecimento. **Representação do conhecimento** de maneira formal e estruturada,

com capacidade para representar conhecimentos complexos, permitindo fácil manipulação e raciocínio.

No entanto, a IA simbólica não possui capacidade de escalabilidade, pois ela pode se tornar computacionalmente cara à medida que o número de símbolos e regras aumenta, dificultando o dimensionamento para grandes domínios. Esta característica justifica o fato de que suas aplicações não resultam em sucesso comercial.



Este conteúdo introdutório corresponde a um plano de aula teórica, a menos que você queira utilizar a linguagem de programação Prolog, e você pode construir este plano. Ele pode ser dividido em duas aulas teóricas.

O professor pode utilizar a Linha do tempo da IA (<https://www.computacional.com.br/ia/linha-tempo.php>) para localizar seus alunos no período do tempo (antes de 1980), onde só existia esta linha da IA, a IA simbólica.

Também é importante você explicar aos seus alunos que o surgimento de uma nova linha da IA, não elimina as anteriores. E para isso você pode dar aos seus alunos vários exemplos de tecnologias atuais da IA, que utilizam IA simbólica junto com outras tecnologias de linhas mais novas da IA.

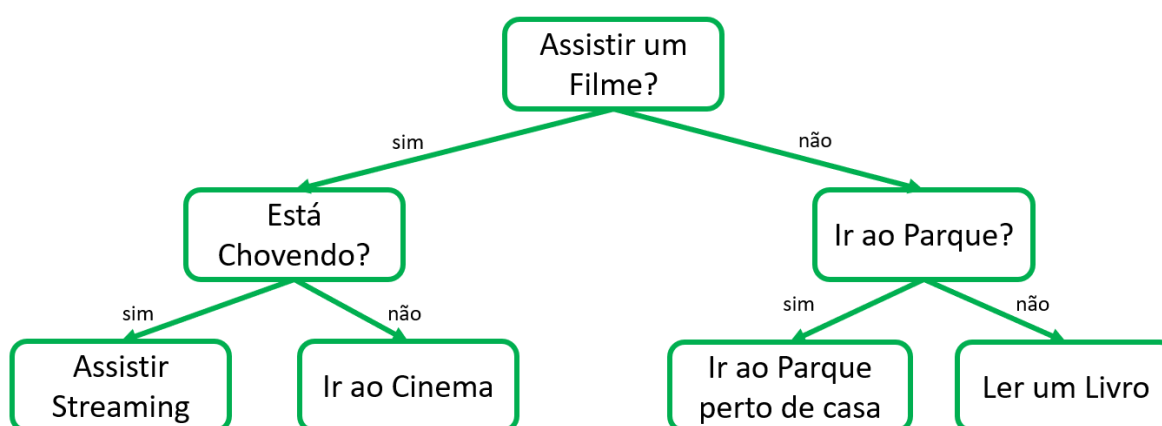
Os alunos podem fazer a árvore de suas famílias ou então, junto com a disciplina de história, pode ser feita a árvore genealógica da família imperial brasileira.

Uma versão online dos exemplos desenvolvidos neste capítulo estão disponíveis em <https://swish.swi-prolog.org/p/PIA-PROLOG.swinb>

## ÁRVORES DE DECISÃO AVANÇADAS

Uma árvore de decisão é uma estrutura hierárquica (um algoritmo) que representa uma sequência de decisões, permitindo a visualização dos resultados, custos e consequências de uma decisão complexa. Permite que um indivíduo ou organização compare possíveis ações com base em seus custos, probabilidades e benefícios. Ou seja, ela é um algoritmo de aprendizado de máquina supervisionado que é utilizado para classificação e para regressão. Isto é, pode ser usado para prever categorias discretas (sim ou não) e para prever valores numéricos (o valor do lucro de um investimento comparado com outro).

Assim como um fluxograma, a árvore de decisão estabelece nós (decision nodes) que se relacionam entre si por uma hierarquia. Existe o nó-raiz (root node), que é o mais importante, e os nós-folha (leaf nodes), que são os resultados finais. No contexto do aprendizado de máquina, o nodo raiz é um dos atributos da base de dados e o nó-folha é a classe ou o valor que será gerado como resposta. O exemplo vem do plano de aula do ano 1 - [Tema 2 – Classificação de animais](#). Nesse caso, o nó raiz é assistir a um filme. Existem dois caminhos de decisão. As folhas são os retângulos “assistir streaming”, “ir ao cinema”, “ir ao parque” e “ler um livro”.



Na ligação entre nós, temos regras de **se-então** (no caso de exemplo, sim ou não). Ao chegar em um nó, o algoritmo se pergunta acerca de uma regra, uma condição (por exemplo, “está chovendo?” ou “ir ao parque?”). A resposta a estas perguntas definirá o lado da árvore que será seguido. No próximo nó, segue a mesma lógica.

O algoritmo repete o mesmo comportamento a cada nível de profundidade da área de decisão (no exemplo existem apenas 2 níveis). Ou seja, é um algoritmo recursivo. É como se uma função chamasse a ela mesma como uma segunda função para uma execução paralela, da qual a primeira função depende para gerar sua resposta.

O grande trabalho da árvore é justamente encontrar os nós que vão ser encaixados em cada posição. **Quem é o nó raiz? Depois, quem será o nó da esquerda? E o da direita?**

Para descobrir quem será o nó raiz ou próximo nó, o algoritmo realiza alguns cálculos. Uma abordagem comum é usar o ganho de informação e a entropia. Essas duas variáveis dizem respeito à desorganização e falta de uniformidade nos dados. Quanto mais alta a entropia, mais

caóticos e misturados estão os dados. Quanto menor a entropia, mais uniforme e homogênea está a base. No caso do nosso exemplo, temos uma base homogênea. Para definir os posicionamentos, é preciso calcular a entropia das classes de saída e o ganho de informação dos atributos da base de dados. Quem tiver maior ganho de informação entre os atributos é o nó-raiz. Para calcular a esquerda e a direita, deve-se realizar novos cálculos de entropia e ganho com o conjunto de dados que atende à condição que leva à esquerda ou à direita. Ou seja, para dividir a base de dados em uma árvore, depende-se de condições. A partir delas, é possível dividir a base em caminhos com análise dos registros que satisfazem determinada condição. Se uma condição for “sabe nadar” para o lado direito, por exemplo, teremos somente os registros da base que correspondem aos animais aquáticos. Já se a condição for “sabe voar” para a esquerda, teremos somente registros dos animais aéreos para o lado esquerdo da árvore.

O ganho de informação é calculado a partir dessa lógica. Se quando se analisa um atributo, os registros das bases para cada lado são homogêneos ou próximos disso, o ganho de informação é alto. Afinal, sabemos que se optarmos por determinada condição, é muito provável que saibamos exatamente a saída esperada ou estejamos mais próximos de descobrir. Mas, se o ganho for pequeno, isso significa que os dados estão muito misturados e que estamos mais distantes de descobrir as saídas esperadas.

O algoritmo que analisa as árvores de decisão é chamado de ganancioso. Esse atributo se deve ao fato de que ele se foca na tarefa atual e não considera a árvore como um todo. Ou seja, quando está calculando o lado esquerdo de um nó, esse método não considera o lado direito.

Embora nosso exemplo de estudo seja bastante simples e considere apenas (sim ou não). Árvores de decisão são muito utilizadas para problemas com diversos rótulos (não binários). Ou seja, quando as categorias de classificação são múltiplas, e não apenas duas. Outros algoritmos, de IA, apresentam maior complexidade para tratar de casos não binários, mas com as árvores, cientistas de dados conseguem lidar com isso com facilidade.

Árvores de decisão também são boas para representar dados sem a necessidade de grande curadoria. Valores que ficam muito fora do padrão dos dados ou valores faltantes não chegam a ser prejudiciais. Pouquíssimas etapas de tratamento são necessárias. Os dados não precisam nem mesmo ser convertidos para informações numéricas, já que esse algoritmo também lida bem com informações categóricas (nominais). Mas, quando se trata do tratamento de imagens, se a opção for pela linguagem Python, existe um processo bastante trabalhoso para transformá-las em informações numéricas. Ainda, o algoritmo só apresenta bons resultados com muitos dados (imagens).



Aplicação em Sala de Aula:

Agora vamos utilizar a árvore de decisão abordada na sequência didática do 1º ano.

É importante redesenhar a árvore de decisão escolhendo perguntas de decisão, como: O animal tem pelos? O animal voa? O animal tem penas? O animal é viscoso? E assim por diante. A árvore de decisão vai classificar as espécies até chegar ao animal que se encaixa naqueles critérios.

## 1. Introdução ao Tema

Apresente questões aos seus alunos que precisam ser respondidas com um processo decisório. Por exemplo:

- Como diferenciamos objetos no dia a dia?
- Como saber se uma fruta é doce ou ácida?
- Como vocês decidem se um alimento é saudável?
- O que leva vocês a escolherem um filme para assistir?
- Como um médico pode identificar uma doença baseada em sintomas?

Assim que os estudantes entenderem que para tomar uma decisão, escolhas precisam ser feitas, você poderá introduzir os conceitos de Árvores de Decisão. De forma resumida, podemos explicar o que são árvores de decisão da seguinte forma:

- Estrutura usada para classificar informações com base em perguntas lógicas, sendo uma forma organizada de tomar decisões.
- Cada pergunta leva a um novo caminho, até chegar a uma conclusão.
- São amplamente usadas na IA para classificar e prever resultados.
- Permitem que um computador aprenda a classificar objetos sem intervenção humana.

Em outras palavras, as árvores de decisão são um modelo fundamental dentro da Inteligência Artificial e do aprendizado de máquina. Elas funcionam como um fluxograma de decisões, onde cada pergunta feita leva a uma nova ramificação até se chegar a uma resposta final. Esse tipo de estrutura é extremamente útil porque torna os processos de tomada de decisão transparentes e fáceis de interpretar, o que é essencial para muitas aplicações da IA. Em áreas como medicina, por exemplo, árvores de decisão podem ser usadas para ajudar na identificação de doenças, guiando os médicos com base nos sintomas do paciente. Da mesma forma, em sistemas de recomendação, elas podem auxiliar na sugestão de filmes, produtos ou até mesmo caminhos mais eficientes para deslocamento urbano. O grande diferencial desse modelo é sua capacidade de organizar e analisar dados de forma estruturada, facilitando tanto a explicação quanto a adaptação conforme novas informações são incluídas.

## 2. Construindo uma Árvore de Decisão Manualmente

Caso não se tenha mais a árvore criada no ano anterior, pode-se construir uma nova árvore. De início, é importante definir o objetivo da árvore: *Sobre o que queremos decidir*. Comece perguntando: *“Como podemos classificar animais de maneira lógica?”*. Pode seguir questionando os estudantes:

- O animal tem pelos? → Sim → Mamífero.
- O animal tem penas? → Sim → Ave.
- O animal vive na água? → Sim → Peixe ou anfíbio.

- O animal voa? → Sim → Pode ser uma ave ou um inseto.

Conforme o processo avança, outros questionamentos podem ser realizados para aprofundar a discussão:

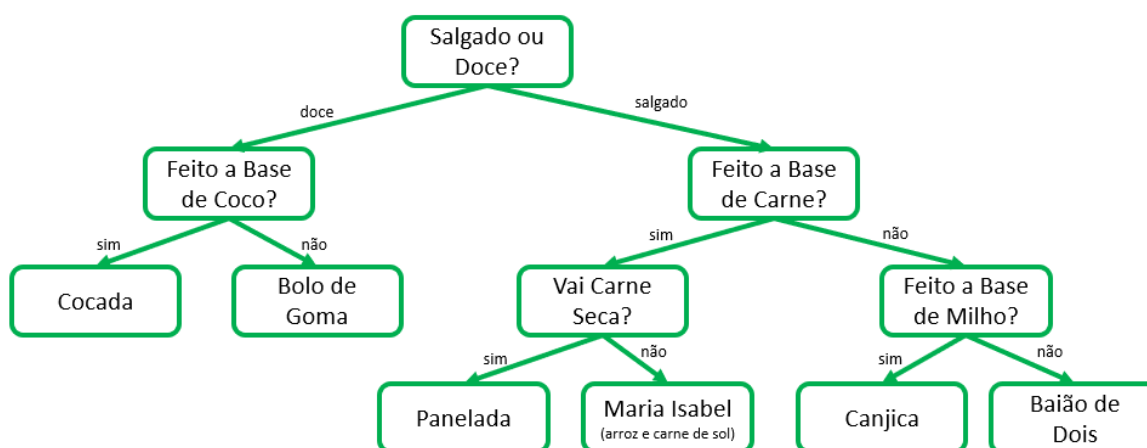
- Como podemos diferenciar um peixe de um anfíbio?
- Se encontrarmos um animal novo, como saber onde ele se encaixa?
- E se tivermos um animal que não se encaixa bem em nenhuma categoria?

A partir dessas discussões, pode-se apresentar algumas explicações aos estudantes. Com base no que foi apresentado anteriormente, as árvores de decisão funcionam organizando informações em grupos de acordo com perguntas objetivas. Cada pergunta ajuda a refinar a classificação, permitindo que os dados sejam segmentados de maneira lógica e progressiva até chegar a uma conclusão precisa. Esse método é amplamente utilizado porque pode ser aplicado a diferentes tipos de informações, desde a categorização de animais com base em características físicas até a organização de estilos musicais conforme a preferência do público. Além disso, as árvores de decisão são ferramentas que se adaptam a inúmeros cenários, capazes de lidar com diferentes contextos, como diagnósticos médicos, recomendação de produtos e análise de dados financeiros. Entretanto, algumas classificações podem apresentar desafios, especialmente quando um item compartilha características de mais de um grupo. **Por exemplo, um morcego tem pelos como um mamífero, mas também voa como um pássaro.** Essas situações exigem ajustes na árvore de decisão para garantir que o modelo continue representando corretamente a realidade e não gere classificações equivocadas.

Sugestões de exemplos de árvores para a aula:

A seguir serão apresentados dois exemplos de árvore de decisão, sendo a primeira um no contexto de escolha de pratos típicos enquanto o segundo será sobre classificação de animais.

### Escolhendo um Prato Típico



Essa árvore de decisão tem como objetivo ajudar na escolha de um prato típico do Piauí. Ela começa com uma pergunta inicial: *o prato é doce ou salgado?*. Se o aluno responder que o prato é **doce**, há uma nova pergunta para classificar melhor essa escolha: *o prato tem coco como ingrediente principal?*. Se a resposta for **sim**, a sugestão é **Cocada**. Se a resposta for **não**, então o prato indicado é **Bolo de Goma**.

Caso a resposta inicial indique que o prato **não é doce**, o próximo critério de decisão analisa se ele é *feito à base de carne*. Se for, o aluno é levado a uma nova decisão: *o prato usa carne seca?* Se **sim**, o resultado é **Panelada**. Se **não**, a sugestão é **Maria Isabel**, um prato típico feito com arroz e carne de sol.

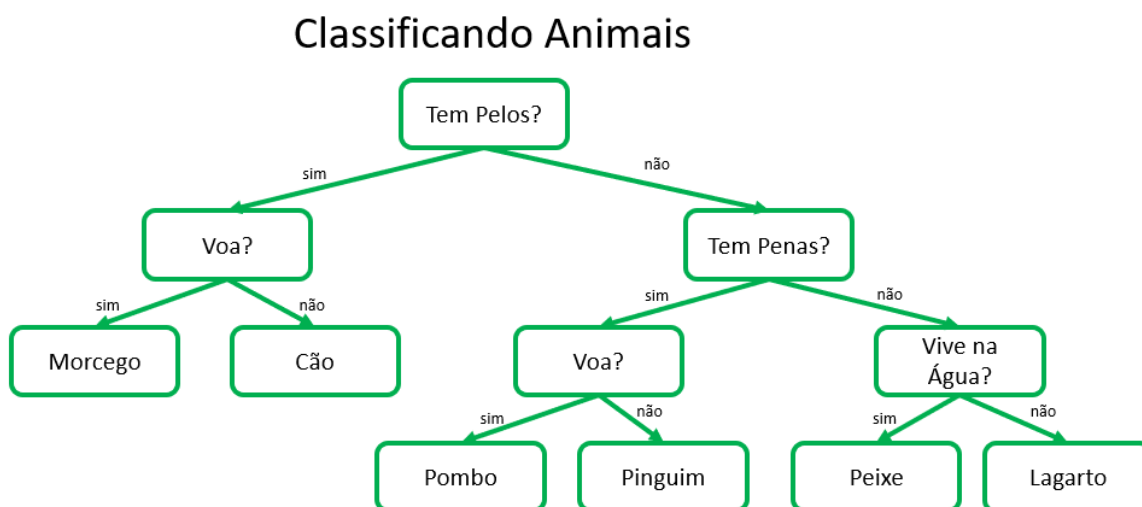
Se o prato não for de carne, a árvore faz uma última verificação: *o prato é à base de milho?* Se **sim**, o resultado será **Canjica**. Caso contrário, a árvore sugere **Baião de Dois**.

Essa estrutura permite que os alunos compreendam como um conjunto de perguntas simples pode organizar informações e classificá-las de forma lógica, tornando a tomada de decisão mais estruturada e compreensível.

Estrutura resumida da árvore de decisão:

1. O prato é doce?
  - Sim → Vá para a próxima pergunta.
  - Não → Vá para outra pergunta.
2. Se for doce, tem coco como ingrediente principal?
  - Sim → Cocada.
  - Não → Bolo de Goma.
3. Se for salgado, é feito à base de carne?
  - Sim → Vá para a próxima pergunta.
  - Não → Vá para outra pergunta.
4. Se for de carne, usa carne seca?
  - Sim → Panelada.
  - Não → Maria Isabel (arroz com carne de sol).
5. Se não for de carne, é à base de milho?
  - Sim → Canjica.
  - Não → Baião de Dois.

A seguir apresentamos um exemplo de árvore de decisão para classificação de animais. Recomendamos que essa árvore seja construída com os alunos ou utilizada como base para iniciar a atividade.



Esta árvore de decisão organiza os animais em grupos distintos com base em características físicas e hábitos de vida. O processo de classificação segue uma sequência de perguntas simples que direcionam a escolha até chegar ao animal correspondente.

Pergunta inicial: O animal tem pelos?

A primeira divisão da árvore é feita com base na presença ou ausência de pelos. Essa característica é essencial porque define um grupo específico de animais: os mamíferos.

- Se a resposta for "Sim" (Tem pelos): O animal pertence à classe dos mamíferos.
  - A próxima pergunta é: "O animal voa?"
  - Se sim, o animal classificado é Morcego, um mamífero que tem pelos e voa.
  - Se não, o animal classificado é Cão, um mamífero terrestre que não voa.
- Se a resposta for "Não" (Não tem pêlos): O animal não é um mamífero. Nesse caso, a árvore de decisão continua investigando outras características.

Segunda Distinção: O animal tem penas?

Se o animal não tem pelos, ele pode ser uma ave, um peixe ou um réptil. Para diferenciar, a próxima pergunta analisa a presença de penas, uma característica exclusiva das aves.

- Se a resposta for "Sim" (Tem penas): O animal é uma ave.
  - **OBS.:** Se não quisermos aprofundar, pode-se parar a essa divisão da árvore escolhendo uma ave. Contudo, para distinguirmos os animais, podemos fazer

---

uma nova pergunta, aprofundando ainda mais a análise e discussão com os estudantes.

- A próxima pergunta é: "O animal voa?"
- Se sim, o animal classificado é Pombo, uma ave que voa.
- Se não, o animal classificado é Pinguim, que apesar de ser uma ave, não voa.
- Se a resposta for "Não" (Não tem penas): O animal não é uma ave. Neste caso, precisamos investigar se ele é um animal aquático ou terrestre.

### 3. Última Distinção: O animal vive na água?

Se o animal não tem penas, ele pode ser um réptil ou um peixe. A última pergunta diferencia esses dois grupos.

- Se a resposta for "Sim" (Vive na água): O animal classificado é Peixe, que possui escamas e respira debaixo d'água.
- Se a resposta for "Não" (Não vive na água): O animal classificado é Lagarto, um réptil terrestre com escamas.

### 3. Reflexão sobre a Explicabilidade

Conforme destacado na introdução deste módulo, a IA simbólica tem várias vantagens, como **explicabilidade**, oferecendo transparência no processo de raciocínio e facilitando a compreensão acerca de como um sistema chegou a uma conclusão (seus objetivos são explícitos). Nesse sentido, sugere-se, após a discussão sobre a Árvore construída ou antes de iniciar a atividade prática, destacar algumas questões com os estudantes:

- Por que é importante entender como uma IA chega a uma decisão?
- Como garantir que um algoritmo de IA seja justo e imparcial?
- O que aconteceria se um sistema de IA classificar erroneamente um animal? Como corrigir?
- Apresente um caso problemático: "O morcego é um mamífero, mas voa. Como a árvore de decisão pode ser ajustada (ou foi proposta) para levar isso em conta?"
- O que significa IA explicável?
  - Um modelo de IA explicável permite que humanos entendam suas decisões.
  - A IA pode ser percorrida para explicar como chegou a um resultado.
- Duas formas de percorrer a árvore:

- De cima para baixo (dedutivo): Partimos das regras para classificar um novo exemplo.
- De baixo para cima (indutivo): Pegamos um exemplo e tentamos entender como foi classificado.

As árvores de decisão são um dos modelos mais **explicáveis** dentro da Inteligência Artificial. Sua estrutura baseada em regras claras permite que humanos possam acompanhar o processo de tomada de decisão, compreendendo exatamente quais critérios levaram a um determinado resultado. Diferente de modelos mais complexos, como redes neurais profundas, onde os cálculos internos podem ser difíceis de interpretar, as árvores de decisão oferecem transparência e rastreabilidade. Isso significa que qualquer erro ou inconsistência pode ser identificado e corrigido com mais facilidade.

Entretanto, à medida que a IA evolui ao longo do tempo e passa a lidar com grandes volumes de dados e padrões complexos, cientistas e empresas enfrentam o desafio de criar modelos que sejam ao mesmo tempo **eficientes e explicáveis**. Diversas técnicas vêm sendo desenvolvidas para aumentar a interpretabilidade dos sistemas de IA, garantindo que suas decisões possam ser compreendidas e justificadas. Isso é especialmente importante em áreas como saúde, finanças e segurança, onde a **transparência na tomada de decisão é essencial para evitar vieses** e garantir a confiabilidade dos modelos automatizados.

## Atividade Alternativa - Regras de Produção

Caso ocorram dificuldades em acessar o material disponibilizado e criado na linguagem Python, é possível transcrever as Árvores de Decisão na forma de Regras de Produção (RP). Uma regra de produção é um par condição-ação que define uma porção de conhecimento para solução de um problema. A condição da regra é um padrão que determina quando a regra pode ser aplicada para um caso do problema. A ação define o passo da solução do problema associado. Ou seja, uma regra de produção tem o formato **“Se então”** ou um par **condição-ação**. Veja que nesta técnica o raciocínio simbólico já faz parte (está embutido) no próprio método. **SE** for verdadeiro seguem uma linha de raciocínio, **SENÃO** segue outra linha de raciocínio.

Seu funcionamento segue o princípio: “Se esta condição se aplica, então esta ação é apropriada”. Durante a execução do algoritmo de regras de produção, uma RP cuja parte condicional é satisfeita pode ter a sua parte de ação executada pela linguagem de programação escolhida. Os fatos (dados) podem disparar as regras para que elas sejam aplicadas para a solução de um determinado problema.

Informação mais refinada para você professor ter maior domínio sobre o tema:

*RP são utilizadas desde o surgimento da IA. São algoritmos típicos da IA simbólica. Elas possuem algumas vantagens como, modularidade que resulta da representação do conhecimento sob a forma de regras independentes, o que facilita a inclusão e modificação de elementos do conhecimento; uniformidade da representação, que facilita a compreensão do conhecimento armazenado; naturalidade pois, as regras condição-ação podem ser utilizadas pelo*

*desenvolvedor para expressar o conhecimento. Mas, também possuem pontos fracos, como ineficiência de execução em função da modularidade; dificuldade de seguir o fluxo de controle do sistema e dificuldade de verificar a coerência entre as regras; pouca estruturação (hierarquia).*

Exemplo de estruturação de um algoritmo simples (você pode usar este ou outro algoritmos qualquer encontrado na bibliografia de IA) no formato regra de produção, que ajuda a diagnosticar se uma pessoa necessita ou não de óculos (presbiopia significa perda de visão):

**Se** prescrição de óculos = hipermetropia

**e** astigmatismo = não

**e** taxa de produção de lágrima = normal **então** recomendação = gelatinosa

**Se** idade = jovem

**e** astigmatismo = não

**e** taxa de produção de lágrima = normal **então** recomendação = gelatinosa

**Se** idade = pré-presbiopia

**e** astigmatismo = não

**e** taxa de produção de lágrima = normal **então** recomendação = gelatinosa

**Se** prescrição de óculos = miopia

**e** astigmatismo = sim

**e** taxa de produção de lágrima = normal **então** recomendação = dura

**Se** idade = jovem

**e** astigmatismo = sim

**e** taxa de produção de lágrima = normal **então** recomendação = dura

**Se** taxa de produção de lágrima = reduzida **então** recomendação = nenhuma

**Se** idade = pré-presbiopia

**e** prescrição de óculos = hipermetropia

**e** astigmatismo = sim **então** recomendação = nenhuma

**Se** idade = presbiopia

**e** prescrição de óculos = hipermetropia

**e** astigmatismo = sim **então** recomendação = nenhuma

**Se** idade = presbiopia

**e** prescrição de óculos = miopia

**e** astigmatismo = não

**e** taxa de produção de lágrima = normal **então** recomendação = nenhuma

Veja que todas as possíveis decisões são programadas e é possível seguir o raciocínio utilizado pelo algoritmo para a tomada de decisão. Ou seja, é explicável e auditável. Ainda, RP são aplicação direta de lógica de predicados.

 Material complementar: [regras de produção em python](#)

Após ver o vídeo você conseguirá programar o exemplo acima ou o exemplo da classificação de animais (Ver plano de aula do ano 1 - Classificação de animais) em Python. Caso não consiga, é aconselhável sempre recorrer ao tutor.

O trabalho com regras de produção é bastante simples. Você pode trabalhar este exemplo, tanto na forma conectada, como desconectada. Este plano de aula ficará a seu encargo.

Ao longo deste capítulo, vimos que a **IA simbólica** organiza o conhecimento por meio de fatos, regras e inferências lógicas, como fizemos com a família Pinheiro em Prolog. No entanto, além de representar relações por meio de predicados e axiomas formais, também é possível estruturar esse mesmo conhecimento em forma de rede, evidenciando explicitamente os nós (conceitos ou indivíduos) e as ligações que os conectam. É exatamente nesse ponto que avançamos para o próximo capítulo: as Redes Semânticas. Se na lógica de predicados descrevemos relações como `progenitor(maria,joao)` ou `avo(jose,mario)`, nas **redes semânticas** essas informações passam a ser organizadas graficamente, mostrando como os conceitos se relacionam em uma estrutura interligada. Assim, mantemos a perspectiva simbólica — baseada em representação explícita do conhecimento —, mas ampliamos a forma de visualização e organização das relações, tornando mais intuitiva a compreensão das hierarquias, heranças e conexões conceituais que sustentam o raciocínio em sistemas de IA.

## REDES SEMÂNTICAS

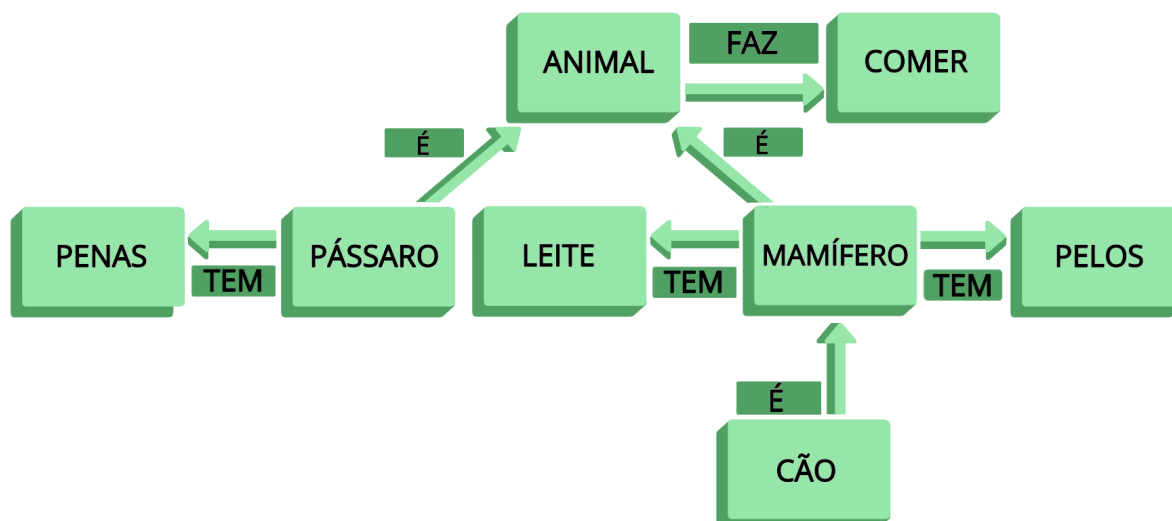
Uma **rede semântica** é um sistema de representação do conhecimento estabelecido pelo contexto e imbuído de intenção de funcionalidade. Elas são uma forma de representar relações entre objetos e ideias. Este é outro método de IA simbólica que trabalha com o conhecimento e sua representação. Ou seja, uma rede semântica é composta por:

- Vértices (nós): palavras, conceitos ou entidades com significado (por exemplo, “gato”, “mamífero” ou “carne”).
- Arestas (conexões): representam as relações entre esses conceitos (por exemplo, “é”, “tem”, “gosta”).


Assim, podemos dizer que uma rede semântica é uma forma de IA simbólica que trabalha com o conhecimento por meio das relações entre esses conceitos. A matemática por trás dessa representação é a teoria de grafos. As redes semânticas são representadas matematicamente por um grafo  $G = (V, E)$ . Um grafo é uma estrutura matemática que consiste em dois conjuntos:  $V$  (finito e não vazio que contém os vértices) e  $E$  (relação binária sobre  $V$  que contém as arestas). Um exemplo pode ser visto na figura a seguir.

### Exemplo de Rede Semântica

Na figura a seguir, temos vértices que são como conceitos (animal, mamífero, pássaro, cão) e arestas que representam relações binárias (de um para um) entre os vértices, como por exemplo: pássaro é um animal, cão é um mamífero e é um animal, entre outros. Todas as arestas são orientadas e existem as relações entre as classes e subclasse **é**, e entre atributos de uma classe ou subclasse **faz** e **tem**. O nodo raiz (outro nome comumente utilizado na literatura para se referir à vértice) é a classe **animal** e os nodos folha são **pássaro** e **cão**. **Pelos** e **comer** são atributos respectivamente, de **animal** e de **mamífero**.




Por meio dessas conexões, a rede semântica organiza conceitos de forma que tanto humanos quanto sistemas de IA possam **entender e inferir** informações sobre esses elementos. Essas redes podem ajudar os sistemas de IA, e aos humanos também, a compreender o conhecimento do **senso comum**.

 Senso comum: é um tipo de conhecimento popular, adquirido pela observação e pela repetição, que não foi testado metodicamente

## Por que usar Redes Semânticas?

As redes semânticas ajudam a relacionar conceitos de forma clara e hierárquica, sem envolver cálculos estatísticos avançados. Pelo contrário, elas utilizam a representação simbólica do conhecimento, facilitando a criação de explicações e a compreensão de como o sistema chega a uma conclusão (IA explicável). Nesse sentido, muitas vezes, as redes semânticas incluem informações de senso comum (“gato tem bigodes”, “gato gosta de carne”), que ajudam a IA (ou os alunos) a lidar com conhecimento cotidiano.

 Aplicação em Sala de Aula:

Podemos escolher animais como tema central, mas também é possível trabalhar com qualquer outro domínio: família, instrumentos musicais, objetos do dia a dia, entre outros.

Aqui vamos considerar o tema animais, onde os vértices da rede serão figuras dos animais. Estes objetos estarão conectados de alguma maneira. As conexões são orientadas. Elas representam relacionamentos entre objetos ou conceitos.

Nosso exemplo utiliza três tipos de relacionamentos distintos: **É**, **TEM** e **GOSTA**. Por exemplo, uma rede pode informar a relação entre diferentes animais (o gato **é** um mamífero, o gato **tem** bigodes, o gato **gosta** de carne). Exemplo de situações que podem ser representadas (você pode escolher as características para representar na rede, cuidando sempre para que as escolhas possibilitem a identificação do conceito que está sendo representado):

- **É** um animal carnívoro;
- **Tem** bigodes;
- **Gosta** de carne;
- Família **tem** gato

## Planejamento Prático

Materiais

- Folha de cartolina (ou grande superfície) para fixar a rede.
- Figuras recortadas: as figuras vão representar os objetos ou os conceitos (animais, pessoas, objetos, instrumentos musicais etc.).

- Fios ou linhas de várias cores: Corte pedaços do fio de linha, no tamanho aproximado de 20cm. Corte ainda um conjunto de fios de aproximadamente 5cm para fazer as setas que irão direcionar a sua rede.
- Etiquetas ou cartões de cartolina para as relações (por exemplo, “É”, “Tem”, “Gosta”).

As Figuras irão representar os conceitos e as linhas irão representar as conexões orientadas entre estes objetos ou ideias enquanto que as conexões representam relacionamentos entre os objetos ou conceitos. Você pode usar três conjuntos de peças quadradas (figuras recortadas) de objetos/conceitos, por exemplo: 1) família, 1) animais e 3) instrumentos musicais. Além disso, você tem conjuntos de setas com os diferentes tipos de relacionamento: **É**, **TEM**, **GOSTA**, etc. Cada uma das cores que você selecionou nos materiais, irá representar um tipo de relacionamento.

### Montagem

- Distribua as figuras na mesa ou no chão fora da folha de cartolina, que deve estar aberta para receber a rede que será construída.
- Separe as figuras por categorias. Por exemplo, em uma turma, podem ser animais, família e instrumentos musicais.
- Escolha relações principais para cada conjunto. Exemplos:
  - “é um animal carnívoro”, “tem bigodes”, “gosta de carne” (para animais)
  - “é um membro da família”, “tem laços de parentesco” (para família)
  - “é de corda”, “gosta de samba” (para instrumentos musicais)
- Conecte as figuras às relações usando fios e setas, formando caminhos que indicam como os conceitos se relacionam.

### **Exemplo de Fatos**

Você pode escolher as características para representar na rede, cuidando sempre para que as escolhas possibilitem a identificação do conceito que está sendo representado:

- “Gato **TEM** bigodes”
- “Gato **É** um mamífero”
- “Família **TEM** gato”
- “Mamífero **GOSTA** de carne”

### **Finalização da Rede**

- Garanta que todas as setas estejam orientadas (ponta da seta indicando a direção) e que os rótulos estejam voltados para a mesma direção.
- Coloque todos os elementos dentro dos limites da cartolina, de modo que o trabalho fique organizado e visualmente limpo.

## Etapa de Aprendizado

Depois da rede ter sido construída, você discutir com seus estudantes:

- Verifique se as relações fazem sentido: um gato realmente tem bigodes e é um mamífero?
- Discuta com os alunos a possibilidade de relações falsas ou incompletas, introduzindo o conceito de viés e revisão de conhecimento.
- Exemplifique como um chatbot ou outro programa de IA simbólica poderia usar essa rede: caso o aluno pergunte “gato tem bigodes?”, o sistema (ou o próprio aluno ao consultar a rede) perceberá o nó “gato” conectado à relação “tem” e, em seguida, ao nó “bigodes”. A resposta, portanto, é “Sim, o gato tem bigodes.”

Essa atividade pode ser feita tanto desconectada (apenas com a cartolina) quanto conectada (caso seja possível inserir os dados em um chatbot). Para integrar com um chatbot é possível determinar para ele todas as relações ou construir a rede fisicamente, como na atividade, fotografá-la e inseri-la no chatbot. Após isso, ele poderá responder a perguntas que envolvam os conceitos e os relacionamentos que você estabeleceu na rede. Por exemplo, você pode perguntar: gatos têm bigodes? e o chatbot, ou você mesmo pode seguir os relacionamentos estabelecidos a partir do conceito "gato" e encontrar uma seta como o relacionamento "tem" apontado para bigodes. Nesse sentido, a resposta deverá ser: sim, gatos tem bigodes. Esse procedimento pode ser repetido quantas vezes julgar necessário e o conhecimento presente ou não na rede permite respostas como **sim**, **não** ou **desconheço**.

## Sugestões Pedagógicas

- Explorar diferenças: É interessante comparar essa representação simbólica com outros métodos de IA, como árvores de decisão ou algoritmos estatísticos.
- Refletir sobre a veracidade: Discutir com os alunos se todas as informações ali contidas são verdades absolutas ou apenas reflexo de crenças ou observações dos participantes.
- Criar perguntas: Estimular os estudantes a elaborarem questões sobre os conceitos conectados na rede. Podem surgir perguntas como “por que o pássaro está na mesma categoria que o gato, se um voa e o outro não?”, fomentando o pensamento crítico.

## Considerações Finais

Este plano de aula será no modelo desconectado, mas você pode utilizar, como sugerido, um chatbot para realizar este experimento de uso da IA simbólica, de forma conectada. A sequência didática da aula 2 (fundamentos da IA simbólica) pode ser composta por 4 planos de aula. Estamos fornecendo 2 deles. Este aborda redes semânticas de forma desconectada. Este material tem a sugestão de 2 planos de aula. Mas você pode fazer vários planos a partir dele. Pode ser criado um plano para regras de produção e outro para revisar a linha do tempo da IA até 1980, por exemplo.

Na próxima aula vocês continuarão tratando da IA com a aula sobre redes neurais, seguindo a ordem cronológica do surgimento das tecnologias e conceitos que compõem a IA

# MÓDULO 2

## REDES NEURAIS ARTIFICIAIS

### **Objetivo do Módulo:**

Ao final do módulo os professores participantes deverão ser capazes de entender neurônios artificiais e como eles se organizam em redes neurais.

### **Contempla:**

AULA 03 - Introdução ao Neurônio Artificial

AULA 04 - Redes de Neurônios Artificiais

AULA 05 - Aprofundando as Redes de Neurônios Artificiais

## INTRODUÇÃO AO NEURÔNIO ARTIFICIAL

### Introdução

Redes Neurais Artificiais (RNs) são uma das técnicas mais famosas de Inteligência Artificial. Sua origem está numa área interdisciplinar, na biologia, no estudo do sistema nervoso dos animais. Neste material, vamos estudar um pouco da história e da teoria das RNs, buscando compreender como elas são capazes de modelar o mundo, e quais as suas limitações.

### Inspirações Biológicas e o Neurônio Artificial


Animais mais complexos possuem um sistema biológico especializado para lidar com seus comportamentos. Por meio dele, é possível não apenas coordenar ações de diferentes órgãos, mas também de perceber o mundo e agir de acordo.

Graças ao sistema nervoso, podemos observar e planejar, criar métodos para alcançar um objetivo. Pode parecer simples, mas o simples ato de levantar e caminhar até a porta é extremamente complexo, exigindo reconhecer objetos, imaginar caminhos e compará-los, além de movimentar as pernas e equilibrar-se. Esses passos ocorrem, muitas vezes, simultaneamente.

Computadores são máquinas sequenciais, que realizam comandos conhecidos sobre dados. Eles fazem apenas o que o programador as manda fazer, não tendo capacidade de se adaptar, de corrigir erros e de planejar, ao menos não sem que sejam programadas para isso. Mas será que não há um atalho? Será que não podemos programar um computador para simular um sistema nervoso?

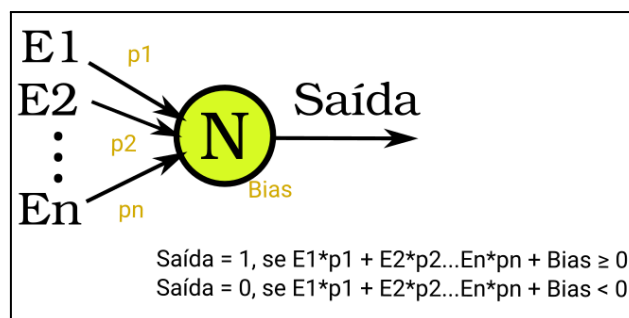
Uma das regras do Pensamento Computacional é “dividir para conquistar”, analisar um problema a partir de suas menores partes. No caso do sistema nervoso, a sua menor parte é o neurônio, a célula especial que o constitui.

Um neurônio é constituído de três partes, os **dendritos**, que recebem sinais, o **axônio**, que envia sinais, e o **soma**, que é o corpo celular e que determina quando o neurônio dispara, ou seja, envia sinais. De acordo com um dos primeiros modelos de neurônios, o Mccullough-Pitts, criado em 1948, o neurônio é excitado pelos neurônios. Quando alcançar um determinado nível de excitação, ele dispara, enviando sinais pelo axônio que vão excitar outros neurônios.



Em 1957, um engenheiro, Frank Rosenblatt, decidiu usar essa arquitetura. Seu objetivo, trabalhando para o projeto de inteligência aeroespacial, era construir um detector de imagens, que ele propôs na forma de um detector de caracteres. Como um programa para detectar imagens é algo complexo e limitado, sendo capaz apenas de detectar as imagens para as quais

foi programado para, Rosenblatt pensou em uma abordagem mais ampla. Ele decidiu simular um sistema nervoso, de modo a poder treiná-lo em diferentes imagens. Para isso, criou um modelo matemático simplificado de neurônio artificial que seria chamado de Perceptron.



Como um neurônio real, o perceptron é composto de **entradas**, equivalentes aos dendritos, uma **função de ativação**, equivalente ao soma, e uma **saída**, equivalente ao axônio. Além disso, cada entrada terá um valor de peso e a função de ativação também terá um bias, um valor interno de viés. Vamos usar o valor de 0 para conexões (entradas e saídas) desativadas e 1 para as ativadas. Assim, dependendo do número de entradas ativadas, a função de ativação vai determinar um valor 0 ou 1 para a saída. De uma maneira mais direta:

A saída terá o valor de 1 se a soma do produto das entradas pelos seus pesos e do bias for maior ou igual a zero. Se não, terá o valor de 0.

Note que os pesos e o bias podem ser tanto valores positivos, valores excitatórios, quanto negativos, inibitórios.

## Aproximações, Treinamento e Representações


O Perceptron foi bem-sucedido em sua tarefa, Rosenblatt conseguiu construir uma máquina de reconhecer caracteres que usava vários Perceptrons ligados em rede. Ela aprendia não por ser programada com a forma de cada caracter, mas sendo ajustada a partir de informações que lhes eram apresentadas. Apesar disso, a área das redes neurais não continuaria a se desenvolver por muitos anos. O motivo foi simples, não havia poder computacional suficiente, memória e velocidade de processamento, para realizar tarefas mais complexas. Esse foi o “inverno da IA”, e demoraria mais de uma década para que os investimentos fossem retomados na área.

Mas havia algo dentro do Perceptron, algo que não foi muito discutido na época. O neurônio artificial não precisa ser binário, mas pode lidar com qualquer valor que lhe for dado. Um neurônio linear com uma entrada nada mais é do que uma função linear se o seu valor for positivo:  $f(x) = a \cdot x + b$ .

Proporções não são apenas um tipo de conta matemática, são, também, uma habilidade mental. Se temos uma receita que faz um bolo para uma pessoa, podemos dobrar a quantidade de ingredientes para fazer bolo para duas pessoas. Esta é uma heurística, uma aproximação, que estende a informação inicial (como fazer bolo para uma pessoa) para outros casos (podemos pensar como fazer bolo para cinco pessoas também). Portanto, no centro do neurônio artificial há uma capacidade de extrapolação.

Um procedimento matemático mais rigoroso é a interpolação linear, muito usado em ciências químicas e biológicas. Se imaginamos que há dois dados que são linearmente relacionados, podemos criar um modelo para ele através de medidas. Fazemos uma, duas, três, n medidas e vamos anotando as relações (por exemplo, concentração de uma substância na água e a mudança do seu ponto de congelamento). Talvez por que a relação não seja exatamente linear, ou por interferências de fatores externos, ou talvez por erros nas medidas, nós dificilmente teremos uma única reta que passa por todos os pontos. Vamos precisar encontrar a reta que melhor passa por entre os pontos, que menos comete erros.


Estamos falando de uma aproximação, que também generaliza. Estamos criando um modelo para um fenômeno. O impressionante é que isso pode ser feito de forma automática, usando um algoritmo que, para cada ponto, calcula um erro, ou uma perda, como sendo a distância entre o ponto da função e da medida. Esse algoritmo pode ir ajustando as retas de acordo com a redução ou o aumento da perda!



Além disso, neurônios com várias entradas possuem uma multidimensionalidade, não representando apenas retas num plano cartesiano, mas num espaço. É possível que haja mais do que três dimensões, o que leva a possibilidade de modelar fenômenos bem complexos a partir do mesmo princípio.

## Redes Neurais, Aprendizagem e o Teorema da Aproximação Universal

Se utilizarmos vários neurônios, podemos construir uma rede neural. O que é interessante é que podemos utilizar vários neurônios em sequência, utilizando a saída de um como entrada para o próximo. Isso nos permite escapar dos limites de uma simples função linear, compondo formas mais complexas, é o chamado teorema da aproximação universal. Quanto mais neurônios utilizarmos, mais próximo será o resultado.



Quando construímos redes neurais (RN), temos apenas três partes, uma camada de entrada, que será responsável por receber os dados, uma de saída, que vai apresentar os resultados, e as chamadas camadas ocultas, nem sempre necessárias, que representam as aproximações necessárias para o modelo. Uma RN pode ter vários neurônios em suas camadas, e elas não precisam ser “uma depois da outra”, redes recorrentes retroalimentam a saída de um neurônio em sua entrada, e não é incomum que hajam “pulos” das camadas. Podemos pensar que cada

---

caminho entre as entradas e as saídas representa uma função possível de modelagem de dados, e lembre-se de que eles são espalhados por várias dimensões!

O que nos falta agora é uma maneira de treinar a rede e, para isso, há o algoritmo de backpropagation. Desenvolvido no início da década de 80, ele é uma forma de ajustar os pesos e biases dos neurônios. Esse algoritmo divide a perda atual entre as entradas, multiplicando, em cada uma delas, o peso e a derivada da função no ponto. Isso permite “propagar para trás” um erro geral, criando a possibilidade de treinar a rede a partir de exemplos, o que chamamos de **aprendizagem supervisionada**.

Podemos pensar em uma RN como uma série de funções matemáticas que vão “filtrando” as informações de entrada para categorizá-las a partir dos neurônios de saída. Podemos imaginar uma rede com 10 neurônios de saída, cada um representando um número reconhecido, o seu valor numérico é a confiança da rede na sua classificação!

## Conclusões

Desde o lançamento dos microprocessadores, na década de 70, os computadores têm se desenvolvido em uma velocidade exponencial. Desde a década de 2000, temos um poder computacional suficiente para utilizar uma técnica custosa como as RNs. A última novidade foi a arquitetura transformer, muito utilizada nos GPTs e outros geradores de texto e imagem, que simplifica os cálculos necessários para treinar e utilizar a rede.

O chatGPT na versão 4.0 possui 1,8 trilhões de parâmetros, de pesos e biases, que foram treinados com cerca de 10 trilhões de palavras no decorrer de seis meses. Podemos pensar na complexidade desse sistema, e na quantidade de energia necessária para construí-lo. Isso tudo só foi possível porque as redes neurais possuem uma grande autonomia, exigindo pouca interferência humana para serem treinadas. Podemos imaginar que elas se tornarão um lugar comum na pesquisa e no desenvolvimento, sendo capazes de processar vastas quantidades de dados.

## ÉTICA E TREINAMENTO DE REDES NEURAIS ARTIFICIAIS

Redes Neurais artificiais são um dos primeiros algoritmos de Aprendizagem de Máquina (AM) que encontramos e que são relativamente fáceis de serem compreendidos. Isso significa que estes algoritmos aprendem, ou seja, extraem informações de forma autônoma, com pouca ou nenhuma supervisão de seres humanos, aproximando-os a modelos matemáticos.

Por um lado, a AM permite processar grandes volumes de dados. Ela nos permite encontrar soluções adequadas para modelar dados meteorológicos, por exemplo, levando em conta séries temporais gigantescas; Ela também pode trabalhar com dados que não são intuitivos, não são facilmente compreendidos por seres humanos, como dados de câmeras ou de sensores posicionais de um carro autônomo. Por outro lado, a AM possui um grau de autonomia que escapa do seu programador, ela pode gerar soluções inadequadas ou inusitadas. As primeiras questões que aparecem podem ser chamadas de *overfitting* e *underfitting*.

Vamos a um primeiro exemplo, um programador quer construir um sistema de reconhecimento de imagens de maçãs e bananas e utiliza um conjunto de imagens de treinamento. Após ser treinado, não é incomum que o sistema simplesmente reconheça apenas as imagens de seu conjunto de treinamento, o que chamamos de *overfitting*. Assim, se apresentarmos fotos de maçãs ou bananas, especialmente em novas posições, ele não possui capacidades transversais. Um problema similar ocorre com o *underfitting*, quando o modelo não é capaz de reconhecer nem mesmo o conjunto de treinamento original.

Balancar uma IA entre o *overfitting* e o *underfitting* é a chave para que o sistema funcione bem, e isso depende de um conjunto de treinamento bem selecionado e diverso. A garantia de um bom funcionamento do sistema, que será usado para análises e decisões, é imperativa. Mas isso não é tudo. Nem sempre, na verdade quase nunca, estaremos alimentando um algoritmo de IA com os dados completos. Vamos imaginar uma rede neural que é alimentada puramente com uma imagem, cada pixel (ou ponto) da imagem é sinal para a camada de entrada. Uma imagem de alta definição, hoje, tem cerca de 2 milhões de pixels, imagine o quão custos, em termos computacionais, seria para se trabalhar com ela.

Geralmente, alimentamos algoritmos de AM com *features*, ou seja, atributos dos dados. Esses são simplificações dos fenômenos que serão modelados. Atributos podem ser características dos dados, por exemplo médias, ou mesmo medidas que forem feitas. A sua escolha pode ser tão impactante quanto os dados coletados.

Um exemplo real é a aplicação de uma IA para fazer estimativas de preços de imóveis. Podemos pensar nas *features* com as quais ele seria alimentado para relacionar com o preço, tais como a metragem do imóvel, o andar, a distância a uma parada de ônibus... Mas questões éticas começam a surgir com a escolha desses atributos, se usarmos o preço médio dos imóveis de um bairro, podemos começar a implicar no sistema uma distinção entre centro e periferia. Há *features* ainda mais sensíveis, como dados censitários como referentes aos perfis socioeconômicos e raciais. Essas escolhas podem levar a IA a ter inferências discriminatórias.

Há um terceiro problema, que é o uso da IA. Há uma diferença bem grande entre usar um sistema para estimar preços de imóveis, e um que tomará a decisão do preço. Uma IA é uma máquina, e não pode ser responsabilizada por suas decisões, mas ela também não é determinística, e algumas vezes surpreende mesmo os seus projetistas e usuários. Definir onde ela será aplicada e se haverá pessoas responsáveis por sua aplicação ética e segura também está se tornando uma necessidade. Assim, a ética na Aprendizagem de Máquina pode ser entendida em três questões:

- Os dados com os quais alimentamos a IA foram adquiridos de maneira ética? Respeitam a privacidade e os direitos sobre dados pessoais?
- As *features* e as inferências realizadas pela IA são feitas de forma ética? Elas possuem algum tipo de discriminação inata?
- O funcionamento do sistema é estável e confiável? Há uma cadeia de responsabilidade sobre o uso dessa tecnologia?

Mais a frente, vamos ver como está se formando um entendimento jurídico sobre como as IAs devem funcionar.

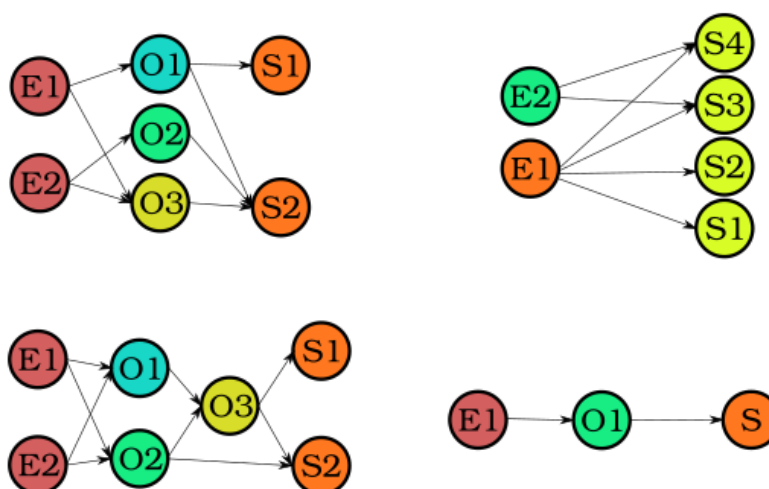
## REDES DE NEURÔNIOS ARTIFICIAIS

### Introdução

Neurônios artificiais são pequenas unidades que podem ser ligadas para criar diferentes funções. Essas funções podem ser usadas para criar modelos de fenômenos físicos e sociais, mas o seu resultado depende de um conjunto de dados a partir do qual ele pode ser ajustado para representar a realidade. Nesta seção, vamos ver como a arquitetura de uma rede de neurônios influencia o seu desempenho.

### Redes de Neurônios e Backpropagation.

Quando vários neurônios são conectados, temos uma rede neural, e chamamos essas áreas de camadas, a camada de entrada (E), que recebe os dados do mundo externo, e a camada de saída (S), que envia os dados para o mesmo mundo externo. Entre as duas, podemos ter camadas intermediárias, chamadas de camadas ocultas (O). As ligações e a conexão com os neurônios depende do projeto da rede.



Essas redes ganham a capacidade de desenhar funções bastante complexas, podendo mapear entradas e saídas. A rede pode aprender relações diretas entre dados ou símbolos, que serão generalizadas (pois interpolamos uma função aos dados), criando um “conhecimento de máquina”.

A configuração de uma rede neural depende inteiramente do modelo que queremos criar, mas, geralmente, ela deve ter um número de entradas e saídas de acordo com a quantidade de dados que queremos mapear. Mas como podemos configurar (ou treinar) uma rede neural que tenha tantos elementos e ligações?

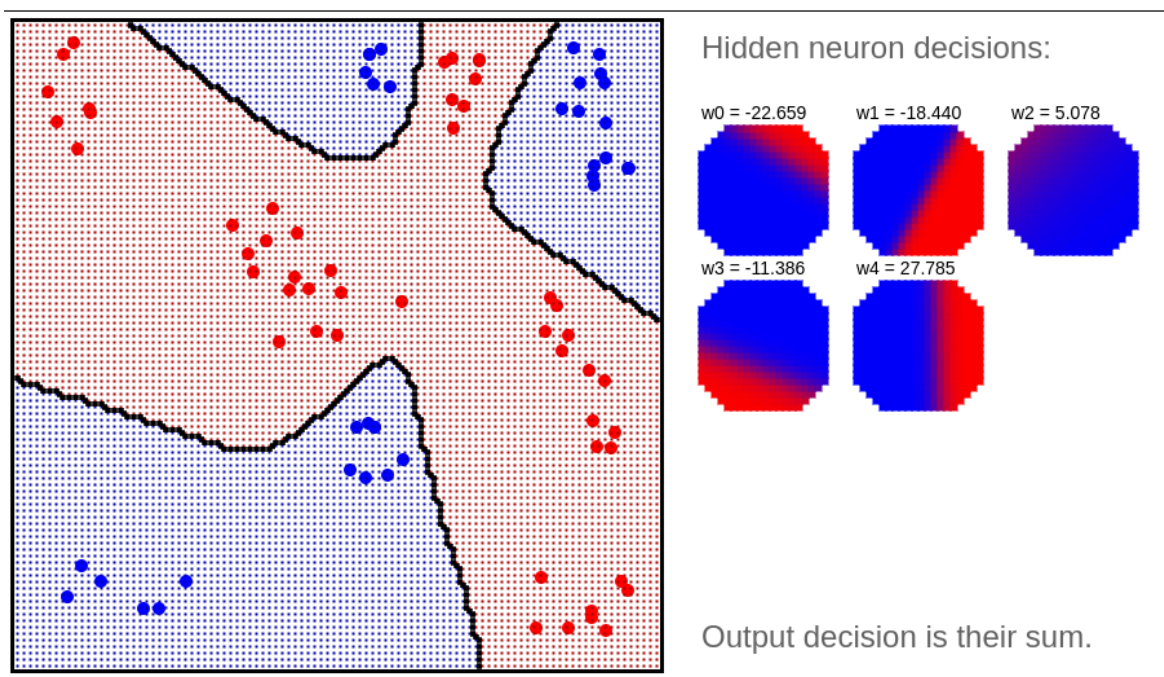
A ideia é usar a mesma técnica que usamos num neurônio, o cálculo da perda. Mas, dessa vez, nós passamos a perda de trás para a frente, por dentro da rede neural, isso é chamado de backpropagation. Esse algoritmo normalmente é aplicado na chamada aprendizagem supervisionada, quando há um conjunto de treinamento preparado, um grupo de entradas e suas saídas esperadas pela rede. O treinamento ocorre da seguinte forma:

- Aplicamos uma entrada à rede neural e observamos a saída. Caso ela não esteja adequada, caso os neurônios de saída não apresentem os resultados esperados, aplicamos o backpropagation.
  - Comece calculando a perda para a entrada, em seguida ela deve ser propagada de trás para a frente pela rede neural, por cada uma das camadas, encontrando a contribuição de cada conexão do neurônio com a perda.
    - Isso requer cálculos extensivos multiplicando o erro pelos pesos de cada neurônio e pela derivada da função de ativação no ponto.
    - Após esses cálculos, vamos ter um vetor que indica todas as contribuições de cada conexão para o erro final. Mudamos os valores de acordo com uma taxa de aprendizado, uma sensibilidade geral definida pelos projetistas
  - Notadamente, essa técnica é extremamente custosa, exigindo muitos cálculos.
- O processo é repetido várias vezes até a perda ser reduzida a um nível satisfatório.

Você pode visualizar o treinamento de uma rede neural com um simulador, como o abaixo:

- <https://www.ccom.ucsd.edu/~cdeotte/programs/neuralnetwork.html>

O seu funcionamento é simples, há um canva no qual podemos clicar com o botão direito do mouse para inserir pontos vermelhos e com o botão esquerdo para inserir pontos azuis. Quando clicamos em START Learning, a rede neural começa a ser treinada para tentar criar classificações, desenhando áreas vermelhas onde estão os pontos vermelhos e azuis onde estão os outros pontos.

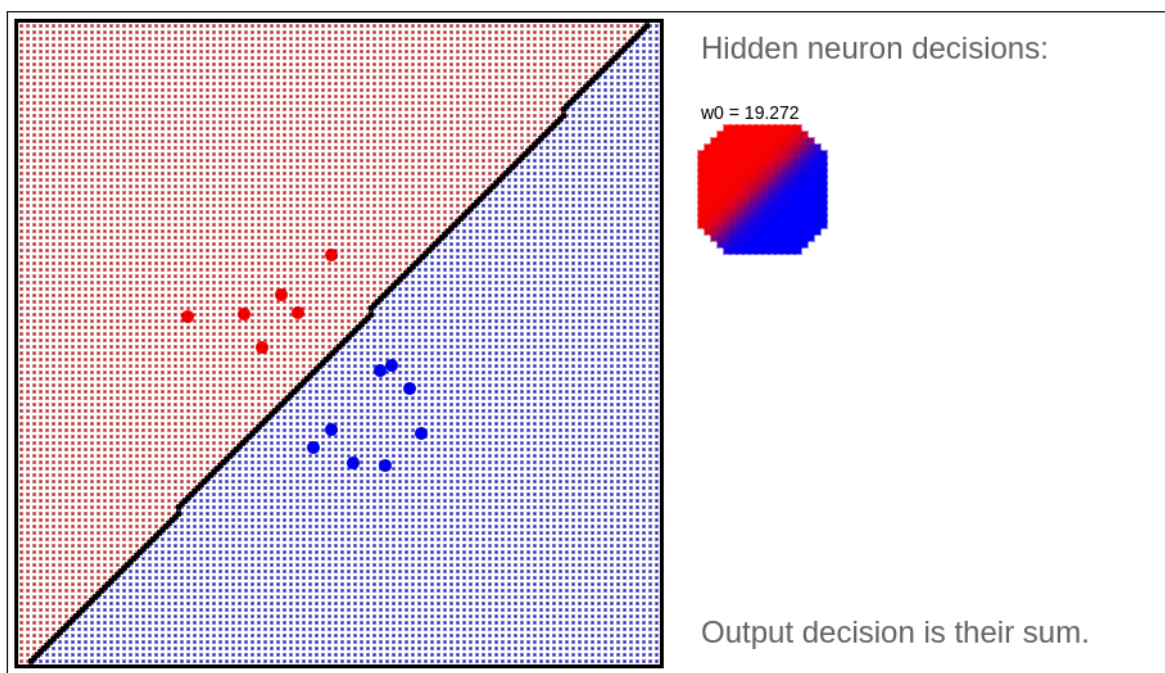


Enquanto a rede é treinada, podemos ir adicionando novos pontos. Há também o botão Reset learn, que faz com que a rede neural esqueça o que aprendeu até o momento e o botão Clear points que limpa o canvas. Há também o parâmetro H, que adiciona neurônios à rede oculta, podendo ser de um neurônio a nove, e uma anotação sobre as *training epochs*, o número de passadas de backpropagation pela rede.

Observe a relação do parâmetro H na hora que você vai desenhar diferentes curvas, configurando o sistema:

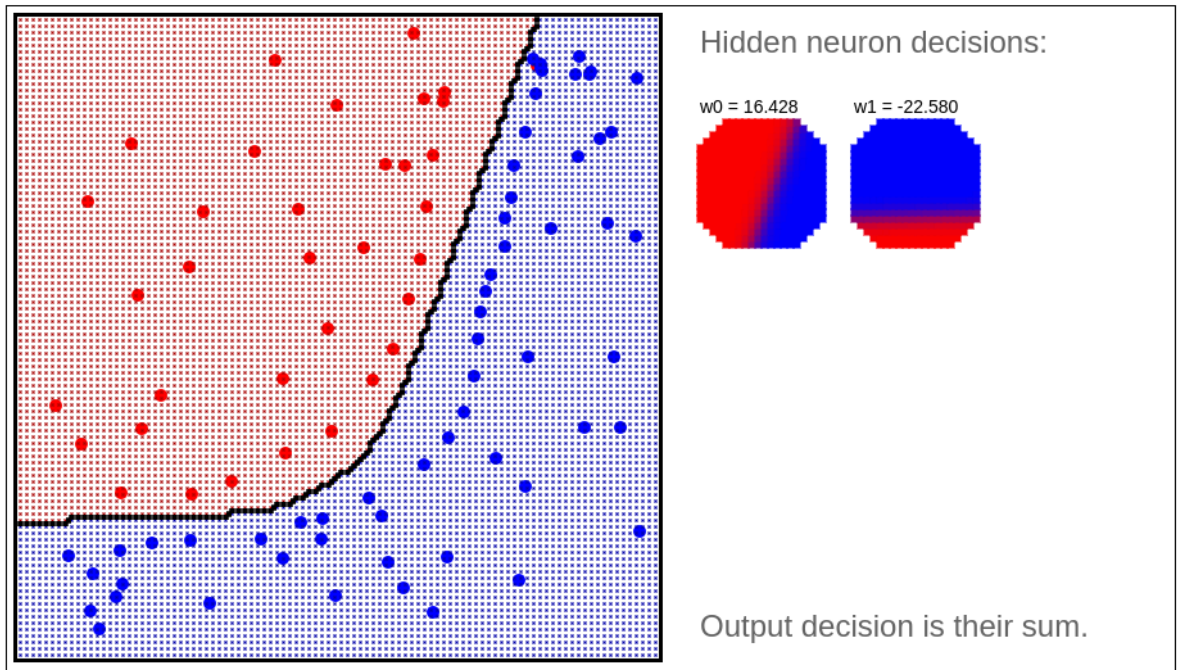
- Uma reta

## Neural Network Playground




- Uma função exponencial

# Neural Network Playground

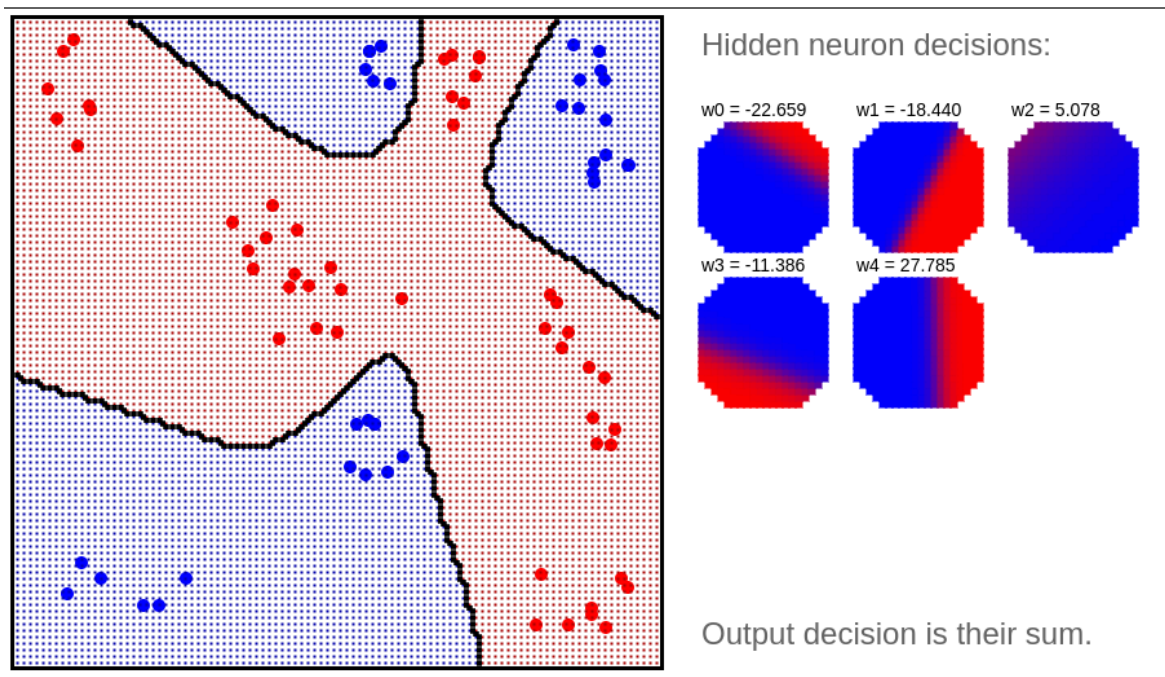


- Uma curva sigmoide

# Neural Network Playground

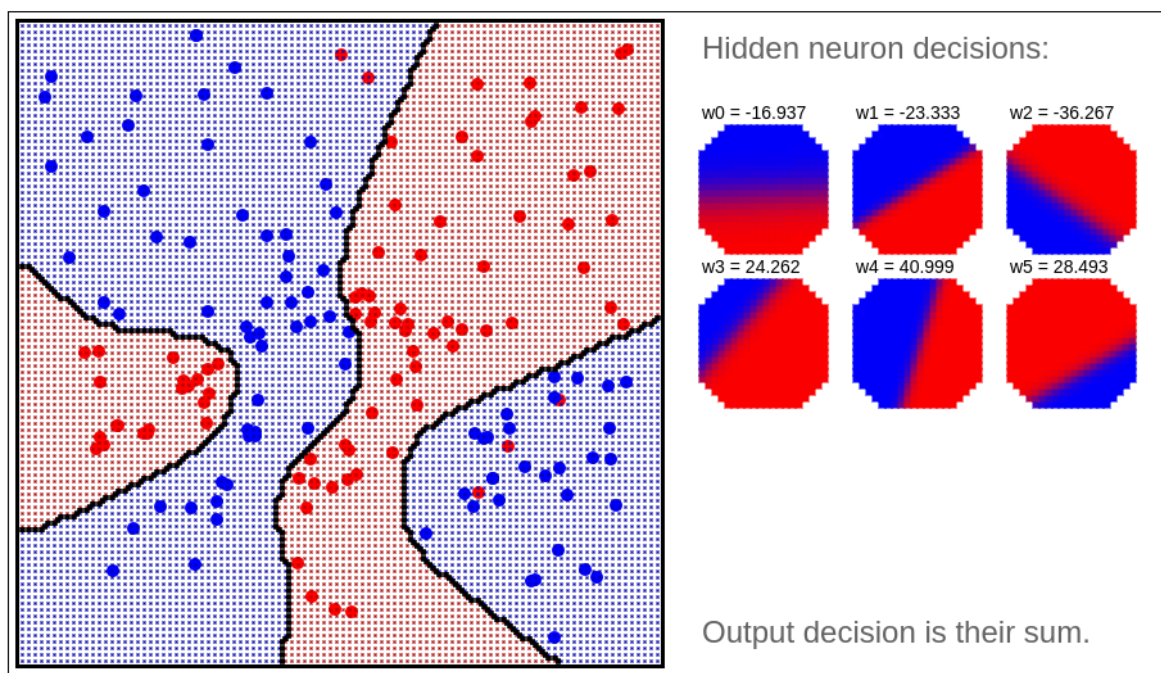


- Um conjunto de três áreas azuis, separadas por uma área vermelha



- Uma área dividida em quatro zonas, duas vermelhas e duas azuis.

## Neural Network Playground



Com os experimentos, vamos ver que:

- Quanto mais neurônios na camada oculta, mais complexa é a classificação que pode ser feita, mas maior será o número de cálculos necessários para fazer a rede funcionar.
- Redes têm uma capacidade de aprender dependendo de suas redes internas e de seus estados anteriores, algumas vezes é necessário reiniciar o treinamento do zero.

- Uma vez treinada a rede, clicando no botão STOP training temos uma classificação pronta. Os pontos que passamos são o conjunto de treinamento, e esperamos que novos pontos caiam nas áreas determinadas.
- O maior poder de uma rede neural é sua capacidade de trabalhar com dados limitados, não exigindo todos os dados possíveis do fenômeno. Ela “completa” os buracos nos dados.
- Algumas vezes, a rede não vai mais aprender, ficando com uma solução inadequada. Escolher um conjunto de treinamento é essencial para fazê-la funcionar.

Se olharmos os caminhos das conexões dos neurônios artificiais, vamos ver que cada uma delas é capaz de modelar um espaço. De forma abstrata, isso pode ser:

- Mapear dados de entrada e saída, por exemplo, números binários com números decimais.
- Criar um sistema de reconhecimento, de letras, imagens, até mesmo de textos, cada
  - A representação de um dado pode ser simbólica (e.g. palavras inteiras), ou sub-simbólica (com dados que não necessariamente representam informações).
- Modelar equações de modelos, por exemplo, a relação de uma concentração de remédio no sangue de uma pessoa com o aumento de pressão. Isso permite criar previsões, olhar para além do conjunto de dados iniciais.
- Relacionar grandezas, incluindo frequência, criando correlações novas.
- Recomendar dados similares, em uma mesma classificação.

Redes neurais possuem aplicações específicas, um treinamento em reconhecimento de dígitos não é válido para o treinamento de recomendação de conteúdos educacionais. Chamamos essa área de aplicação de domínio.

## APROFUNDANDO AS REDES DE NEURÔNIOS ARTIFICIAIS

### Introdução

Aqui, vamos observar como redes neurais complexas funcionam por dentro, observando os pesos e o treinamento em backpropagation. Você pode ter uma descrição completa disso utilizando o seguinte link:

<https://www.i-am.ai/neural-numbers.html>

### Abrindo uma rede neural

Acesse o seguinte site.

- <http://blueneurons.ch/nn>

Este site é um simulador de redes neurais que pode ser treinado com diferentes conjuntos de treinamento, de modo supervisionado.

**First: Build the Neural Network Architecture**

Choose Dataset:  ⓘ

Input:  Activation:  Bias:


Hidden 1:  Tanh:  True:  ✖

[+ Add Hidden Layer](#)

Output:  Softmax:  True:

[→ Continue to Training](#)

Visualization:



Em primeiro lugar, clique em **choose dataset** para escolher entre diferentes conjuntos de treinamento já realizados:

- Dice
- Letters
- Numbers
- OR
- XOR

Selecione Numbers, para compararmos com uma rede neural de reconhecimento de números. Não vamos ver o dataset, mas ele consiste de imagens de números e o número que deve ser reconhecido. É possível alterar os padrões relativos à rede, as camadas ocultas, a função de ativação e de saída,, mas mantenha os padrões para esta atividade. Clique em **continue to training**.

**Second: Train the Weights**

[← Edit Architecture](#)

Optimizer:  ⓘ

Loss:  ⓘ

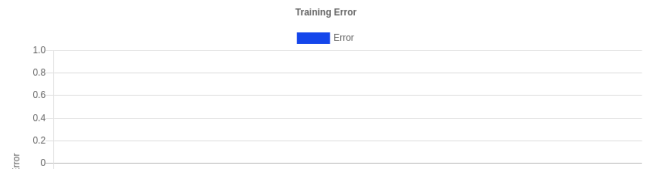
Optimizer Settings:  ⓘ  ⓘ ⓘ

Maximum Iterations:  ⓘ

Minimum Error:  ⓘ

[↺ Reset Network](#) [▶ Start](#) [⚠ Continue without training](#)

Training Error



Aqui também é possível selecionar o algoritmo de otimização, o cálculo de perda, indicar um número máximo de iterações e um erro mínimo esperado para a função. Novamente, o objetivo não é entrar nestes detalhes, mas demonstrar a variedade de parâmetros existentes. Clique em train, e você verá o gráfico com os erros com o decorrer do tempo:



Note que o erro não reduz em uma taxa constante, mas ele sobe e desce. Isso acontece porque o treinamento é uma heurística e, se o conjunto de treino não for adequado, por exemplo, pode não ser possível reduzir o erro da rede. Por fim, clique em **compute** para ir para a área de testes.

Aqui, selecione **Fill Input Manually** e, na área de quadrados brancos, que representa uma imagem, desenhe um número. Em seguida, clique em **Compute**. O programa vai tentar reconhecer algum número a partir do quadrado passado para ele.

**Last: Evaluate or make Predictions with the Neural Network**

Choose Dataset: Numbers

Fill Inputs manually

Result: 1

Visualization:

The visualization shows a neural network with four layers:
 

- Input Layer:** Four nodes labeled i1, i2, i3, and i4, each with a bias node labeled 'Bias = 1'.
- Hidden Layer 1:** Three nodes labeled h01, h02, and h03, each with a bias node labeled 'Bias = 1'.
- Hidden Layer 2:** Two nodes labeled h11 and h12, each with a bias node labeled 'Bias = 1'.
- Output Layer:** Two nodes labeled o1 and o2. Node o1 is highlighted in blue and has a probability of 0.0006. Node o2 is highlighted in red and has a probability of 0.964.

Veja que o neurônio de saída, aquele que dispara com o maior resultado de probabilidade, acaba sendo iluminado. Para fazer uma avaliação dos alunos, peça para que eles façam diferentes testes com as suas redes neurais e indiquem quais os resultados encontrados para cada input num documento de texto, anotando o valor do neurônio disparado. Depois, na segunda opção, em **train the weights**, indique a opção **Minimum Error**, indique 0,07 e **Maximum Iterations** em 20, significando que vamos treinar a rede apenas 20 vezes com cada item do conjunto de treino e esperar um erro 14 vezes maior do que o primeiro treinamento.

Trabalhando com essas quantidades, você pode analisar quantas rodadas de treinamento são necessárias para que os classificadores simples sejam capazes de reconhecer os conjuntos de dados. Imagine, agora, como ficaria uma rede neural profunda. É por isso que as grandes empresas estão criando datacenters gigantescos, o treinamento de uma rede neural é algo bastante custoso.

# MÓDULO 3

## APRENDIZADO DE MÁQUINA

### **Objetivo do Módulo:**

Ao final do módulo os professores participantes deverão compreender os princípios de Aprendizagem de Máquina e o funcionamento das modalidades de treinamento.

### **Contempla:**

AULA 06 - Ciência de Dados para Aprendizado de Máquina

AULA 07 - Aprendizado Supervisionado

AULA 08 - Aprendizado não-Supervisionado e por Reforço

## Ciência de Dados para Aprendizado de Máquina

Este módulo introduz o tema da Ciência de Dados e sua importância para a IA. Assim, uma boa forma de começar é: sabemos dos módulos anteriores que a IA começou na década de 50. O que a fez alcançar os resultados atuais? A resposta tem duas partes:

- a. A evolução do hardware (que não vamos tratar aqui);
- b. A imensa disponibilidade de **dados** atual.

Mas o que é um dado? Existem muitas definições, mas, para nossos objetivos aqui, podemos dizer que dado é informação armazenada, e que pode ser usada para resolver problemas e responder perguntas. Mais importante do que buscar a definição mais precisa possível, é importante mostrar – com exemplos – que há dados de dois tipos: estruturados e não-estruturados. Os primeiros podem, tipicamente, ser representados em tabelas como as que criamos em Excel, como abaixo:

Nome Completo	Idade	Gênero	Sintomas	Nível de Urgência	Altura (m)
João Pedro Alves	45	Masculino	Dor lombar intensa, dificuldade de locomoção	Alta	1.80
Roberto Gomes	75	Masculino	Tontura, fraqueza, pressão alta	Alta	1.70
Antônio Martins	80	Masculino	Confusão mental, dificuldade para falar	Alta	1.62
Ricardo Pereira	62	Masculino	Dor no joelho, inchaço, dificuldade para caminhar	Alta	1.60
Gustavo Oliveira	21	Masculino	Corte profundo no braço com sangramento ativo	Alta	1.90
Edson Rocha	70	Masculino	Dor de cabeça, visão turva, formigamento no braço	Alta	1.67
Ana Paula Silva	32	Feminino	Dor de cabeça, febre baixa, tosse seca	Baixa	1.65
Fernanda Lima	28	Feminino	Irritação na pele, coceira, vermelhidão	Baixa	1.60

Chamamos as colunas de tabelas como essa de **atributos** e as linhas de **exemplos** ou **instâncias**. No exemplo acima, temos 6 atributos: nome, idade, gênero e sintomas. Nível de urgência e altura. Temos 8 instâncias, onde cada instância tem um valor particular para cada atributo.

Dados não estruturados, por outro lado, estão na forma de texto, imagem ou voz. São mais confortáveis para nós, humanos, porém mais complexos de tratar, como vimos no módulo de Redes Neurais.

Tendo o conceito de “dado”, podemos apresentar o que é a Ciência de Dados: é uma atividade que busca resolver problemas complexos de organizações (empresas ou governo) a partir dos dados de que elas dispõem. Aplicando técnicas adequadas (já veremos quais), podemos descobrir muita coisa interessante, se tivermos um bom volume de dados. O importante é aprender a olhar para os dados como um cientista – com curiosidade e método.

Para aplicar Ciência de Dados sobre um conjunto de dados – para facilitar, costumamos chamar esse conjunto de “dataset” – realizamos várias atividades:

1. Primeiro, temos que **coletar** os dados. Eles podem vir de muitas fontes diferentes: da internet, de repositórios governamentais, de arquivos armazenados nos computadores de uma empresa, de sensores instalados em uma plantação etc.
2. Feita a coleta, precisamos aplicar um **pré-processamento**, onde principalmente filtramos os dados que nos interessam. Por exemplo, se coletamos dados na internet sobre famílias recebendo ajuda do governo devido a um desastre natural, podem vir junto na nossa coleta famílias que moravam na região, mas que se mudaram; essas devemos remover do dataset, porque, na hora de fazer uma análise estatística, a presença dessas informações pode nos levar a conclusões erradas -por exemplo, podemos concluir que precisamos de mais auxílio do que realmente é necessário. Outra decisão importante é verificar quais informações de cada família realmente são relevantes para o problema que desejamos resolver. Por exemplo, talvez os dados contenham as fotos das pessoas, mas será que isso é relevante? Vai depender muito do que estamos tentando descobrir; se a ideia é distribuir melhor os recursos da ajuda, provavelmente, não. Limpamos também dados incorretos devido a erros de digitação, ou com informações faltando etc.

Dois cuidados muito importantes que merecem atenção especial nesta fase são a **privacidade** e o risco de **vieses**. Do ponto de vista de privacidade, devemos cuidar para mascarar dados pessoais que porventura existam em nossa amostra (nomes, endereços, CPF etc.). Dados pessoais são protegidos pela Lei Geral de Proteção de Dados – LGPD. Os vieses, por sua vez, são mais difíceis de perceber à primeira vista, mas podem ser muito prejudiciais. Um viés pode ser caracterizado como um favorecimento sistemático, em nosso modelo de IA, em favor de um grupo ou indivíduo em detrimento de outros. Por exemplo, há alguns anos atrás, nos EUA, foi descoberto que havia que um sistema de triagem automática de pacientes em alguns hospitais favorecia pessoas brancas em detrimento de outras. Isso foi devido a um viés implícito na amostra de dados utilizada para treinar o modelo (veremos mais sobre o processo de treinamento). Hoje em dia, temos técnicas matemáticas para detectar vieses em *datasets*.

3. Feito o pré-processamento, aplicamos **transformações** nos dados, para que fiquem adequados para uso na geração de modelos de IA. Existem diversos tipos de transformações que podemos aplicar, dependendo dos dados que temos. Por exemplo, para respeitar as restrições de privacidade, podemos construir programas que aplicam **anonimização**. Anonimizar consiste em substituir o dado por outro, fictício, mas de forma que não altere a estatística da amostra de dados. Em nossa amostra de dados de

exemplo, devemos substituir os nomes das pessoas por nomes fictícios (cortesia da franquia Star Wars):

Nome Completo	Idade	Gênero	Sintomas	Nível de Urgência	Altura (m)
Ahsoka Tano	45	Masculino	Dor lombar intensa, dificuldade de locomoção	Alta	1.80
Obi-Wan Kenobi	75	Masculino	Tontura, fraqueza, pressão alta	Alta	1.70
Rey Palpatine	80	Masculino	Confusão mental, dificuldade para falar	Alta	1.62
Anakin Skywalker	62	Masculino	Dor no joelho, inchaço, dificuldade para caminhar	Alta	1.60
Luminara Unduli	21	Masculino	Corte profundo no braço com sangramento ativo	Alta	1.90
Mace Windu	70	Masculino	Dor de cabeça, visão turva, formigamento no braço	Alta	1.67
Barriss Offee	32	Feminino	Corte profundo no braço com sangramento ativo	Baixa	1.65
Kit Fisto	28	Feminino	Irritação na pele, coceira, vermelhidão	Baixa	1.60

Outro tipo de transformação é a **reescala**. Imagine que temos, na mesma amostra, dados de idade e de altura de um grupo de pessoas, por exemplo:

Nome Completo	Idade	Gênero	Sintomas	Nível de Urgência	Altura (m)
Ahsoka Tano	45	Masculino	Dor lombar intensa, dificuldade de locomoção	Alta	1.80
Obi-Wan Kenobi	75	Masculino	Tontura, fraqueza, pressão alta	Alta	1.70
Rey Palpatine	80	Masculino	Confusão mental, dificuldade para falar	Alta	1.62
Anakin Skywalker	62	Masculino	Dor no joelho, inchaço, dificuldade para caminhar	Alta	1.60
Luminara Unduli	21	Masculino	Corte profundo no braço com sangramento ativo	Alta	1.90
Mace Windu	70	Masculino	Dor de cabeça, visão turva, formigamento no braço	Alta	1.67
Barriss Offee	32	Feminino	Corte profundo no braço com sangramento ativo	Baixa	1.65
Kit Fisto	28	Feminino	Irritação na pele, coceira, vermelhidão	Baixa	1.60

Naturalmente, os valores de idade são, na média, muito maiores que os de altura. Quando aplicarmos algoritmos de aprendizagem de máquina, isso será um problema,

porque são algoritmos numéricos com fundamento estatístico. Na prática, a idade terá uma influência maior do que a altura, independente do que estamos tentando fazer o programa aprender. Ou seja, o algoritmo vai “interpretar” que a idade é um fator mais importante do que a altura, mesmo que não seja. Para evitar isso, aplicamos reescala nos valores, de forma que todos fiquem no mesmo intervalo., ou pelo menos em escalas compatíveis. Uma forma de fazer isso é aplica a fórmula

$$(x - u)/s$$

onde os valores de  $x$  são os dados da coluna que desejamos transformar (p.ex. os valores de idade),  $u$  é a média dos valores, e  $s$  é o desvio padrão. No exemplo, aplicando essa transformação sobre as colunas de idade e altura, temos:

Nome Completo	Idade	Gênero	Sintomas	Nível de Urgência	Altura (m)
Ahsoka Tano	-0.30	Masculino	Dor lombar intensa, dificuldade de locomoção	Alta	1.07
Obi-Wan Kenobi	1.08	Masculino	Tontura, fraqueza, pressão alta	Alta	0.07
Rey Palpatine	1.31	Masculino	Confusão mental, dificuldade para falar	Alta	-0.72
Anakin Skywalker	0.48	Masculino	Dor no joelho, inchaço, dificuldade para caminhar	Alta	-0.92
Luminara Unduli	-1.41	Masculino	Corte profundo no braço com sangramento ativo	Alta	2.08
Mace Windu	0.85	Masculino	Dor de cabeça, visão turva, formigamento no braço	Alta	-0.22
Barriss Offee	-0.90	Feminino	Corte profundo no braço com sangramento ativo	Baixa	-0.42
Kit Fisto	-1.09	Feminino	Irritação na pele, coceira, vermelhidão	Baixa	-0.92

Note como os valores agora tem escalas bem compatíveis. A título de curiosidade, a média das idades é 51.6 e a das alturas é 1.69. Ao aplicar a transformação, valores menores do que a média ficam negativos e valores maiores ficam positivos. Para fazer essa transformação, aplicamos o módulo **StandardScaler**, da biblioteca **Sklearn**.

Agora, observe uma coisa curiosa: todos os pacientes do gênero masculino, independente do sintoma, foram classificados com prioridade alta, enquanto todas as pacientes do gênero feminino estão com prioridade baixa. A amostra é pequena, mas podemos acender um sinal de alerta: pode estar havendo algum problema de viés nos dados.

Existem diversas outras técnicas de pré-processamento e transformação que podemos aplicar nos dados, até nosso *dataset* estar pronto para aplicarmos Aprendizagem de Máquina. Vamos ver mais uma, que pode ser usada para um exercício: tratar atributos **categóricos**. Nesse tipo de atributo, os valores pertencem a um conjunto limitado de possibilidades. Em nosso exemplo, os atributos de gênero e nível de urgência são categóricos. Para aplicar nossos algoritmos de aprendizagem, substituímos os valores

dos atributos categóricos por números – por exemplo, os níveis de urgência – alta, média e baixa – são substituídos, respectivamente, por 1, 2 e 3.

4. Quando os dados estão prontos, podemos aplicar algoritmos de Aprendizagem de Máquina para gerar um **modelo**. O modelo é o componente central de um sistema de IA; é ele que vai gerar as respostas para as perguntas, que chamamos **predições**. Os modelos podem ser de vários tipos; as árvores de decisão que vimos em aulas anteriores são exemplos de modelos que podem ser gerados por aprendizado. Na próxima aula veremos os diversos tipos de algoritmos e os modelos que eles geram. No exemplo acima, podemos tentar usar os dados (feitos os devidos ajustes!!) para aprender a atribuir automaticamente o nível de urgência de pacientes que chegam para triagem.
5. Criado o modelo, nosso trabalho está encerrado? Não!! É preciso **interpretar e validar** os resultados que o modelo está nos dando. Será que estão corretos? São resultados úteis? Conseguimos eliminar eventuais distorções/vieses? Para responder essas questões, precisamos  *muito* de pessoas com conhecimento da realidade que estamos analisando, não somente pessoal técnico. Somente depois de uma validação cuidadosa, por pessoas especializadas, é que podemos colocar nossa IA em uso.

## Aprendizado Supervisionado

Agora temos uma compreensão de como os dados podem ser trabalhados para nos ajudar a gerar **modelos de IA** que respondem questões úteis e complexas. Também vimos as Redes Neurais, o que nos trouxe os conceitos do que são modelos e de que modelos precisam ser **treinados**. Só que as redes neurais, como vimos, são um modelo bem poderoso e que, dependendo do caso, pode exigir mais do nosso hardware, ou demorar bastante para treinar. Ocorre que, dependendo do problema, existem outros algoritmos e modelos que podem ser usados, que não exigem tantos recursos, e cujos resultados atendem muito bem nossas necessidades! Vamos, então, explorar esses algoritmos, começando pelas técnicas de **aprendizado supervisionado**.

## Aprendizado de Máquina Supervisionado – que é

As técnicas de aprendizado de máquina supervisionado geram modelos capazes de realizar inferências preditivas ou prescritivas a partir de um conjunto de dados ou dataset. Esses modelos são treinados com dados **rotulados**, ou seja, dados que já possuem uma resposta conhecida, permitindo que o modelo aprenda a fazer previsões sobre novos dados. É o uso de dados rotulados no treinamento que caracteriza o aprendizado supervisionado. É bom lembrar que, antes de usá-los no treinamento, os dados passam por aquelas etapas que vimos ao estudar a Ciência de Dados (limpeza, seleção de atributos, transformações etc.).

Vamos considerar o conjunto de dados abaixo, que é uma amostra do dataset disponível em <https://dadosabertos.poa.br/dataset/acidentes-de-transito-acidentes>. Os dados mostram diversas informações de acidentes de trânsito, como número de veículos envolvidos e número de feridos ou mortos nestes acidentes:

data	feridos	fat ais	auto	taxi	lotação	ônibus	moto	tipo_acidente	dia_semana	noite_dia
17/10/2020	1	0	3	0	0	0	1	ABALROAMENTO	SÁBADO	NOITE
01/01/2020	1	0	0	1	0	0	1	ABALROAMENTO	QUARTA-FEIRA	NOITE
01/01/2020	1	0	1	0	0	0	0	ATROPELAMENTO	QUARTA-FEIRA	NOITE
02/01/2020	2	0	0	0	0	0	1	ATROPELAMENTO	QUINTA-FEIRA	NOITE
02/01/2020	1	0	1	0	0	0	1	ABALROAMENTO	QUINTA-FEIRA	DIA
02/01/2020	1	0	1	0	0	0	1	ABALROAMENTO	QUINTA-FEIRA	DIA
02/01/2020	1	0	2	0	0	0	1	COLISÃO	QUINTA-FEIRA	DIA
02/01/2020	7	0	2	0	0	0	0	ABALROAMENTO	QUINTA-FEIRA	DIA
02/01/2020	0	0	2	0	0	0	0	ABALROAMENTO	QUINTA-FEIRA	NOITE
02/01/2020	0	0	2	0	0	0	0	COLISÃO	QUINTA-FEIRA	DIA
02/01/2020	0	0	2	0	0	0	0	COLISÃO	QUINTA-FEIRA	DIA
02/01/2020	0	0	1	0	0	1	0	ABALROAMENTO	QUINTA-FEIRA	DIA
02/01/2020	0	0	2	0	0	0	0	CHOQUE	QUINTA-FEIRA	DIA
02/01/2020	0	0	2	0	0	0	0	CHOQUE	QUINTA-FEIRA	DIA
02/01/2020	0	0	2	0	0	0	0	ABALROAMENTO	QUINTA-FEIRA	DIA
03/01/2020	0	0	2	0	0	0	0	ABALROAMENTO	SEXTA-FEIRA	DIA
02/01/2020	0	0	1	0	0	1	0	CHOQUE	QUINTA-FEIRA	DIA
02/01/2020	1	0	1	0	0	0	1	ABALROAMENTO	QUINTA-FEIRA	NOITE
03/01/2020	1	0	1	0	0	0	1	ABALROAMENTO	SEXTA-FEIRA	DIA
03/01/2020	2	0	1	0	0	0	1	ABALROAMENTO	SEXTA-FEIRA	DIA

Os dados acima são apenas uma amostra; o dataset original tem mais atributos (colunas) e um total de 68661 linhas, de 2019 a 2025. Será que podemos treinar um modelo capaz de, dado um registro de acidente, prever com boa taxa de acertos o número de vítimas fatais (que chamaremos de nosso **atributo-alvo**), por exemplo, a partir dos valores de outros atributos? Note que, no dataset, esta informação já veio preenchida com o número correto; é isso o que torna este um caso de aprendizado supervisionado. Claro que nosso objetivo é, com esses dados, conseguir prever esse atributo para acidentes que ainda não aconteceram. Isso pode ter diversas aplicações; por exemplo, se conseguirmos prever o que mais impacta no número de vítimas (se o tipo de acidente ou os veículos envolvidos, ou o dia da semana etc.), o governo pode fazer campanhas mais direcionadas, ou se organizar melhor. Vamos, ver, então, como podemos treinar esse modelo.

## Conjuntos de treino e teste

O primeiro passo, depois de aplicarmos as técnicas que vimos em Ciência de Dados, é dividir nosso *dataset* em:

1. **Conjunto de Treino:** dados utilizados para treinar o modelo.
2. **Conjunto de Teste:** dados utilizados para avaliar o desempenho do modelo, ao longo do treinamento (para ver se o treinamento está progredindo bem).
3. **Conjunto de validação:** dados utilizados para avaliar o desempenho final do modelo.

A ideia é que, para termos uma avaliação realista do modelo, devemos testá-lo com dados que ele ainda não “viu”, ou seja, que não foram usados durante o treinamento. Assim, podemos garantir que a chance do modelo acertar as predições – e assim, ter um bom desempenho – porque já conhecia a resposta não ocorre. É bem comum usar a proporção 80/10/10: 80% dos dados para treino, 10% para teste e 10% para validação. Às vezes, o conjunto de validação é separado no início e aplicamos 80/20 sobre o conjunto restante. Em nosso exemplo, considerando apenas treino e teste, temos 20 linhas: se aplicarmos essa proporção, teremos 16 linhas para treino e 4 linhas para teste, que devemos escolher ao acaso. Algo como:

Conjunto de treino:

data	feriados	fat ais	auto	taxi	lotação	ônibus	moto	tipo_acidente	dia_semana	noite_dia
17/10/2020	1	0	3	0	0	0	1	ABALROAMENTO	SÁBADO	NOITE
02/01/2020	2	0	0	0	0	0	1	ATROPELAMENTO	QUINTA-FEIRA	NOITE
02/01/2020	1	0	1	0	0	0	1	ABALROAMENTO	QUINTA-FEIRA	DIA
02/01/2020	1	0	1	0	0	0	1	ABALROAMENTO	QUINTA-FEIRA	DIA
02/01/2020	1	0	2	0	0	0	1	COLISÃO	QUINTA-FEIRA	DIA
02/01/2020	7	0	2	0	0	0	0	ABALROAMENTO	QUINTA-FEIRA	DIA
02/01/2020	0	0	2	0	0	0	0	ABALROAMENTO	QUINTA-FEIRA	NOITE
02/01/2020	0	0	2	0	0	0	0	COLISÃO	QUINTA-FEIRA	DIA
02/01/2020	0	0	1	0	0	1	0	ABALROAMENTO	QUINTA-FEIRA	DIA
02/01/2020	0	0	2	0	0	0	0	CHOQUE	QUINTA-FEIRA	DIA
02/01/2020	0	0	2	0	0	0	0	ABALROAMENTO	QUINTA-FEIRA	DIA
03/01/2020	0	0	2	0	0	0	0	ABALROAMENTO	SEXTA-FEIRA	DIA
02/01/2020	0	0	1	0	0	1	0	CHOQUE	QUINTA-FEIRA	DIA
02/01/2020	1	0	1	0	0	0	1	ABALROAMENTO	QUINTA-FEIRA	NOITE
03/01/2020	1	0	1	0	0	0	1	ABALROAMENTO	SEXTA-FEIRA	DIA
03/01/2020	2	0	1	0	0	0	1	ABALROAMENTO	SEXTA-FEIRA	DIA

Conjunto de teste:

data	feriados	fat ais	auto	taxi	lotação	ônibus	mo to	tipo_acidente	dia_semana	noite_dia
01/01/2020	1	0	0	1	0	0	1	ABALROAMENTO	QUARTA-FEIRA	NOITE
01/01/2020	1	0	1	0	0	0	0	ATROPELAMENTO	QUARTA-FEIRA	NOITE
02/01/2020	0	0	2	0	0	0	0	COLISÃO	QUINTA-FEIRA	DIA
02/01/2020	0	0	2	0	0	0	0	CHOQUE	QUINTA-FEIRA	DIA

Você pode achar que é pouco para termos um resultado confiável – e é mesmo! A tabela do exemplo é apenas para fins didáticos. Na amostra original, teríamos  $68661 * 0,8 = 54929$  linhas para treino e 13732 linhas para teste. Quanto maior for o volume de dados, podemos considerar proporções maiores para o treino – por exemplo, 90% para treino e 10% para teste. Quanto mais dados de treino, melhor; só precisamos garantir as seguintes condições:

1. O conjunto de teste deve ter um tamanho mínimo, compatível com nosso universo de dados. Se for muito pequeno, o teste pode não ser confiável.

2. Os dados – tanto de treino quanto de teste – devem estar **balanceados**. Em nosso exemplo, se a cidade possui mais carros do que motos, por exemplo, isso deve se refletir em nossa amostra, para podermos gerar um modelo capaz de fazer previsões realistas. Não é o caso de entrarmos em todos os detalhes estatísticos aqui, mas podemos resumir a questão da seguinte forma: quanto mais próximo do universo real for o *dataset* que usarmos na aprendizagem, mais confiável será o modelo de IA treinado.

Ok, agora temos nossos dados. O que fazer com eles? É hora de olharmos para os algoritmos que fazem a magia: as *técnicas de aprendizagem supervisionada*.

## Técnicas de Aprendizagem Supervisionada

**1) Classificação:** Os algoritmos de classificação aprendem a responder, dado um exemplo, a qual classe ele pertence, dentro de um conjunto de classes possíveis. Por exemplo, no nosso conjunto de dados, temos a coluna “tipo de acidente”, que tem um conjunto de valores possíveis, colisão, atropelamento, choque e abaloamento. Outro exemplo é a classificação de animais, quer vimos ao discutir árvores de decisão. Por sinal, as árvores de decisão constituem um exemplo muito popular de modelos de classificação e podem ser treinadas a partir de *datasets*. valores alvos a partir de dados rotulados. Outro exemplo é a **regressão logística**, muito popular para classificação binária (ou seja, quando temos duas classes possíveis, como dia e noite), que calcula uma combinação linear dos valores dos atributos e aplica a função logística sobre o resultado para gerar uma probabilidade de pertencimento à classe.

A título de curiosidade: treinamos uma árvore de decisão para prever o tipo de acidente usando o nosso *dataset* de exemplo, mas o resultado não foi nada bom: a acurácia (taxa de acertos) foi pouco maior do que 50%. Por outro lado, treinamos outra árvore para responder se o acidente foi de noite ou de dia e o resultado foi um pouco melhor, em torno de 71%. O interessante é que temos o mesmo resultando aplicando regressão logística.

Existem muitas técnicas para treinar modelos de classificação, tais como Random Forest, XGBoost, SVM etc.; inclusive, Redes Neurais podem ser treinadas para fazer classificação. Não é nossa ideia esgotar o tema aqui. Vamos ver apenas mais uma, cuja estratégia é diferente e bastante intuitiva: a técnica do **vizinho mais próximo** (*nearest neighbors* ou, mais exatamente, *K-nearest neighbors* - *KNN*). O conceito é bem simples: classificar um objeto como pertencendo à mesma classe que os objetos conhecidos mais parecidos com ele. Mas o que é “ser parecido” quando um objeto é descrito por um conjunto de valores de atributos? Na técnica do vizinho mais próximo, interpretamos os valores dos atributos como coordenadas em um espaço com **n** dimensões, onde **n** é o número de atributos no *dataset* (menos o atributo relativo à classe). No exemplo dos acidentes, temos 11 atributos; logo, cada acidente é representado por um ponto em um espaço de 10 dimensões. Interpretando dessa forma, podemos definir alguma forma de *distância* entre os objetos, de tal forma que, quanto mais parecidos, menor a distância entre eles. Dois acidentes envolvendo apenas um táxi e uma moto, ocorridos de dia, com o mesmo número de feridos, são mais próximos entre si (portanto, similares) do que de outro

envolvendo dois ônibus à noite, por exemplo. Assim, se estamos tentando prever o tipo de acidente, é intuitivo imaginar que dois acidentes parecidos possam ser do mesmo tipo (classe).

Na técnica do vizinho mais próximo, definimos quantos vizinhos vamos examinar para decidir a classe de um objeto; esse valor é chamado  $K$  (daí o nome em inglês dessa técnica: *K-nearest neighbors*). Isso é necessário porque seria impraticável comparar cada novo objeto que desejamos classificar com todos os outros em nossos dados! Note que, apesar de ser muito intuitiva e fácil de implementar, isso não garante que o algoritmo do vizinho mais próximo vá funcionar bem em todos os casos: isso depende do quanto a classe que desejamos aprender se relaciona com os outros atributos.

 Um pouco mais de detalhe sobre regressão linear:  
<https://youtu.be/-PGDAbkLzSw?si=5fqwcqoTQyql7DQr>

**2) Regressão:** A regressão é um conjunto de técnicas de aprendizado supervisionado onde os valores alvos são valores contínuos – diferente da classificação, onde o atributo alvo tem um conjunto limitado de valores (dia/noite, tipo de acidente). Em nosso exemplo, se quisermos treinar um modelo para prever o número de vítimas fatais, devemos usar regressão, porque esse número pode ser um inteiro positivo qualquer (incluindo 0) – embora números muito altos, na prática, não ocorram. Exemplos de algoritmos de regressão incluem:

- **Regressão Linear:** Modela a relação entre uma variável dependente e uma ou mais variáveis independentes de forma linear.
- **Regressão Polinomial:** Modela a relação como um polinômio quando o erro da regressão linear é muito alto.
- **Regressão usando Árvores de Decisão:** Técnicas originalmente usadas para classificação podem ser aplicadas em regressão.

As técnicas de regressão possuem um grande número de aplicações: previsão de tempo de viagens, previsão de preços ou de demanda de produtos, e muito mais.

 Veja um exemplo didático do uso do KNN:  
<https://www.youtube.com/watch?v=3uA9tGBx0s>

## Como Avaliar os Modelos?

Como dissemos anteriormente, para saber se o modelo já está pronto para ser usado, temos que fazer uma validação do desempenho: aplicamos o modelo sobre o conjunto de validação e

medimos como ele se saiu. Mas como medir? Quando falamos de classificação, usamos o exemplo dos acidentes e consideramos a taxa de acertos do modelo para falar do desempenho dele. Essa é uma das métricas mais clássicas e é chamada de **acurácia** – simplesmente vemos o percentual de acertos. A fórmula da acurácia é bem simples:

$$A = (\text{número de acertos}) / (\text{número total de linhas})$$

Essa é a métrica mais simples para medir a qualidade de modelos de classificação. Há outras, como F1, AUC, precisão, *recall* etc., que são mais robustas e/ou podem ser usadas para situações específicas.

Note que a acurácia só faz sentido para aprendizagem supervisionada por classificação, porque, neste cenário, ou o modelo acerta – predizendo a classe correta – ou erra. Na regressão, precisamos avaliar de outra forma: se a resposta era 10 e o modelo predisse 9, isso é diferente de uma predição de 1 ou de 10,5, pois estamos lidando com uma faixa de valores numéricos, e não classes. Para modelos de regressão, medimos o desempenho através do conceito de **erro médio**, onde o erro é a diferença (em valor absoluto) entre o valor correto e o valor obtido pelo modelo. No exemplo, acima, o erro foi de  $|10-9| = 1$  no primeiro caso, 9 o segundo e 0,5. Se nosso conjunto de teste fosse composto apenas desses exemplos, o erro médio seria  $(1+9+0,5)/3=3,5$ . Isso é pouco ou muito? Este é outro detalhe importante: o erro é medido nas mesmas unidades do atributo alvo, e para avaliar se o erro é pequeno ou não, temos que ver a escala de valores do *dataset* e do problema que estamos estudando. Um erro de 3,5 minutos em uma viagem que pode levar 2 horas é pequeno; já 3,5 segundos em uma corrida de 100 metros rasos é decisiva.

O erro médio é chamado de MAE (*mean absolute error* – erro médio absoluto) e é a métrica mais simples para avaliar modelos de regressão. Na prática, é mais frequente usar as variações MSE (*mean squared error* – erro médio quadrático) ou RMSE (*root mean squared error* – raiz quadrada do erro médio quadrático), quando queremos dar mais importância a erros maiores.

## Cuidados e considerações

A essa altura, deve ter ficado visível que os resultados de um modelo de aprendizagem supervisionado dependem *muito* de termos um bom conjunto de dados e de conduzirmos um bom treinamento, independentemente de ser uma aplicação de classificação ou de regressão. Alguns cuidados são especialmente importantes (já falamos de alguns deles, mas incluímos aqui devido a sua importância):

- Codificar atributos categóricos: os algoritmos de aprendizagem supervisionada esperam números como entrada; assim, se tivermos um atributo como dia da semana, por exemplo, temos que substituir os nomes dos dias por números (p.ex. 1=domingo, 2=segunda etc.).
- Normalização: se tivermos atributos com escalas muito diferentes (idade e altura, p.ex.), é fundamental colocá-los na mesma escala.

- Tratamento de *outliers*: um *outlier* é um valor excepcional ou até mesmo impossível, como uma altura negativa ou um salário de R\$1 milhão por mês. Mesmo que não seja impossível, é bom filtrar esses casos, pois prejudicam o funcionamento do algoritmo de aprendizagem. Se não é um erro, devem ser tratados em separado.
- Pressupostos: por exemplo, regressão linear só faz sentido se existe uma proporcionalidade linear ou bem próxima de linear entre os atributos de entrada e o atributo alv. Devemos conferir se o algoritmo escolhido pode ser aplicado com segurança no problema que estamos estudando.
- *Overfitting/underfitting*: *overfitting* é quando o modelo fica muito ajustado aos dados de treinamento, tendo um desempenho muito bom – até demais – seguido de maus resultados na validação. Já o *underfitting* ocorre quando o treinamento não consegue gerar um modelo com bom desempenho. No primeiro caso, devemos reavaliar a composição dos conjuntos de treino e teste, possivelmente aumentando o volume e variedade dos dados de treino. No segundo, devemos considerar também se estamos usando a melhor técnica para o problema.
- Seleção/engenharia de atributos: é importante escolher atributos que realmente influenciem o nosso alvo. Aqui é importante estudar bem o problema! Às vezes é fácil descartar um atributo irrelevante (a cor da roupa do paciente não influencia sua condição de saúde), mas outros casos podem exigir uma avaliação estatística (será que a data do acidente influencia o tipo?).
- Balanceamento do *dataset*: como vimos, é importante fornecer exemplos de todos os casos que podem ocorrer na realidade, em proporções realistas. Porém, é importante entender se uma classe, por exemplo, está mal representada no dataset ou se é naturalmente rara (por exemplo, acidentes de carro com explosões são naturalmente mais raros). No primeiro caso, devemos corrigir o balanceamento; no segundo, talvez seja melhor usar outra técnica.

## Aprendizado de Máquina Não-Supervisionado e por Reforço

Como vimos, é possível criar modelos de IA usando conjuntos de dados rotulados. O fato deles já estarem rotulados (ou seja, para cada exemplo temos a resposta correta associada a ele) permite criar modelos precisos e confiáveis. Isso também facilita avaliarmos o desempenho do modelo, o que nos dá um bom controle do que estamos construindo. Como sabemos de antemão o universo de respostas possíveis, os resultados dos modelos de aprendizagem supervisionada também são relativamente mais fáceis de interpretar.

A grande limitação da aprendizagem supervisionada, claro, é que nem sempre temos dados rotulados à disposição. Além disso, como o aprendizado é guiado pelos rótulos existentes, o modelo pode não ser capaz de identificar padrões ou *insights* que não estavam explicitamente presentes nos dados rotulados. Quando não temos dados rotulados, ou quando queremos descobrir padrões que não estão evidentes nos dados, temos a alternativa de usar aprendizagem **não-supervisionada**.

Neste encontro, também vamos discutir outra forma de aprendizagem, cada dia mais importante: a **aprendizagem por reforço**. Embora, de certa forma, a aprendizagem por reforço tenha uma forma de supervisão, ela é bem diferente do aprendizado supervisionado usual.

## Aprendizado de Máquina Não Supervisionado – que é

O aprendizado de máquina não-supervisionado é um conjunto de técnicas onde o modelo é treinado usando dados que não possuem rótulos. O objetivo é encontrar padrões ou agrupamentos nos dados. A grande vantagem é que os dados não rotulados são muito mais abundantes e fáceis de obter do que dados rotulados. O aprendizado não supervisionado é uma ferramenta poderosa para a análise exploratória de dados, ajudando a entender a estrutura subjacente dos dados antes de aplicar outras técnicas. Os padrões encontrados, frequentemente, não são evidentes à primeira vista, o que pode levar a descobertas valiosas. Em alguns casos, podemos inclusive usar os resultados do aprendizado não supervisionado para gerar previsões, como no aprendizado supervisionado.

## Técnicas de Aprendizagem Não-Supervisionada

**1) Agrupamento (Clustering):** O agrupamento é usado para encontrar grupos de instâncias similares nos dados. É uma das formas mais populares de usar aprendizado não-supervisionado, porque é muito intuitiva. Alguns dos principais algoritmos de agrupamento incluem:

- **K-Means:** Um algoritmo simples que particiona os dados em K grupos (chamados *clusters*). Ele seleciona um conjunto de K pontos do dataset para usar como centroides (como se fossem os “centros de gravidade”) dos grupos. Os outros pontos são incluídos iterativamente no grupo cujo centroide é mais próximo. A ideia de proximidade usada aqui é a mesma usada no algoritmo do vizinho mais próximo, que discutimos anteriormente. Ou seja, precisamos definir uma forma de calcular a distância entre os pontos do *dataset*, de tal forma que pontos representando instâncias similares fiquem próximos.
- **Agrupamento Hierárquico:** Cria uma hierarquia de grupos iterativamente. Pode ser aglomerativo (bottom-up) ou divisivo (top-down) e não necessita definir o número de grupos (K) previamente.
- **DBSCAN:** Um algoritmo de agrupamento baseado em densidade. Ele identifica áreas de alta densidade de pontos e as considera como grupos. Pontos afastados dessas áreas são considerados *outliers* – ou seja, pontos que representam exceções e não se enquadram em nenhum grupo (pontos “fora da curva”).

Por exemplo, se considerarmos o *dataset* de acidentes visto no encontro anterior, podemos aplicar a técnica de K-means para prever o atributo “noite\_dia”, e teremos uma acurácia de 71%, similar à obtida usando aprendizado supervisionado.

🔍 Veja um exemplo didático, usando Python, do uso de K-Means para agrupar clientes em uma loja:  
[www.youtube.com/watch?v=WwKe5AaKi8g&pp=ygUOZXhlcXBsbyBrbWVhbnM%3D](http://www.youtube.com/watch?v=WwKe5AaKi8g&pp=ygUOZXhlcXBsbyBrbWVhbnM%3D)

🔍 Outro exemplo interessante (porém mais longo, com várias partes e entrando um pouco mais no detalhe técnico) usando K-Means para fazer agrupamento de deputados e partidos:  
<https://www.youtube.com/watch?v=VyP4pUiV23M>

**2) Regras de Associação:** As técnicas de agrupamento analisam pontos (linhas) no conjunto de dados. Já as **regras de associação** analisam os atributos (colunas) dos dados. Usando esses algoritmos, podemos descobrir relacionamentos interessantes entre variáveis em grandes conjuntos de dados, que são formulados como regras (por exemplo, algo como "quem compra X também compra Y"). Os algoritmos deste tipo são muito aplicados em análises de comportamento de consumidores, por exemplo. Um algoritmo clássico para descobrir regras de associação é o Apriori.

## Detecção de Anomalias (ou Outliers)

Falamos de *outliers* (anomalias) anteriormente, como elementos no conjunto de dados que são exceções (eventualmente causadas por entrada de dados incorretos), que precisamos remover do *dataset* para ter um bom treinamento. No entanto, há aplicações onde são justamente as exceções que nos interessam. O exemplo mais típico é em detecção de fraudes, por exemplo em cartões de crédito; neste caso, queremos identificar situações fora do comum, tais como compras atípicas. Existem algoritmos não supervisionados para essa tarefa, que chamamos *detecção de anomalias*. Como exemplos, podemos mencionar Isolation Forest e LOF (Local Outlier Factor).

## Como Avaliar os Modelos?

Quando falamos de aprendizado supervisionado, vimos que podemos medir a qualidade de um modelo usando métricas como acurácia (para classificação) ou erro médio (para regressão). Claramente, não temos métricas análogas para aprendizado não supervisionado, pois não sabemos quais os resultados "corretos" de antemão para avaliar o treinamento. No entanto, podemos medir a qualidade de um agrupamento: em um bom agrupamento, os elementos de um grupo são bem similares entre si (similaridade intragrupo), mas também devem ser suficientemente diferentes dos elementos de outros grupos (distância entre grupos). Uma métrica que captura essa ideia é chamada de *silhouette score*, e é calculada justamente pegando a média das similaridades intragrupo e dividindo pela média das similaridades entre grupos.

## Cuidados e considerações

Vimos que o aprendizado não supervisionado tem muitas aplicações. No entanto, essas técnicas também possuem desafios, e devem ser avaliadas cuidadosamente. Alguns cuidados que precisamos considerar são:

- como não há rótulos para guiar o aprendizado, os resultados podem ser menos precisos e mais difíceis de avaliar objetivamente;
- os resultados podem ser mais difíceis de interpretar, por serem padrões inicialmente desconhecidos;
- a validação dos modelos pode ser mais difícil e indireta, como vimos;
- o custo computacional (tempo de processamento, hardware necessário) frequentemente é mais alto do que no aprendizado supervisionado.

## Aprendizado por reforço – que é

Imagine um robô que precisa aprender a navegar em um ambiente dinâmico para realizar sua tarefa – movimentar-se no interior de uma fábrica, ou em uma zona de desastre, buscando pessoas precisando de resgate, por exemplo. Como podemos treiná-lo? Note que, como o ambiente é dinâmico, o resultado de uma ação nem sempre é totalmente previsível. As técnicas que vimos anteriormente não se aplicam bem neste tipo de cenário. Para obter bons resultados, existe a *aprendizagem por reforço*.

A aprendizagem por reforço envolve um agente (no exemplo, o robô) que interage com um ambiente onde, se o agente executa uma ação **a** em uma determinada situação, existe uma **probabilidade** do resultado ser o esperado: a mesma ação, na mesma situação, pode ter um resultado **x** da primeira vez e um resultado **y** na segunda. Por exemplo, o robô pode seguir uma rua na primeira vez para chegar em um ponto e, na segunda, descobrir que a rua está inundada. Ambientes desse tipo são chamados *estocásticos*. A questão, portanto, passa a ser: como podemos treinar nosso agente para tomar decisões com maior chance de sucesso nestes ambientes?

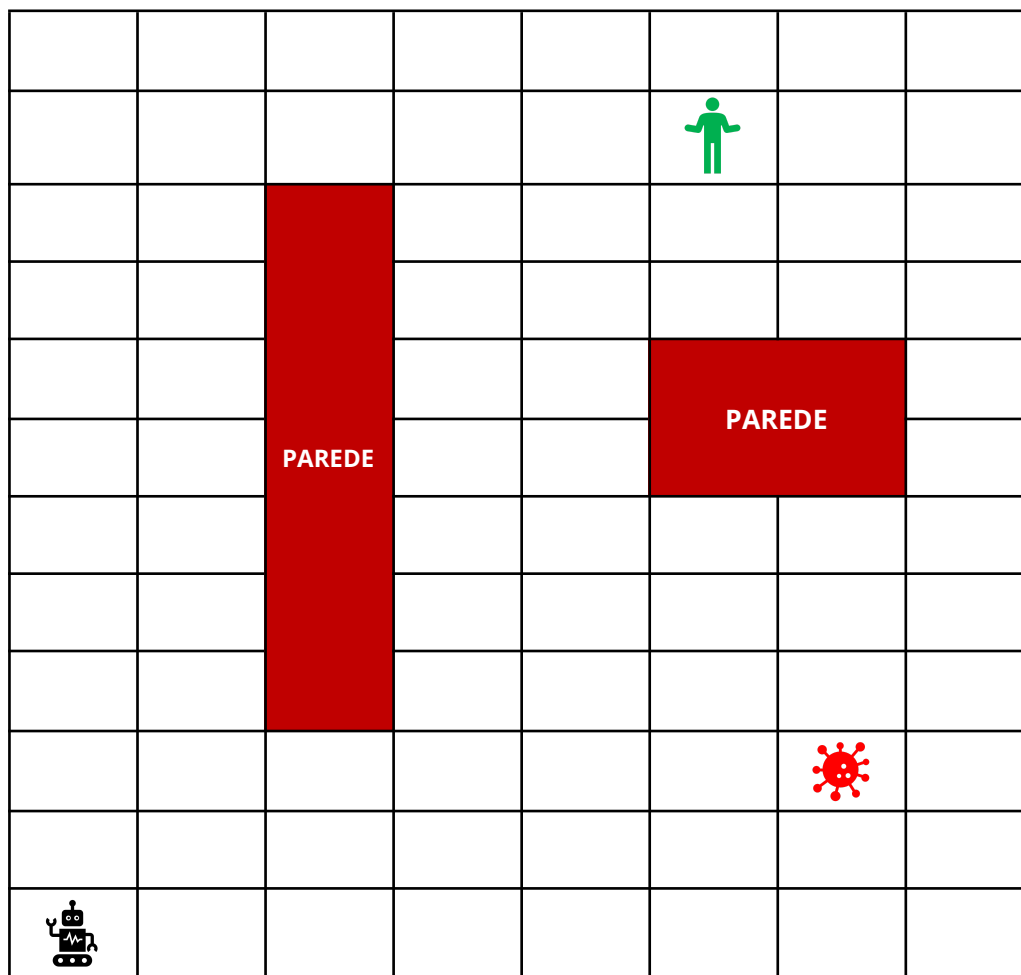
A pesquisa mostrou que uma boa estratégia para treinar agentes em ambientes estocásticos é bem conhecida nossa: a cada vez que um agente consegue atingir um objetivo, ele recebe uma *recompensa*; da mesma forma, se o agente chega a uma situação indesejada, recebe uma *punição*. Assim, a aprendizagem por reforço segue o mesmo padrão de recompensa e punição que aplicamos para treinar um animal doméstico, por exemplo.

## Agentes Reativos e Ambientes Estocásticos


Os agentes que treinamos usando aprendizagem por reforço são relativamente simples – eles decidem qual ação executar com base apenas na situação atual. Por isso, são chamados agentes *reativos*. Pode parecer estranho usarmos um esquema tão primário para nossos robôs, já que possuímos tecnologia para fazer algo mais sofisticado. Ocorre que, para ambientes estocásticos, onde temos uma imprevisibilidade maior, não é eficiente ficar planejando muito, porque as condições mudam com muita frequência. Assim, agentes reativos podem ser treinados de maneira a tornar-se efetivos nesses ambientes.

## Associando Recompensas aos Estados

Como funciona o treinamento da aprendizagem por reforço? Diferentemente da aprendizagem supervisionada, aqui o nosso agente vai, basicamente, explorar o ambiente e ver o que acontece – em que situações ele ganha recompensas e em quais recebe punições. Assim, ele vai aprendendo quais ações executar e quando. Mas há um detalhe importante. Vamos ver o exemplo abaixo:



Imagine o nosso robô explorando este ambiente e procurando pessoas para resgatar. Ele vai executar diversas ações (virar à direita, avançar em linha reta, virar de novo etc.); cada ação muda a situação do robô, ou seu *estado*, como chamamos. Assim, ao invés de linhas com atributos no conjunto de dados, cada linha é uma sequência de ações executadas e seus resultados, que termina quando o robô encontra uma pessoa ou quando entra em um local infectado. Cada uma dessas linhas é chamada de "*episódio*". Assim, um episódio tem vários estados – *mas a recompensa ou punição só é recebida no final*. Essa recompensa é distribuída pelo algoritmo para as diversas ações executadas no episódio, pois todas contribuíram para o resultado final. A regra de distribuição é tal que, após um número suficiente de episódios, o agente desenvolve uma forma de se comportar naquele ambiente.

 Você vai encontrar muitos exemplos de aplicação de aprendizagem por reforço em jogos, pois a técnica se aplica muito bem a estes cenários. Aqui um exemplo didático de um agente aprendendo a jogar Super Mario Bros: <https://www.youtube.com/watch?v=9nqwVYCxQIs>

## Algoritmos de Aprendizagem


Alguns dos principais algoritmos de aprendizagem por reforço incluem:

- **Q-learning:** Um algoritmo que atualiza o valor de uma ação em um estado com base na recompensa recebida e no valor máximo das ações no próximo estado.
- **SARSA:** Similar ao Q-learning, mas atualiza o valor da ação com base na ação realmente tomada no próximo estado.
- **DQN (Deep Q-network):** Combina deep learning (redes neurais de aprendizado profundo) com Q-learning para lidar com problemas com muitos estados e/ou ações.

## Cuidados

Alguns cuidados a serem tomados na aprendizagem por reforço incluem:

- Exploração vs. Exploração: Encontrar um equilíbrio entre explorar novas ações e explorar ações conhecidas que são recompensadas.
- Escalabilidade: Lidar com ambientes com alto número de ações disponíveis e/ou estados possíveis

 **Ferramentas e Bibliotecas:** Para implementar algoritmos de aprendizagem não-supervisionada e por reforço, algumas ferramentas e bibliotecas úteis incluem:

- Scikit-learn: Ideal para algoritmos de agrupamento.
- TensorFlow: Oferece suporte para redes neurais em aprendizagem por reforço.
- OpenAI Gym: Proporciona ambientes para testar algoritmos de reforço.

# MÓDULO 4

## SEGURANÇA DOS DADOS NA IA

### **Objetivo do Módulo:**

Ao final do módulo os professores participantes deverão compreender o ciclo de vida da IA e os principais cuidados que devem ser tomados em cada etapa.

### **Contempla:**

Aula 09 - Introdução à Segurança de Dados na IA

Aula 10 - Segurança dos Dados na IA

## Segurança dos Dados na IA

### Por que falar de segurança de dados na escola?

Hoje quase tudo que fazemos — registrar notas, usar aplicativos de leitura, postar no grupo da turma — deixa “pegadas digitais”. Esses rastros são transformados em dados que, quando tratados com cuidado, podem melhorar o ensino (por exemplo, sugerir exercícios personalizados). Mas, se caírem em mãos erradas ou forem usados sem critério, podem expor alunos e professores a constrangimentos, golpes ou discriminação.

Pense nos dados como cadernos com informações pessoais. Você não deixaria esses cadernos abertos no pátio; do mesmo modo, não devemos deixar planilhas ou fotos

“abertas” na internet. Ensinar segurança de dados é, portanto, tão fundamental quanto ensinar a travar a porta da escola ao sair.

### Dados pessoais × dados sensíveis

Dados pessoais são como o RG de alguém: servem para identificar a pessoa direta ou indiretamente (nome, matrícula, endereço de e-mail escolar).

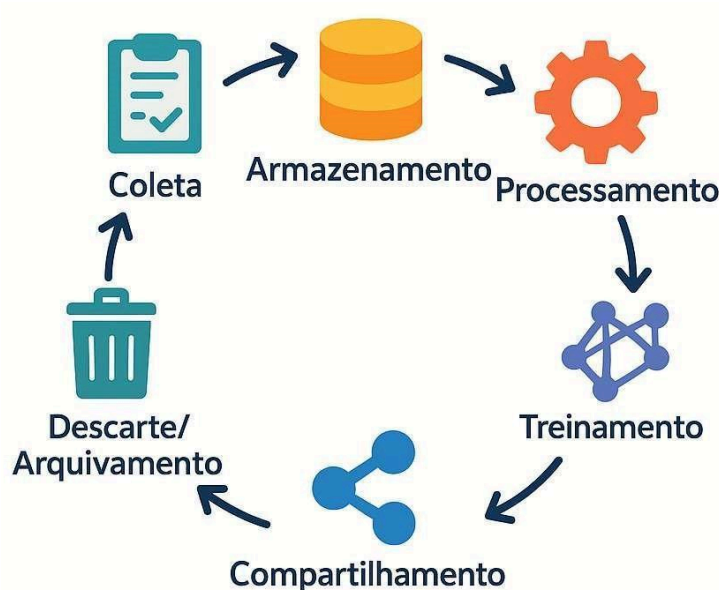
Dados sensíveis são como um diário íntimo: revelam características que, se divulgadas, podem gerar preconceito ou dano (saúde, religião, orientação política, biometria).

Pergunte “Qual informação você escreveria num crachá?” (ex.: nome). Depois pergunte

“Qual informação você não mostraria num cartaz na rua?” (ex.: alergias, crença religiosa). Use esse contraste para diferenciar os dois tipos.

## Ciclo de Vida dos Dados na IA — passo a passo

A seguir, são descritos os passos do ciclo de vida da IA conforme a figura de referência.



- Coleta: momento em que o dado nasce. Pode vir de um formulário, sensor ou mensagem em rede social.
  - Ex.: Google Forms.
- Armazenamento: onde o dado é guardado — planilha no computador, nuvem ou pendrive.
  - Ex.: planilha de notas no pen-drive da coordenação.
- Processamento: limpeza e organização; corrigir erros, tirar duplicatas.
  - Ex.: padronizar “1º Ano”, “Primeiro Ano” e “1 ano” para um único formato.
- Treinamento: fase em que a IA estuda o conjunto de dados para aprender padrões.
  - Ex.: sistema aprende quais alunos tendem a atrasar tarefas.
- Compartilhamento: envio a outras pessoas ou empresas.
  - Ex.: repassar lista de contatos a uma plataforma de correção automática.
- Descarte/Arquivamento: fim do ciclo. Dados desnecessários devem ser apagados ou guardados de forma segura e anonimizada.
  - Ex.: deletar registros de um projeto concluído há 5 anos.

Problemas em qualquer passo contaminam os passos seguintes (efeito “dominó”).

## Qualidade e viés nos dados — o que podem causar?

Quando dizemos que um conjunto de dados tem qualidade, queremos dizer que ele retrata de forma fiel, completa e coerente a realidade que se propôs a medir. Quatro características costumam servir de “pente-fino”:

- **Completude** – há registros faltando? Se 20% dos alunos não têm nota lançada, qualquer média ficará distorcida.
- **Exatidão** – os valores estão corretos? Um “110” numa escala de 0 a 100 é claramente um erro.
- **Consistência** – o mesmo tipo de dado aparece sempre no mesmo formato? “1º Ano”, “Primeiro Ano” e “1 ano” na mesma coluna dificultam análises.
- **Atualidade** – o dado está em dia? Usar estatísticas de 2015 para decidir turmas de 2025 ignora mudanças demográficas.

Em outras palavras, quanto melhor a qualidade, mais confiável será a conclusão ou o modelo de IA que se baseia nesses números.

Já o viés é um desvio sistemático que faz com que o conjunto de dados favoreça certas interpretações e ignore outras. Em outras palavras, o viés acontece quando a amostra não representa todo mundo ou carrega estereótipos. Se só observarmos escolas urbanas, a IA pode ignorar a realidade rural.

- **Viés de seleção** – ocorre quando o grupo observado não representa todo o universo. Se coletamos respostas só da escola urbana, a realidade rural fica fora do radar.
- **Viés de mensuração** – surge de instrumentos ou perguntas mal formuladas. Um questionário on-line exclui quem tem conexão precária.
- **Viés de rotulagem** – acontece quando as categorias atribuem julgamentos diferentes a situações iguais. Dois professores avaliando a mesma redação com critérios distintos ensinam “regras confusas” ao algoritmo.
- **Viés temporal** – dados muito antigos refletem valores, expressões ou contextos que já mudaram (por exemplo, livros de 1950 com linguagem sexista).

Ideia-chave: viés não é “erro de cálculo”; é o reflexo de quem coletou, onde, quando e como. Se não for reconhecido e corrigido, transfere desigualdades humanas para as decisões automatizadas.

Mesmo um arquivo perfeitamente preenchido e sem falhas técnicas pode carregar viés se incluir só parte da população. Por isso, revisar qualidade e viés deve andar junto: garantimos que os números estão corretos e que contam a história completa – não apenas o capítulo mais fácil de ler.

## Princípios da LGPD e UNESCO — traduzidos para o dia a dia

Princípio	Pergunta prática a fazer	Exemplo em aula
<b>Finalidade</b>	“Para que preciso desse dado?”	Só recolher CPF se houver justificativa (ex.: emitir certificado).
<b>Necessidade</b>	“Posso cumprir o objetivo com menos dados?”	Registrar só o e-mail, não o endereço completo, para enviar atividades.
<b>Transparência</b>	“Expliquei claramente o uso?”	Informar aos alunos que as redações serão avaliadas por IA e guardadas por 1 ano.
<b>Segurança</b>	“Onde guardarei e quem acessa?”	Usar senha forte no Drive da escola e limitar o acesso a professores.
<b>Inclusão (UNESCO)</b>	“Alguém pode ser excluído?”	Garantir que alunos sem smartphone recebam material impresso equivalente.
<b>Accountability (OCDE)</b>	“Quem é responsável se algo der errado?”	Definir que a coordenação revisa relatórios antes de compartilhar fora da escola.

## Segurança dos Dados na IA

### Orientações para a atividade prática

Esta atividade tem como objetivo levar os estudantes a aplicar, em situações concretas, os conceitos discutidos neste módulo, especialmente dados pessoais e sensíveis, ciclo de vida dos dados, qualidade e viés, finalidade, necessidade, transparência, segurança, inclusão e responsabilização no uso da Inteligência Artificial. Mais do que identificar se uma tecnologia é “boa” ou “ruim”, a proposta é analisar em que condições seu uso pode ser considerado aceitável, questionável ou inaceitável no contexto escolar.

A dinâmica foi planejada para que os estudantes atuem como avaliadores de situações que envolvem coleta, armazenamento, processamento, compartilhamento e uso de dados em ambientes educacionais. Para isso, cada grupo receberá um cartão com um caso realista ou inspirado em situações possíveis, devendo ler, interpretar, diagnosticar e argumentar sobre o caso apresentado.

Antes de iniciar a atividade, recomenda-se que o professor retome brevemente os princípios discutidos anteriormente no módulo, destacando que toda análise deve considerar, pelo menos, as seguintes perguntas: qual é a finalidade da coleta de dados? Os dados solicitados são realmente necessários? O uso está claro para os envolvidos? Há medidas de segurança? Existe risco de exclusão, exposição ou discriminação? Quem se responsabiliza caso algo dê errado?

### Desenvolvimento da dinâmica

Organize a turma em grupos de quatro a cinco estudantes. Entregue um cartão de caso para cada grupo e solicite que escolham um relator. Esse relator será o responsável por apresentar o caso aos demais colegas, mas a análise deve ser construída coletivamente pelo grupo.

Após a leitura do cartão, o grupo deverá identificar o objetivo central da proposta apresentada, os possíveis benefícios pedagógicos ou administrativos, os dados que serão coletados ou utilizados, os principais riscos envolvidos e a posição inicial do grupo sobre o caso. É importante que os estudantes percebam que nem todo problema está apenas na tecnologia em si, mas também na forma como ela é implementada, nos dados que utiliza, nas finalidades declaradas e na ausência ou presença de salvaguardas.

Na etapa seguinte, o relator apresenta o caso para a turma, explicando de maneira sintética o que está sendo proposto, quais dados estão em jogo, quais benefícios são alegados e quais riscos o grupo identificou. Depois da apresentação, os demais grupos terão um tempo curto para expor seu entendimento e emitir um veredicto argumentado sobre o caso.

O professor atua como mediador do debate, garantindo que os estudantes fundamentem suas falas nos princípios discutidos ao longo do módulo e evitando que a discussão se reduza a opiniões vagas ou exclusivamente intuitivas.

### Critérios para o julgamento dos casos

Para tornar o debate mais consistente, os grupos podem utilizar os seguintes critérios de análise:

**Aceitável:** quando há finalidade clara, coleta proporcional, transparência, proteção dos dados, limitação de acesso, responsabilidade definida e baixo risco de dano ou discriminação.

**Questionável:** quando a proposta apresenta um objetivo legítimo, mas possui fragilidades importantes, como coleta excessiva, falta de clareza sobre consentimento, ausência de política de descarte, uso secundário mal definido ou riscos de viés e exposição.

**Inaceitável:** quando há coleta desproporcional, uso indevido de dados, tratamento de dados sensíveis sem justificativa adequada, ausência de transparência, risco elevado de vigilância, discriminação, exploração comercial ou violação de direitos dos estudantes.

Essas categorias ajudam os estudantes a compreender que a discussão ética sobre IA não é apenas técnica, mas também pedagógica, social e institucional.

### Apresentação dos cartões de caso

Os cartões a seguir foram elaborados para apoiar a discussão em sala de aula. Cada um apresenta uma situação envolvendo IA, dados escolares e possíveis tensões entre inovação, eficiência, segurança, direitos e equidade. Recomenda-se que o professor distribua um cartão

---

por grupo e oriente os estudantes a fazerem uma leitura atenta, buscando responder às perguntas-guia propostas ao final de cada caso.

Para facilitar a análise, o professor pode orientar os grupos a observarem, em todos os cartões, cinco elementos centrais: o contexto da situação, os dados envolvidos, os benefícios prometidos, os riscos identificáveis e os princípios que podem estar sendo respeitados ou violados. Diversos cartões podem ser elaborados para que os estudantes discutam e reflitam sobre a segurança dos dados. A seguir, os cartões dos planos de aula são detalhados.

## Cartão 1. Uniforme Inteligente

Uma escola estadual firmou parceria com uma startup para introduzir camisetas que trazem um chip RFID costurado na gola. A ideia é que, ao atravessar catracas instaladas nos portões, cada aluno seja automaticamente identificado: o sistema registra o horário de entrada e de saída, libera ou bloqueia a passagem e, em seguida, envia um SMS aos responsáveis. Esses registros (ID do chip, número de matrícula, horário e local) são transmitidos em tempo real para servidores na nuvem mantidos pela própria startup — servidores que, além de estarem fora do Brasil, não contam com cláusulas específicas que equiparem sua proteção à LGPD. Embora o serviço não custe nada à escola, o contrato prevê que a empresa possa “utilizar os dados para fins de melhoria de produto”, sem definir limites concretos. O consentimento é considerado tácito: basta assinar o Termo de Matrícula. Isso cria um cenário de rastreamento contínuo dentro do ambiente escolar, sem política clara de descarte ao fim do ano letivo, e com riscos de uso secundário dos dados de localização dos estudantes.

**Perguntas-guia:** 1) A coleta é proporcional à finalidade? 2) Como prevenir que o sistema seja usado para vigiar rotas internas (banheiro, pátio)? 3) Quem responde se os servidores externos forem invadidos?

## Cartão 2. App de Redação

Para agilizar a correção de textos, a secretaria adotou um aplicativo de IA generativa: o aluno digita a redação, o texto é enviado à nuvem da empresa, o modelo devolve nota e feedback instantâneo — e, em seguida, armazena a redação num banco que alimenta ciclos futuros de treinamento. Junto com o texto vão metadados como data, escola, série e até gênero declarado. O licenciamento é “gratuito para escolas públicas”, mas a mesma empresa comercializa uma versão premium para cursinhos privados. Não existe opção de opt-out: a redação só pode ser entregue via app. Além da possibilidade de que os textos passem a circular como exemplos “exemplares” sem anonimização perfeita, há a discussão sobre direitos autorais — afinal, a obra pertence ao estudante, mas o contrato embutido no cadastro não esclarece se ele cede esses direitos. Há ainda o risco de que opiniões sensíveis sejam incorporadas ao modelo e reapareçam em respostas futuras.

**Perguntas-guia:** O aluno mantém direitos sobre o conteúdo? 2) Como garantir que dados sensíveis não fiquem expostos? 3) O feedback automatizado pode reforçar viés de linguagem?

### Cartão 3. Câmera no Refeitório

Para reduzir o desperdício de merenda, a escola instalou uma câmera em posição elevada sobre a esteira de bandejas devolvidas. O sistema de visão computacional, hospedado numa API externa, calcula quantos gramas de comida foram desperdiçados a cada refeição. Para funcionar, a câmera precisa captar vídeo em alta definição, deixando inevitavelmente os rostos dos alunos visíveis. As imagens, associadas à data, ao tipo de alimento e à fila percorrida, ficam armazenadas por doze meses “para auditoria ambiental”. Passados alguns meses, a direção considerou reutilizar o banco de imagens para correlacionar padrão nutricional por aluno com o desempenho escolar, o que configuraria uso de dados de saúde. Como se trata de informação sensível, qualquer reaproveitamento exigiria novo consentimento. Além disso, existe a possibilidade de estigmatização dos estudantes que mais desperdiçam ou que tenham dietas particulares identificáveis.

Perguntas-guia: É possível atingir o mesmo fim sem capturar rostos? 2) O uso secundário exige novo consentimento? 3) Quem tem acesso às imagens e por quê?

### Cartão 4. Banco de Provas Históricas

Um professor resolveu digitalizar provas aplicadas entre 2005 e 2015 para alimentar um gerador de questões por machine learning. O acervo reúne enunciados, imagens, gabaritos e até observações manuscritas do docente, tudo hospedado num Drive compartilhado com pesquisadores universitários. Os alunos atuais recebem exercícios gerados por esse modelo e a universidade pretende publicar artigo descrevendo os resultados. Entretanto, boa parte do material contém logos de editoras e questões licenciadas; as respostas de ex-alunos, coletadas numa época em que não se falava em LGPD, agora ajudam a calibrar a dificuldade do algoritmo. Além da possível infração de direitos autorais, há o risco de viés curricular: muitas questões refletem um programa anterior à BNCC de 2018, com linguagem que hoje pode ser considerada excludente ou enviesada.

#### Encaminhamento final do professor

Ao final das apresentações e dos julgamentos, cabe ao professor retomar os pontos principais que emergiram no debate, comparando os argumentos dos grupos com os princípios da LGPD, com as diretrizes de inclusão e com os cuidados éticos associados ao uso de IA na escola.

Esse fechamento é importante para mostrar que o objetivo da atividade não é apenas “dar um veredicto”, mas desenvolver a capacidade de analisar criticamente propostas tecnológicas que envolvem coleta e tratamento de dados. Em muitos casos, a tecnologia pode até atender a uma necessidade real, mas sua implementação exige limites, regras, transparência e revisão humana.

Como síntese, o professor pode reforçar três ideias centrais: primeiro, que todo uso de dados precisa ter finalidade clara e proporcional; segundo, que inovação pedagógica não justifica vigilância, exposição ou coleta excessiva; e, terceiro, que decisões envolvendo IA na escola devem sempre considerar proteção, equidade, responsabilidade e direitos dos estudantes.

#### Fechamento opcional para o material

A atividade com cartões permite transformar conceitos abstratos em situações concretas de análise e julgamento, aproximando os estudantes de dilemas reais do uso da IA na educação. Ao discutir casos, argumentar com base em princípios e confrontar pontos de vista diferentes, os estudantes desenvolvem não apenas conhecimentos técnicos sobre dados e algoritmos, mas também competências críticas, éticas e cidadãs essenciais para sua formação.

Perguntas-guia:

- 1) Há base legal para reutilizar provas protegidas por copyright?
- 2) 2) O uso das respostas de ex-alunos exige consentimento?
- 3) 3) Manter questões desatualizadas afeta a equidade da avaliação?

# MÓDULO 5

## MODELOS DE LINGUAGEM

### **Objetivo do Módulo:**

Ao final do módulo os professores participantes deverão conhecer os princípios dos modelos de linguagem e de engenharia de prompt.

### **Contempla:**

Aula 11 - Consumo Energético e Pegada Digital

Aula 12 - Engenharia de Prompt

Aula 13 - Prompts Multimodais

---

## CONSUMO ENERGÉTICO E IMPACTO AMBIENTAL

### INTRODUÇÃO

Você já se perguntou quanta energia é necessária para uma simples pergunta feita ao Chat GPT? Ou quanto impacto ambiental existe por trás da criação de uma imagem com inteligência artificial? Embora a IA pareça algo “virtual”, ela depende de enormes quantidades de eletricidade e água para funcionar — e isso tem consequências reais para o planeta. Neste capítulo, vamos explorar os custos energéticos e a pegada de carbono da IA, mostrando como esse tema está cada vez mais presente nas discussões sobre meio ambiente. É importante destacar que muitos dos números apresentados são estimativas realizadas por empresas especializadas em monitoramento ambiental e não necessariamente dados oficiais divulgados pelos próprios desenvolvedores de IA. Mesmo assim, eles ajudam a dimensionar os efeitos desse avanço tecnológico sobre o clima, os recursos naturais e o nosso modo de viver.

O treinamento de modelos de inteligência artificial e seu uso diário representam uma das questões ambientais mais urgentes da nossa era digital (deve ser por isso que muitos indicadores não são publicamente divulgados pelas empresas). Por exemplo, o antigo modelo, GPT-3, consumia 1.287 MWh de energia - equivalente ao consumo de 120 casas estadunidenses durante um ano inteiro (Statista, 2022; ADaSci, 2024).


Os números são alarmantes: em apenas cinco anos, os data centers globais passariam de consumir 415 TWh (1,5% da eletricidade mundial) com projeções de 945 TWh até 2030 (3% do consumo global) segundo a IEA (2025) e Goldman Sachs (2024). Outra pesquisa (Shah, 2025) indica que em 2023, os data centers consumiram 4,4% da eletricidade dos EUA, e estima-se que esse valor suba para 6,7% a 12% até 2028.

Pela primeira vez na história, os data centers devem superar a aviação em emissões globais de carbono (Tremayne-Pengelly, 2024). Simultaneamente, empresas como Google viram suas emissões crescerem 48% desde 2019 devido à expansão da IA, enquanto Microsoft registrou aumento de 29% desde 2020 (NPR, 2024). Essas tendências revelam que, apesar dos benefícios transformadores da IA, sua pegada ambiental está crescendo mais rapidamente que as soluções sustentáveis.

### O GIGANTE ENERGÉTICO POR TRÁS DA INTELIGÊNCIA ARTIFICIAL

Cada vez que você faz uma pergunta ao Chat GPT, está acionando um processo que consome 10 vezes mais energia que uma busca no Google (Tom's Guide, 2024). Para contextualizar essa diferença: uma única consulta ao Chat GPT usa energia suficiente para manter uma lâmpada LED da sua casa acesa por 20 minutos, enquanto uma busca tradicional no Google manteria a mesma lâmpada acesa por apenas 2 minutos (NPR, 2024). Já o treinamento de grandes modelos de IA consome quantidades extraordinárias de energia. O GPT-3, com seus 175 bilhões de parâmetros, necessitou de 1.287 MWh apenas para ser treinado - isso equivale à energia gerada em joules por 112 carros a gasolina durante toda sua vida útil (Statista, 2022).

Para tornar esses números mais tangíveis, considere que gerar uma única imagem com IA consome energia equivalente a carregar de 50% a 100% um smartphone (depende do modelo). Se você produzir 1.000 imagens usando Stable Diffusion XL, isso consumiria aproximadamente 11.400 Wh - energia suficiente para manter uma geladeira funcionando por aproximadamente uma semana inteira. Em termos de emissões de carbono, essa mesma atividade liberaria CO<sub>2</sub> equivalente ao de dirigir 6,6 quilômetros em um carro movido a gasolina (Akepa, 2025). Quando multiplicamos isso pela escala global - bilhões de consultas diárias - o impacto se torna monumental.



Fonte: Akepa (2025)

## PEGADA DE CARBONO E EMISSÕES DOS MODELOS

A pegada de carbono do treinamento de IA é comparável às emissões de indústrias inteiras. O treinamento do GPT-3 emitiu 552 toneladas métricas de CO<sub>2</sub> equivalente, o mesmo que cinco carros produziram durante toda sua vida útil ou 300 voos de ida e volta entre Nova York e São

Francisco (Akepa, 2025). O modelo Llama 3.1 da Meta foi ainda mais impactante, emitindo 8.930 toneladas de CO<sub>2</sub> - equivalente às emissões de 496 estadunidenses vivendo um ano completo.

Quando analisamos as emissões por consulta individual, uma pergunta ao ChatGPT gera aproximadamente 2,2g de CO<sub>2</sub> equivalente (considerando tanto a operação quanto à parcela amortizada do treinamento), enquanto uma busca tradicional no Google produz apenas 0,2g - uma diferença de 11 vezes (Sustainability by Numbers, 2024). Para perspectiva, apenas 16 perguntas (inferências) ao Chat GPT produzem emissões equivalentes a ferver uma chaleira de água (Plan Be Eco, 2024).

## CUSTOS ECONÔMICOS DOS MODELOS DE IA

Os custos de treinamento cresceram exponencialmente nos últimos anos. Desde 2017, os custos aumentaram 200.000 vezes (World Economic Forum, 2024), transformando o treinamento de IA em um investimento comparável ao desenvolvimento de grandes infraestruturas. Os valores em dólares americanos são impressionantes:

O GPT-3 custou aproximadamente US\$ 4,6 milhões para ser treinado, enquanto o GPT-4 demandou cerca de US\$ 78 milhões (World Economic Forum, 2024). O Gemini Ultra do Google teve custo estimado de US\$ 191 milhões, tornando-se um dos modelos mais caros já desenvolvidos (Codingscape, 2024). O modelo LLaMA completo (incluindo todas as variantes 7B, 13B, 33B e 65B) custou aproximadamente US\$ 7 milhões no total, com a variante LLaMA-7B custando cerca de US\$ 82.432 individualmente.

Para contexto brasileiro (cotação de R\$ 5,80 por dólar):

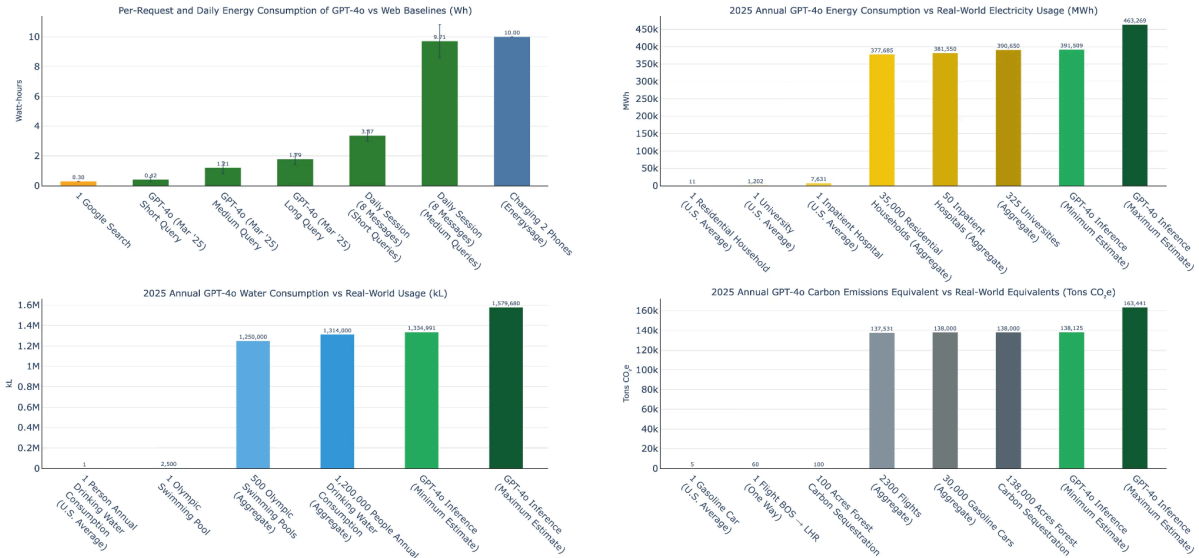
- GPT-3: US\$ 4,6 milhões (R\$ 26,68 milhões)
- GPT-4: US\$ 78 milhões (R\$ 452,4 milhões)
- Gemini Ultra: US\$ 191 milhões (R\$ 1,108 bilhão)
- LLaMA (todos modelos): US\$ 7 milhões (R\$ 40,6 milhões)
- LLaMA-7B: US\$ 82.432 (R\$ 478.105)

## CONSUMO NA FASE DE INFERÊNCIA VS. TREINAMENTO

Contrariamente à intuição, o maior impacto ambiental da IA não ocorre durante o treinamento, mas durante o uso diário (inferência) (MIT News, 2025). Embora o treinamento do GPT-3 tenha consumido 1.287 MWh, o Chat GPT consumia 564 MWh anualmente apenas em operação (SwissCognitive, 2023). Em relação ao GPT4, os números sobem para 1.750 MWh de treinamento e um consumo anual de 463.269 MWh (Jegham et al., 2025). O treinamento gera um impacto ambiental intenso, porém pontual. Já a inferência, por seu caráter repetitivo e em larga escala, torna-se o principal fator de consumo energético acumulado, correspondendo à maior parte da pegada de energia ao longo da vida útil do modelo — ou seja, gasta mais energia em termos cumulativos do que o treinamento.

Se todas as 9 bilhões de buscas diárias do Google fossem substituídas por consultas de IA generativa, o consumo seria equivalente ao de toda a Irlanda (29,2 TWh) por um ano, segundo

análise de Vries (2023). Essa projeção ilustra como a adoção em massa de IA pode rapidamente superar qualquer economia obtida durante o desenvolvimento.



Fonte: de Vries (2023)

### INICIATIVAS DE IA VERDE EMERGENTES

O setor está respondendo com várias iniciativas ambiciosas. A Coalition for Environmentally Sustainable AI, lançada em 2025, reúne mais de 100 parceiros incluindo 37 empresas de tecnologia, 11 países e 5 organizações internacionais, estabelecendo padrões globais para sustentabilidade em IA (UNEP, 2025). Ela tem como objetivo reunir uma comunidade global de atores (governos, setor privado, academia e sociedade civil) para acelerar iniciativas concretas que alinhem o desenvolvimento da IA a metas ambientais globais. Além disso, pretende estabelecer um espaço colaborativo e aberto para promover padrões, metodologias e projetos que reduzam o impacto ecológico da IA, ao mesmo tempo em que potencializam seu uso para proteger o planeta.

Grandes empresas também estão investindo pesadamente em soluções. A Microsoft comprometeu US\$ 1 bilhão através do Climate Innovation Fund, desenvolvendo ferramentas como MatterGen e MatterSim que usam IA para descobrir materiais mais eficientes (Microsoft, 2024; Microsoft, 2025). O Google estabeleceu a meta de energia 24/7 livre de carbono até 2030 (Dave, 2020), enquanto a NVIDIA desenvolve "superchips" que prometem melhorias de desempenho 30x usando 25x menos energia (Takahashi, 2024).

Inovações técnicas estão surgindo rapidamente. Modelos esparsos com ativação seletiva podem consumir menos de 1/10 da energia de modelos densos tradicionais sem perder precisão (Patterson *et al.*, 2021). Agendamento inteligente baseado em disponibilidade de energia renovável permite que treinamentos ocorram quando energia solar e eólica estão abundantes.

---

Data Centers em regiões frias como Suécia e Finlândia aproveitam o resfriamento natural, reduzindo significativamente o consumo energético (Walsh-Elwell, 2022).

## O OUTRO LADO DA MOEDA

Você já refletiu sobre quanto tempo uma pessoa mantém o computador ligado apenas para redigir um texto? Esse processo pode levar horas ou até dias, com longos períodos dedicados à digitação, revisão de palavras e correções gramaticais. Estima-se que a IA para escrita reduz emissões em 130 a 1 500 vezes em relação a produção humana. Da mesma forma um artista ou designer para desenhar uma imagem. A criação de imagens por inteligência artificial (via DALL-E 2 ou Midjourney) emite de 310 a 2.900 vezes menos CO<sub>2</sub> por imagem do que o processo de criação humana. O uso de inteligência artificial gera significativamente menos CO<sub>2</sub> do que o uso de um computador para auxiliar os humanos na criação de imagens (Tomlinson *et al.*, 2024).

## CONCLUSÃO

A IA representa simultaneamente uma das maiores oportunidades e ameaças ambientais do nosso tempo. Enquanto a IA pode acelerar descobertas em energia renovável, otimizar sistemas urbanos e revolucionar a educação, seu próprio crescimento ameaça os objetivos climáticos globais. Os próximos 3-5 anos serão decisivos para determinar se conseguiremos equilibrar os benefícios transformadores da IA com sua sustentabilidade ambiental.

Ensinar sobre IA e meio ambiente não é apenas sobre tecnologia - é sobre formar cidadãos conscientes que compreenderão as implicações de suas escolhas digitais. Quando estudantes entendem que cada consulta em um sistema de IA tem um custo ambiental real, é possível desenvolver o pensamento crítico necessário para usar tecnologia de forma responsável. A educação ambiental digital é urgente. A próxima geração herdará um mundo onde a IA estará integrada a praticamente todos os aspectos da vida. Preparar jovens para navegar esse futuro com consciência ambiental, pensamento crítico e responsabilidade coletiva pode ser uma das contribuições mais importantes que educadores podem fazer para a sustentabilidade do planeta e o bem-estar humano. Sim, existem maneiras de tornar a IA mais sustentável:

- Otimização e eficiência: Melhorar os algoritmos e usar tecnologias de resfriamento mais eficientes reduz o consumo de energia necessário para treinar e operar modelos de IA.
- Energia limpa e reutilização: Utilizar fontes de energia renováveis (como solar e eólica) nos data centers e adotar práticas de reciclagem e reutilização de hardware diminui o impacto ambiental.
- IA a favor do meio ambiente: Aplicar a IA em iniciativas de conservação ambiental — como monitoramento climático, gestão de recursos naturais e proteção da biodiversidade — pode apoiar práticas mais sustentáveis.

O desafio não é evitar a IA, mas utilizá-la sabiamente. Cada pergunta que fazemos, cada imagem que geramos, cada sistema que automatizamos representa uma escolha - e entender as

consequências dessas escolhas é o primeiro passo para construir um futuro onde inteligência artificial e sustentabilidade ambiental caminhem juntas.

## ENGENHARIA DE PROMPT

### INTRODUÇÃO

A Inteligência Artificial (IA) tornou-se uma presença constante em nossa sociedade e nos sistemas tecnológicos atuais. Desde sua popularização no final do ano de 2022, seu uso já está se consolidado em diversas áreas, influenciando significativamente a forma como lidamos com a tecnologia. Esse avanço demanda que a educação acompanhe essa transformação, preparando os estudantes para um futuro em que a IA será tão comum quanto o uso do computador atualmente. Dentro desse contexto, a engenharia de prompts se destaca como uma competência fundamental, independentemente da carreira que o estudante busque seguir. Saber elaborar instruções claras e bem estruturadas para sistemas de IA permite que você obtenha respostas (previsões) mais pertinentes e utilize essas ferramentas de forma estratégica.

Aprender a construir bons prompts envolve habilidades como domínio da linguagem, clareza na formulação de perguntas, organização lógica das ideias e capacidade de interpretação. Quanto mais preciso e fundamentado for o prompt, melhor será a qualidade da resposta gerada pela IA. Assim, quanto mais criativo for o estudante ao elaborar o prompt, mais interessante, útil e inovadora será a resposta produzida — pois é da mente humana que surge a originalidade, não da máquina ou tecnologia utilizada.

Mais do que substituir o pensamento crítico, a proposta é utilizar a IA como aliada na análise e aprofundamento das informações, promovendo a autonomia intelectual dos estudantes. Essa abordagem amplia as possibilidades pedagógicas e prepara os alunos para atuarem de forma consciente em um cenário cada vez mais mediado por tecnologias ditas inteligentes.

No campo educacional, essa competência assume ainda mais relevância. Ao criar um prompt, o estudante não atua de forma passiva. Pelo contrário, precisa analisar sua própria dúvida, organizar o pensamento e expressar o que quer de forma lógica e compreensível. Esse processo estimula o raciocínio crítico, a clareza na comunicação e a autonomia intelectual. A consequência é uma melhora significativa na qualidade das respostas geradas pela IA, seja para estudos, produção de textos, pesquisas, geração de imagens, áudios ou vídeos e outros tipos de mídias.

A engenharia de prompts representa, portanto, uma habilidade cognitiva e comunicativa essencial na contemporaneidade. Dominar essa forma de interação com máquinas significa não só obter respostas mais eficazes, mas também desenvolver consciência crítica sobre o funcionamento e os limites das tecnologias baseadas em IA. O usuário passa a ser um protagonista na construção do conhecimento, e não apenas um mero consumidor dessa tecnologia.

Outro aspecto fundamental da engenharia de prompts é o feedback presente nas interações com a IA. Esse retorno contínuo permite ao usuário ajustar suas perguntas e reformular

---

estratégias, otimizando a qualidade das respostas ao longo do tempo. Esse processo iterativo torna o uso da IA mais preciso, eficiente e alinhado às necessidades reais de quem a utiliza.

## UMA NOVA COMPETÊNCIA PARA O SÉCULO XXI

A revolução da inteligência artificial chegou às salas de aula brasileiras, e com ela surge uma nova competência essencial para os educadores: a engenharia de prompt. Esta disciplina emergente representa muito mais que um conjunto de técnicas computacionais – é uma ferramenta pedagógica poderosa que pode personalizar o ensino, otimizar o tempo docente e preparar os estudantes para um futuro em que a colaboração Humano-IA será fundamental.

No Brasil, onde 74,8% dos professores já demonstram apoio ao uso de IA na educação, mas apenas 39,2% a utilizam regularmente, existe uma lacuna significativa entre aceitação e implementação prática (AGÊNCIA BRASIL, 2024). Este capítulo foi desenvolvido para preencher essa lacuna, oferecendo conhecimentos teóricos sólidos e habilidades práticas que podem ser aplicadas imediatamente em sala de aula.

A engenharia de prompt é a arte de criar instruções claras e objetivas que ajudam a inteligência artificial a entender e executar tarefas com eficiência. Trata-se de uma disciplina voltada ao desenvolvimento e à otimização de comandos (prompts) para utilizar modelos de linguagem em diversas aplicações. Para nós, educadores, isso significa aprender a nos comunicar de forma precisa com ferramentas de IA para criar conteúdos, personalizar atividades, gerar avaliações e otimizar processos pedagógicos. Imagine que estamos dialogando com um assistente muito inteligente, mas que depende da clareza das instruções para compreender exatamente o que se deseja — a qualidade da comunicação define diretamente a qualidade dos resultados obtidos. Não se trata de substituir o professor, mas de ampliar suas capacidades, liberando tempo para o que realmente importa: a interação humana, o desenvolvimento socioemocional e a mediação do conhecimento.

Esta definição ganha dimensões práticas quando consideramos que habilidades de engenharia de prompt de maior qualidade predizem diretamente a qualidade das respostas dos modelos de IA. Isso significa que um professor que domina essas técnicas pode obter materiais pedagógicos mais ricos, avaliações mais adequadas e suporte pedagógico mais efetivo das ferramentas de IA disponíveis. Da mesma forma, o estudante que aprende a formular bons prompts desenvolve sua capacidade de comunicação, pensamento crítico e resolução de problemas, tornando-se mais autônomo e estratégico na busca por conhecimento.

A evolução da engenharia de prompt acompanha o desenvolvimento dos modelos de linguagem. Começamos com sistemas simples de comando e linha, progredimos para interfaces mais sofisticadas, até chegarmos aos atuais modelos conversacionais, também conhecidos por *Large Language Models* (vide algumas opções na imagem a seguir). Cada geração trouxe maior capacidade de compreensão contextual e, conseqüentemente, maior necessidade de refinamento nas técnicas de comunicação com esses sistemas.



Diferentes Soluções de LLMs

O contexto brasileiro torna essa competência ainda mais relevante. Com o Plano Brasileiro de Inteligência Artificial prevendo investimentos de R\$ 817 milhões na educação até 2028 (Brasil, 2024), e o Piauí sendo reconhecido como o primeiro território das Américas a implementar IA como disciplina obrigatória, estamos vivenciando um momento histórico de transformação educacional. Estudos recentes demonstram que estudantes que receberam treinamento em engenharia de prompt superaram significativamente seus pares em todas as dimensões da taxonomia de Bloom, evidenciando o potencial transformador desta competência (ScienceDirect, 2025).

Lembre-se: um mesmo prompt pode gerar respostas diferentes dependendo do modelo de linguagem utilizado, pois cada LLM (Large Language Model) é treinado com conjuntos distintos de dados, o que influencia diretamente na forma como compreende e responde às solicitações. Por exemplo, um modelo treinado com foco em textos acadêmicos tende a gerar respostas mais formais e técnicas, enquanto outro, com base em redes sociais, pode apresentar uma linguagem mais coloquial. Além disso, mesmo utilizando o mesmo modelo, as respostas podem variar entre execuções. Isso acontece porque os modelos operam com base em previsões estatísticas, selecionando entre várias possibilidades de continuação — o que inclui um grau de aleatoriedade controlada, fazendo com que as respostas não sejam sempre idênticas. Esse comportamento reforça a importância de ajustar e refinar os prompts de forma iterativa para alcançar melhores resultados.

### EVIDÊNCIAS DE EFICÁCIA NA EDUCAÇÃO

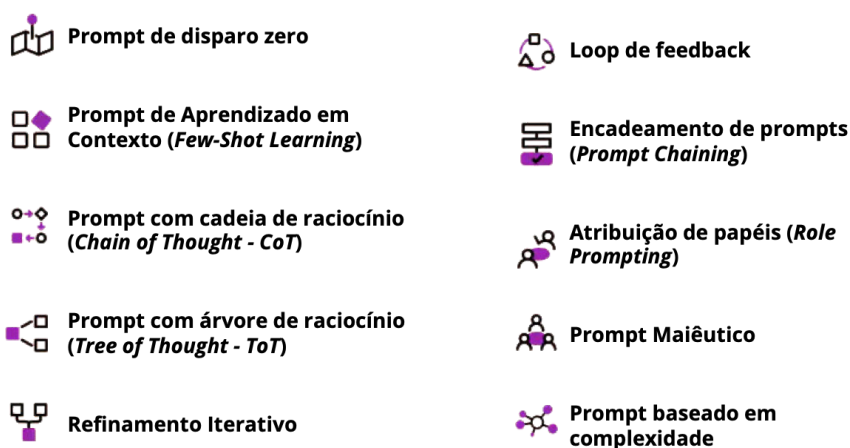
As evidências científicas sobre a eficácia da engenharia de prompt na educação são robustas e crescentes. Uma pesquisa experimental envolvendo 157 estudantes de engenharia demonstrou que o grupo que recebeu treinamento em prompt engineering obteve médias significativamente superiores: 6,60 pontos comparado a 4,94 do grupo sem treinamento e 4,28 do grupo controle. Essa melhoria foi observada em todas as três dimensões da taxonomia de Bloom: conhecimento, compreensão e aplicação (Garg *et al.*, 2025). Outros estudos sobre IA na educação indicam potencial para melhorias em habilidades de pensamento crítico e engajamento estudantil, embora pesquisas específicas sobre engenharia de prompt na

educação básica brasileira ainda sejam limitadas e necessitem de maior desenvolvimento científico (Substack, 2024).

No contexto brasileiro, estudos sobre sistemas de avaliação automática de redação para o ENEM revelaram que a IA pode ajudar a superar gargalos que impedem o acúmulo de habilidades de escrita, permitindo que professores realoquem seu tempo de correção para fornecer assistência mais personalizada aos estudantes (AGÊNCIA BRASIL, 2024). Esta descoberta é particularmente relevante considerando que muitos professores brasileiros relatam sobrecarga com correções e atividades administrativas.

## TÉCNICAS E ESTRATÉGIAS DE PROMPTING: DOMINANDO AS FERRAMENTAS

No contexto educativo, as técnicas de “prompting” oferecem abordagens complementares para maximizar a eficácia da IA em sala de aula. Juntas, essas técnicas possibilitam combinar direcionamento por exemplos, explanação clara, adaptação ao perfil do estudante e construção modular de conhecimento, criando experiências de aprendizagem mais ricas e eficazes. Vamos conhecer cada uma delas?



- 1) **Prompt de disparo zero:** Consiste em apresentar uma tarefa ou pergunta à IA sem fornecer exemplos anteriores ou instruções específicas sobre o tema. A resposta depende da base de conhecimento já adquirida pelo modelo durante o treinamento. Essa técnica é muito utilizada por sua praticidade e por funcionar em diversas situações. Exemplo: "Explique o que é o ciclo da água." — A IA responde diretamente com base em seu conhecimento prévio, sem que o usuário precise dar contexto ou estrutura adicional.
- 2) **Prompt de Aprendizado em Contexto (Few-Shot Learning)**  
É uma das técnicas mais acessíveis e eficazes para estudantes iniciantes em engenharia de prompt. A estratégia consiste em fornecer 2 a 5 exemplos específicos no prompt para orientar o modelo de IA sobre o formato e o tipo de resposta desejada. Esta técnica é particularmente útil para tarefas que requerem formato específico, classificação de conteúdo ou geração de material educacional estruturado.

Considere este exemplo prático para criar questões de múltipla escolha:

"Tarefa: Criar questões de múltipla escolha sobre [TÓPICO].

Exemplo 1: Tópico: Fotossíntese.

Questão: Qual é o principal produto da fotossíntese? a) Oxigênio b) Dióxido de carbono c) Glicose d) Água. Resposta: c) Glicose.

Exemplo 2: Tópico: Revolução Industrial.

Questão: Em que século começou a Revolução Industrial? a) XVII b) XVIII c) XIX d) XX. Resposta: b) XVIII.

Agora crie uma questão sobre: [SEU TÓPICO]."

A eficácia do *few-shot learning* é comprovada por estudos que mostram melhoria de 40-60% na consistência das respostas comparado ao zero-shot prompting (quando não fornecemos exemplos). Para professores de matemática, isso pode significar a diferença entre receber problemas mal estruturados e exercícios pedagogicamente organizados. Para professores de português, pode ser a diferença entre sugestões genéricas de redação e prompts específicos que estimulam a criatividade dos alunos dentro dos parâmetros desejados.

### 3) Prompt com cadeia de raciocínio (*Chain-of-Thought - CoT*)

A técnica é revolucionária por ensinar a IA a explicar seu raciocínio antes de apresentar respostas finais. Esta abordagem é especialmente valiosa para disciplinas que requerem resolução de problemas, como matemática, física e química, mas também se aplica efetivamente em análises históricas, interpretação de textos e raciocínio científico.

Existem duas variações principais do CoT. O zero-shot CoT utiliza simplesmente a frase "Vamos pensar passo a passo:" após apresentar o problema. O few-shot CoT fornece exemplos de raciocínio estruturado. Por exemplo:

Prompt: "Maria tem 20 livros. Ela empresta 3 para João e 5 para Ana. Depois compra mais 8 livros. Quantos livros Maria tem agora? Vamos pensar passo a passo"

A IA responde: "Maria começou com 20 livros. Empréstou  $3 + 5 = 8$  livros, ficando com  $20 - 8 = 12$  livros. Depois comprou 8 livros, totalizando  $12 + 8 = 20$  livros. Resposta: 20 livros."

A eficácia do chain-of-thought é impressionante: pesquisas mostram melhoria de 78% em problemas matemáticos quando comparado a prompts simples (Deepgram, 2024). Contudo, é importante notar que essa técnica funciona melhor com modelos mais avançados (acima de 100 bilhões de parâmetros). Isso significa que o CoT é ideal para tarefas de raciocínio complexo, permitindo que os alunos vejam não apenas as respostas, mas também o processo de pensamento que leva às soluções.

#### 4) **Prompt com árvore de raciocínio (*Tree of Thought - ToT*)**

Ampliando o conceito da cadeia de raciocínio, essa abordagem permite que o modelo explore diferentes caminhos possíveis antes de chegar a uma conclusão. É apropriada para casos em que múltiplas soluções ou pontos de vista devem ser considerados.

Exemplo de prompt: *"Um estudante tem três opções de carreira: Programação, Arquitetura e Artes. Analise os prós e contras de cada caminho antes de sugerir uma escolha possível. Explore diferentes possibilidades de acordo com perfis e interesses."*

A IA irá desenvolver diferentes ramificações de análise — como tempo de formação, mercado de trabalho, afinidades pessoais e impactos sociais — antes de apresentar uma conclusão ponderada.

Para educadores que desejam explorar técnicas mais sofisticadas, o Tree of Thoughts (ToT) permite que a IA explore múltiplos caminhos de raciocínio simultaneamente, avaliando e descartando opções menos promissoras. Um template simplificado seria:

*"Imagine que três especialistas diferentes estão respondendo a esta pergunta. Cada especialista irá: 1. Escrever um passo do seu raciocínio, 2. Compartilhar com o grupo, 3. Continuar para o próximo passo, 4. Se perceberem que estão errados, saem da discussão. Pergunta: [SUA PERGUNTA]."*

O prompt chaining divide tarefas complexas em subtarefas menores, onde a saída de um prompt alimenta o próximo. Para criação de conteúdo educacional, isso pode ser estruturado em três prompts sequenciais: primeiro, criar um esboço detalhado da aula; segundo, desenvolver o conteúdo completo baseado no esboço; terceiro, criar questões de avaliação baseadas no conteúdo desenvolvido.

#### 5) **Refinamento iterativo**

Nesse processo, a primeira resposta gerada pela IA é revisada e melhorada em etapas sucessivas, com novos prompts direcionando correções ou ajustes específicos. Essa estratégia é útil quando se busca maior precisão ou qualidade na resposta final.

Exemplo de uma interação:

Usuário: *"Escreva um parágrafo sobre a Revolução Francesa."*

IA responde com um parágrafo genérico.

Usuário: *"Agora melhore a coesão e inclua datas específicas."*

IA refina o texto.

Usuário: *"Reduza para três linhas, mantendo os principais eventos."*

A resposta é ajustada novamente, com mais clareza e concisão.

## 6) Loop de feedback

Esse método envolve fornecer retornos contínuos ao modelo durante sua execução, permitindo que ele ajuste suas respostas com base em novas informações. O processo melhora progressivamente o desempenho da IA e sua capacidade de adaptação.

Diferente do refinamento iterativo, que parte de uma resposta finalizada e a revisa por etapas sucessivas, o loop de feedback ocorre de forma dinâmica e interativa, com correções sendo aplicadas no próprio fluxo de construção da resposta.

Exemplo de interação:

Usuário: *"Resuma este texto."*

IA responde com um resumo.

Usuário: *"Você omitiu o ponto principal sobre as causas do problema. Inclua isso e reduza as repetições."*

IA ajusta a resposta em tempo real.

Usuário: *"Agora reescreva em linguagem mais acessível para alunos do ensino médio."*

A IA adapta novamente, construindo a versão final com base nos feedbacks progressivos

## 7) Encadeamento de prompts (prompt chaining)

Aqui, os prompts são estruturados em sequência, de modo que cada nova instrução parte da resposta anterior. Esse encadeamento é indicado para tarefas compostas por várias etapas interdependentes.

Diferente do refinamento iterativo ou do loop de feedback, que visam melhorar uma única resposta, o encadeamento de prompts constrói um processo em etapas, onde cada resposta serve como base para a próxima. A ênfase está no desenvolvimento progressivo de um raciocínio ou conteúdo, e não apenas em sua revisão.

Exemplo de interação:

1. *"Liste três problemas ambientais enfrentados atualmente no Brasil."*
2. Com base na resposta: *"Explique as causas do primeiro problema citado."*
3. Depois: *"Proponha duas soluções para esse problema, considerando políticas públicas e ações individuais."*

Nesse modelo, a IA avança etapa por etapa, gerando um resultado final composto por várias partes logicamente conectadas.

## 8) Prompt de Atribuição de papéis (*role prompting*)

O role prompting consiste em atribuir um papel específico ao modelo de IA para ajustar seu tom, expertise e perspectiva. Esta técnica é extremamente versátil na educação, permitindo que a IA assuma diferentes personas pedagógicas conforme a necessidade específica de cada situação de ensino.

O template universal para role prompting é:

*"Você é um [PAPEL] com [X] anos de experiência em [ÁREA]. Seu público-alvo são [DESCRIÇÃO DO PÚBLICO]. Seu estilo de comunicação deve ser [CARACTERÍSTICAS DO ESTILO]. [CONTEXTO ADICIONAL]. Tarefa: [DESCRIÇÃO DA TAREFA]."*

Por exemplo:

*"Você é um professor de história especializado em ensino fundamental com 10 anos de experiência. Seu público-alvo são alunos de 12-13 anos do 7º ano. Seu estilo deve ser didático, envolvente e conectado com a realidade brasileira. Explique as causas da Independência do Brasil de forma que os alunos possam relacionar com questões contemporâneas."*

Pesquisas de 2024 demonstram que o role prompting bem implementado pode melhorar o desempenho em tarefas de raciocínio de 53% para 63% (Prompthub, 2024). Na prática educacional, isso se traduz em respostas mais adequadas ao nível cognitivo dos estudantes, linguagem mais apropriada para cada faixa etária, e abordagens pedagógicas mais alinhadas com objetivos específicos de aprendizagem.

## 9) Prompt Maiêutico

Inspirado no método socrático, esse tipo de prompt conduz a IA por meio de perguntas encadeadas que extraem informações cada vez mais detalhadas, levando o modelo a construir respostas mais refinadas e fundamentadas.

Diferente do encadeamento de prompts tradicional, que estrutura tarefas em etapas técnicas ou lógicas, o prompt maiêutico foca em aprofundar o pensamento por meio de questionamentos sucessivos, geralmente voltados à reflexão, análise crítica ou elaboração conceitual.

Exemplo:

*"O que é democracia?"*

*"Quais são os princípios fundamentais de uma democracia?"*

*"Esses princípios estão sempre presentes em democracias atuais? Por quê?"*

*"Que riscos uma democracia pode enfrentar quando esses princípios são enfraquecidos?"*

A IA é guiada por perguntas que aprofundam gradualmente a análise, como em um diálogo investigativo.

### 10) Prompt por Complexidade

Essa técnica desafia o modelo com diferentes tipos de prompts e avalia a profundidade e sofisticação das respostas geradas. A melhor resposta é selecionada com base em critérios de qualidade, complexidade e relevância.

Diferente de técnicas como o refinamento iterativo ou o loop de feedback, em que há uma única resposta sendo ajustada, o prompt por complexidade gera múltiplas respostas a partir de abordagens distintas, permitindo comparar e escolher a mais adequada para o objetivo proposto.

Exemplo:

O usuário propõe três variações de um mesmo tema:

*"Explique a Revolução Industrial em linguagem simples."*

*"Descreva as causas e consequências econômicas da Revolução Industrial."*

*"Analisar os impactos sociais da Revolução Industrial sob a ótica marxista."*

Com as três respostas em mãos, o usuário então seleciona aquela que melhor atende ao contexto desejado — seja didático, analítico ou crítico.

## ESTRUTURANDO PROMPTS EFICAZES: A ANATOMIA DO SUCESSO

A estrutura de um prompt eficaz segue uma anatomia específica baseada em pesquisas recentes. A estrutura universal recomendada inclui: [PAPEL] definindo claramente o papel da IA, [TAREFA] descrevendo especificamente o que deve ser feito, [CONTEXTO] fornecendo informações relevantes, [INSTRUÇÕES ESPECÍFICAS] listando diretrizes claras, [FORMATO] especificando como a resposta deve ser apresentada, [EXEMPLOS] quando necessário para clarificar expectativas, e [RESTRICÇÕES] definindo o que evitar e o que sempre incluir.

Outras técnicas de otimização incluem o uso de delimitadores XML para organizar informações (<contexto>, <tarefa>, <exemplos>), *prefilling* para iniciar respostas de forma direcionada ("Resposta: Baseado na análise detalhada, posso concluir que..."), e instruções de raciocínio que orientam o processo de pensamento da IA antes da resposta final.

Para finalizar, vamos conhecer uma adaptação dos 25 princípios propostos por outra pesquisa (Bsharat et al., 2023), que também podem ser úteis na hora de criar seus prompts. Alguns já vimos na seção anterior, outros são novos:

#	Princípio
1	Não é necessário ser polido com LLMs, então não é preciso adicionar frases como “por favor”, “se não se importar”, “obrigado”, “eu gostaria de...”, etc. Vá direto ao ponto. Isso economiza energia!
2	Integre o público-alvo no prompt, por exemplo, “o público é especialista no assunto”.
3	Divida tarefas complexas em uma sequência de tarefas mais simples em uma conversa interativa.
4	Use comandos afirmativos como “faça”, evitando linguagem negativa como “não faça”.
5	Quando quiser clareza ou um entendimento mais profundo de um tópico, ideia ou qualquer peça de informação, utilize os prompts a seguir: <ul style="list-style-type: none"> <li>• Explique [tópico específico inserido] em termos simples.</li> <li>• Explique para mim como se eu tivesse 11 anos.</li> <li>• Explique para mim como se eu fosse iniciante em [área].</li> <li>• Escreva o [ensaio/texto/parágrafo] usando português simples como se estivesse explicando para uma criança de 5 anos.</li> </ul>
6	Adicione “Te dou uma gorjeta de \$xxx por uma solução melhor!”
7	Implemente prompting baseado em exemplos (use few-shot prompting).
8	Ao formatar seu prompt, comece com “###Instrução###”, seguido por “###Exemplo###” ou “###Pergunta###” se relevante. Em seguida, apresente seu conteúdo. Use quebras de linha para separar instruções, exemplos, perguntas, contexto e dados de entrada.
9	Incorpore as frases: “Sua tarefa é” e “Você DEVE”.
10	Incorpore as frases: “Você será penalizado”.
11	Use a frase: “Responda a uma pergunta de forma natural, como um humano faria” em seus prompts.
12	Use palavras orientadoras como: “pense passo a passo”.
13	Adicione ao seu prompt a seguinte frase: “Garanta que sua resposta não seja tendenciosa e não dependa de estereótipos”.
14	Permita que o modelo obtenha detalhes e requisitos exatos perguntando de volta até ter informações suficientes para fornecer a resposta necessária (por exemplo, “A partir de agora, gostaria que você me fizesse perguntas...”).
15	Para investigar uma ideia ou tópico específico e verificar se você entendeu corretamente, use a frase: “Ensine-me o [qualquer nome de teorema/tópico/regra] e inclua uma prova no final, mas não me diga as respostas — apenas me diga se acertei quando eu responder”.
16	Atribua um papel ao modelo de linguagem.
17	Use delimitadores.
18	Repita uma palavra ou frase específica várias vezes em um prompt.
19	Combine encadeamento de pensamento (Chain-of-Thought/CoT) com prompts de poucos exemplos (few-shot).

#	Princípio
20	Inclua o começo da resposta desejada no prompt para guiar a continuação automática pelo modelo.
21	Para escrever um ensaio/texto/parágrafo ou qualquer tipo de texto que deve ser detalhado: "Escreva um [ensaio/texto/parágrafo] sobre [tema] em detalhes, adicionando todas as informações necessárias".
22	Para corrigir/alterar texto específico sem mudar o estilo: "Tente revisar cada parágrafo enviado por usuários. Você deve apenas melhorar a gramática e vocabulário do usuário e garantir que soe natural. Você não deve alterar o estilo de escrita, como transformar em um parágrafo formal".
23	Quando você tiver um prompt complexo que possa estar em arquivos diferentes: "A partir de agora e sempre que você encontrar esse padrão mais de uma vez, gere [uma linguagem de programação] script que possa ser usado para automaticamente criar os arquivos especificados ou fazer alterações nos arquivos existentes para inserir o código gerado. [sua pergunta]".
24	Quando quiser iniciar ou continuar um texto usando palavras específicas, frases ou sentenças, use o seguinte prompt: <ul style="list-style-type: none"> <li>• "Estou fornecendo você com o começo [letra de música/história/parágrafo/ensaio...]: [Inserir palavras/sentença/verso]".</li> <li>• Complete com base nas palavras fornecidas. Mantenha o fluxo consistente.</li> </ul>
25	Declare claramente os requisitos que o modelo deve seguir para produzir o conteúdo, na forma de palavras-chave, regras, instruções ou dicas.
26	Para escrever qualquer texto, como ensaio ou parágrafo, que deva ser semelhante a um modelo fornecido, inclua as instruções a seguir: "Use a mesma linguagem baseada no parágrafo/título/texto/[ensaio/resposta] fornecido".

## CONSIDERAÇÕES FINAIS

A engenharia de prompt consolida-se como uma das competências mais relevantes para a formação crítica, criativa e tecnológica dos estudantes do século XXI. Ao dominar essa habilidade, educadores e alunos não apenas aprendem a interagir com sistemas de IA de maneira mais eficaz, mas também desenvolvem capacidades essenciais como organização do pensamento, clareza na comunicação, análise contextual e reflexão ética sobre o uso da tecnologia. Mais do que um conjunto de técnicas, ela representa uma nova forma de pensar, ensinar e aprender em um mundo onde a inteligência artificial já é parte do cotidiano. Integrar essa prática ao processo educacional não é apenas inovar: é garantir que professores e estudantes estejam preparados para atuar com autonomia e responsabilidade em uma sociedade cada vez mais mediada por sistemas inteligentes.














## PROMPTS MULTIMODAIS


### O QUE SÃO PROMPTS MULTIMODAIS



















A interação com sistemas de inteligência artificial costuma ser feita por meio de prompts, ou seja, instruções ou comandos que o usuário envia para que a IA produza uma resposta. Tradicionalmente, esses prompts são textuais, baseados apenas em linguagem escrita — por exemplo: “Explique o que foi a Revolução Francesa em três parágrafos” ou “Gere uma imagem de uma célula animal”. No entanto, com a evolução dos modelos de IA, surgiu um novo tipo de entrada: o prompt multimodal.

Um prompt multimodal combina diferentes tipos de informação no mesmo comando — como texto, imagem, áudio, vídeo e outros — permitindo que a IA compreenda e responda considerando múltiplas formas de entradas. Isso amplia significativamente as possibilidades pedagógicas. Por exemplo, ao subir uma foto de um mapa conceitual feito por um aluno e perguntar “Como posso melhorar a organização desse conteúdo?”, o modelo multimodal analisa a imagem e fornece sugestões textuais. Outro exemplo seria mostrar um vídeo de experimento científico e pedir que a IA explique, por escrito, o fenômeno físico observado.

Tipos de Entrada/Saída	
	: Texto
	: Imagem
<code>&lt;/&gt;</code>	: Código
	: Ferramenta de software
	: Vídeo
	: Música
	: 3D
	: Estado de robô
	: Modalidade biológica

A seguir, apresentamos algumas das possíveis entradas e saídas utilizadas por modelos de inteligência artificial, representadas por ícones. As entradas podem incluir texto () , imagem () , código (`</>`), ferramentas de software () , vídeo () , música () , objetos 3D () , estado de robô () e sinais biológicos () . Diferentemente dos modelos tradicionais baseados apenas em texto, os modelos multimodais são capazes de combinar diferentes tipos de entrada. Por exemplo,  +  →  representa um modelo multimodal que compreende simultaneamente texto e imagem — como no caso de um comando “Descreva o que está representado na imagem”. Já a combinação  →  indica um modelo capaz de transformar uma imagem bidimensional em uma representação tridimensional, permitindo reconstruções 3D a partir de fotos ou desenhos.

Outro exemplo: ao enviar uma imagem () de um gráfico feito à mão e pedir a geração do código correspondente (`</>`) em HTML para reproduzi-lo digitalmente, temos uma combinação

do tipo  +  → `</>`. Em outra situação, um vídeo curto () de um experimento de química pode ser analisado por um modelo que retorna, por texto () a explicação do fenômeno observado:  → . Professores de música podem subir uma gravação de áudio de um aluno () e solicitar que a IA transcreva a melodia ou avalie aspectos técnicos ( → ). Em contextos de robótica educacional, um aluno pode registrar o estado de um robô () e solicitar, com apoio textual () uma recomendação de ajuste no código de movimentação, combinando  +  → `</>`. Por fim, sensores biométricos podem ser usados para enviar sinais fisiológicos () junto com uma descrição textual () permitindo que a IA ofereça um diagnóstico ou análise compatível ( +  → ). Essas possibilidades evidenciam como os modelos multimodais conectam diferentes formatos de informação para gerar soluções educativas mais dinâmicas e integradas. Já imaginou tudo o que você pode fazer em sua sala de aula?

O uso da IA torna-se especialmente relevante no contexto escolar quando se considera sua capacidade de lidar com diferentes tipos de entrada. Professores podem, por exemplo, enviar desenhos feitos pelos alunos, imagens de textos manuscritos, gráficos, quadrinhos ou fotos de atividades, e receber sugestões, correções ou reformulações — o que não seria possível com prompts apenas textuais. Ferramentas de IA já auxiliam na criação e revisão de textos com rapidez e precisão, além de possibilitarem a geração automatizada de planos de aula, questionários, imagens e diagramas. Para integrar essas soluções ao planejamento pedagógico de maneira eficiente e ética, é fundamental compreender como funcionam na prática. A seguir, apresentamos diversas aplicações da IA na sala de aula — da redação de textos à criação de conteúdo visual (imagens, vídeos, apresentações), passando pela personalização da aprendizagem, recursos de acessibilidade, criação de quizzes e apoio à correção de atividades — sempre com exemplos claros e contextualizados.

## EXEMPLOS PRÁTICOS DA IA NA SALA DE AULA

Nesta seção, vamos explorar diferentes formas de integrar a IA ao trabalho docente — de comandos simples em texto até usos mais sofisticados com múltiplas linguagens de entrada e saída.

### Redação e Revisão de Textos

Ferramentas de IA de linguagem, como o Chat GPT, Gemini ou o Escrita Mágica (integrado ao Canva), podem atuar como assistentes virtuais na escrita. Esses sistemas geradores de texto são capazes de produzir redações, sugerir ideias, resumir conteúdos e revisar a gramática de forma rápida e coerente. Por exemplo, um professor pode solicitar: “Resuma os principais pontos da chegada dos portugueses no Brasil em um parágrafo”, ou “Me dê ideias para iniciar uma redação sobre meio ambiente”. Da mesma forma, os alunos podem usar esses assistentes para revisar seus textos – pedindo, por exemplo, “Verifique a gramática e coesão deste texto sobre fotossíntese”. Os sistemas de IA conseguem não apenas apontar erros gramaticais, mas também sugerir melhorias na organização das ideias.

Essa utilização orientada da IA beneficia o desenvolvimento da escrita. Em vez de apenas corrigir o texto, o modelo também pode indicar onde estão os problemas — como trechos pouco claros,

---

argumentação fraca ou falta de coesão — e sugerir formas específicas de aprimorar a redação. Por exemplo, o professor pode instruir: “Avalie este parágrafo argumentativo apontando uma qualidade e uma sugestão de melhoria” para que a IA retorne observações que o docente ou o próprio aluno podem usar para aprimorar o texto.

Outra aplicação prática é a simulação de conversas ou entrevistas por meio da IA. Os sistemas de IA conseguem simular personagens ou especialistas, possibilitando um formato de diálogo. Assim, um professor de história pode pedir que a IA “finja ser um personagem histórico (como Dom Pedro I) respondendo a perguntas dos alunos” – proporcionando uma atividade envolvente de perguntas e respostas. Essa técnica ajuda na compreensão de perspectivas históricas de forma interativa. Já imaginou fazer uma chamada com vídeo para o Cristóvão Colombo? Experimente em [euvou.net/tss9](https://euvou.net/tss9).

Importante salientar que o professor deve integrar essas ferramentas ao planejamento, por exemplo, prevendo momentos em aula para que os alunos utilizem o assistente de escrita com objetivos definidos: primeiro brainstorm de ideias, depois estruturação do texto, revisão final etc. O docente também atua mediando a qualidade das respostas, discutindo com a turma eventuais incorreções ou vieses que a IA possa apresentar. Em suma, a IA na redação de textos serve como um apoio à criatividade e à correção, acelerando etapas mecânicas (como revisão ortográfica) e liberando tempo para o professor focar no conteúdo e no desenvolvimento crítico dos alunos.

Exemplo prático: em uma aula de literatura, o professor solicitou ao sistema de IA uma lista de cinco propostas de redação relacionadas ao livro “Vidas Secas”. A IA gerou sugestões de temas, que o docente refinou e distribuiu à turma. Após os alunos escreverem, eles usaram novamente a IA para obter sugestões de melhoria em seus textos, auxiliando na criação e edição de conteúdo textual, podendo resumir, expandir ou reformular trechos automaticamente. Os alunos, então, incorporaram as sugestões relevantes e discutiram em sala as diferentes abordagens, sempre com o olhar crítico do professor sobre o conteúdo. Essa dinâmica mostra como a IA pode ser incorporada de forma pedagógica, sem substituir a autoria ou o pensamento crítico do estudante, mas sim servindo de apoio para aprimoramento.

### **Geração de Imagens e Recursos Visuais**

A geração de imagens por IA vem revolucionando a forma de criar materiais visuais para a educação. Hoje existem diversas ferramentas – como Meta AI, Chat GPT, Claude, Copilot e outros – que permitem criar imagens a partir de descrições em linguagem natural (prompts). Na prática, isso significa que um professor ou aluno pode digitar algo como “ilustração em estilo de quadrinhos de uma reação química acontecendo” e, em instantes, receber imagens geradas pela IA para usar em slides ou apostilas. O DALL·E, desenvolvido pela OpenAI, é conhecido pela versatilidade e já está até integrado ao Chat GPT, enquanto o Midjourney se destaca pelo realismo das imagens. Ferramentas gratuitas ou freemium, como o Copilot e Meta, também produzem imagens a partir de texto e estão acessíveis para educadores com poucos cliques. Muitas oferecem um plano gratuito limitado por créditos que se renovam periodicamente, possibilitando experimentar sem custos.

As aplicações pedagógicas são inúmeras. Ilustrações geradas por IA servem como poderoso apoio visual, tornando conceitos abstratos mais concretos e estimulando o interesse dos estudantes. Em aulas de história, por exemplo, é possível recriar cenas de períodos históricos: um professor de história do Brasil pode gerar imagens do Rio de Janeiro no século XIX para ambientar a leitura de “Dom Casmurro”, materializando as descrições de Machado de Assis (Sabbatini, 2024). Na literatura, personagens podem ganhar “rostos” segundo as descrições do texto – permitindo que os alunos visualizem figuras como Capitu e Bentinho de forma vívida, o que enriquece a compreensão da obra. Já em aulas de artes, os alunos podem explorar estilos artísticos criando imagens “à la Van Gogh” ou “em estilo mangá” a partir de prompts, comparando os resultados e discutindo elementos de linguagem visual. Até na matemática e nas ciências, diagramas e situações-problema podem ser ilustrados automaticamente: imagine gerar a figura de um sólido geométrico ou a representação de um fenômeno físico para incluir em um material de apoio – tarefas que tradicionalmente demandariam busca de imagens prontas ou desenhos manuais.

Além do professor criar materiais, envolver os alunos na criação de imagens por IA pode ser uma atividade pedagógica valiosa. Ao formular prompts descritivos, os estudantes praticam a descrição precisa e o pensamento criativo. Por exemplo, após estudar ecossistemas, um projeto pode pedir que cada aluno use uma ferramenta de IA para gerar a imagem de um bioma imaginário, descrevendo suas características em detalhes para a IA desenhar. O processo de afinar o prompt (escolhendo palavras que melhor representem sua ideia) estimula o pensamento crítico e a experimentação, pois os alunos analisam os resultados e aprendem a refinar suas instruções para obter a imagem desejada. Essa interação direta com a IA desenvolve a habilidade de comunicação clara e mostra na prática o funcionamento desses modelos.

Convém ressaltar que as imagens geradas devem ser avaliadas pelo professor antes do uso em aula, assegurando que estejam adequadas e corretas em relação ao conteúdo. Às vezes a IA pode produzir detalhes incorretos em temas científicos ou históricos – por isso, a supervisão docente é essencial para validar e, se necessário, ajustar o material visual. No geral, a geração de imagens por IA democratiza a produção de recursos visuais na escola, permitindo que até quem não tenha habilidade em desenho ou orçamento para designers possa obter ilustrações para enriquecer o processo de aprendizagem.

### **Criação de Vídeos Educacionais**

Assim como as imagens, a geração de vídeos por IA tem avançado rapidamente e oferece oportunidades empolgantes para a educação. Ferramentas de IA conseguem transformar texto em vídeos curtos com narração, incluir animações ou mesmo criar avatares virtuais que “falam” o conteúdo programado. Por exemplo, existem plataformas que permitem criar vídeos com avatares digitais que falam em diversos idiomas, a partir de um roteiro fornecido pelo usuário. Isso pode ser útil para o professor preparar uma explicação em vídeo de um tópico da aula: basta inserir o texto (por exemplo, uma explicação de determinado conceito de física) e escolher um avatar para apresentar. Em poucos minutos, gera-se um vídeo com aparência profissional, que pode ser compartilhado com os alunos. É uma forma interessante de diversificar a apresentação de conteúdo, quase como ter um “colega virtual” explicando a matéria.

---

Outra aplicação é a criação de vídeos educacionais para fixação de conteúdo. Ferramentas como Fliki, Lumen5, HeyGen e outras conseguem pegar um texto ou roteiro e gerar automaticamente um vídeo com imagens ilustrativas, legendas e narração. Essas plataformas usam IA para selecionar imagens ou vídeos de banco de dados que combinam com o texto fornecido, sincronizando com uma narração artificial. Um professor de biologia, por exemplo, pode usar um gerador desse tipo para criar um resumo animado sobre fotossíntese: o resultado seria um vídeo de 2-3 minutos combinando explicações escritas e faladas, com fotos de plantas e esquemas aparecendo na hora certa – tudo gerado automaticamente a partir do texto da explicação. Esses vídeos podem ser utilizados em aula ou disponibilizados em uma plataforma online para os alunos revisarem o conteúdo quantas vezes quiserem.

É possível criar videoaulas curtas para introduzir um assunto, produzir seus próprios vídeos explicando um tema, desenvolvendo assim competências de síntese e comunicação. Por exemplo, um professor de geografia poderia desafiar grupos de alunos a usar uma ferramenta de IA para produzir um vídeo de 1 minuto sobre as características de um país, incluindo mapas e dados demográficos. Os estudantes fornecem o texto (revisado pelo professor) e a ferramenta gera o vídeo, que depois será apresentado e discutido em sala. Isso torna a atividade de pesquisa mais atraente e tecnológica.

É importante lembrar que, embora essas plataformas automatizem grande parte do trabalho, o planejamento do roteiro e a curadoria final continuam nas mãos dos estudantes e professores. É necessária a verificação das imagens e se a narração corresponde adequadamente ao conteúdo (evitando eventuais imprecisões da IA) e se o nível da linguagem está apropriado. Com os devidos cuidados, a IA na criação de vídeos se torna um reforço pedagógico valioso, capaz de trazer elementos multimídia modernos para a sala de aula sem exigir do professor habilidades avançadas de edição de vídeo.

### **Criação de Quizzes e Avaliações**

Elaborar questionários, quizzes e testes frequentemente consome bastante tempo dos professores – especialmente ao tentar variar o formato das questões e cobrir diferentes níveis de dificuldade. Nesse aspecto, a IA pode automatizar e acelerar a criação de avaliações. Já existem ferramentas online que, a partir de um tópico indicado, geram bancos de questões variadas para uso imediato. Um exemplo é o Conker.ai, um gerador de questionários movido por IA que cria quizzes personalizados com diferentes tipos de perguntas (múltipla escolha, verdadeiro/falso, dissertativas etc.) em poucos cliques. Um efeito similar também pode ser atingido com os LLMs populares (Gemini, Claude, Chat GPT etc.). Assim, se um professor de matemática deseja um quiz sobre funções quadráticas, ele pode indicar esse tema e obter instantaneamente um conjunto de perguntas, poupando horas que gastaria formulando tudo do zero. A IA automatiza a criação de perguntas e muitas vezes fornece também o gabarito e justificativas, facilitando a correção. Além da agilidade, as ferramentas ajudam a manter coerência com os objetivos de aprendizagem, pois pode calibrar as questões de acordo com níveis de dificuldade ou sub-habilidades desejadas. Isso também é extremamente útil após trabalhar um texto em sala: ao invés de elaborar manualmente as perguntas de compreensão, é

possível usar a IA para propor questões pertinentes e, se necessário, ajustar conforme a necessidade.

O uso de quizzes com IA também favorece a personalização e a prática adaptativa. Como a geração é rápida, o professor pode criar versões diferentes de um mesmo quiz para níveis distintos da turma, ou gerar quizzes extras para alunos que precisam de reforço em determinado tópico. Por exemplo, depois de uma avaliação diagnóstica, separar grupos de alunos conforme as lacunas identificadas e gerar questionários específicos para cada grupo focando nas dificuldades encontradas – tudo isso com pouco esforço graças à automação.

Um exemplo prático de integração no planejamento: digamos que um professor de biologia vá começar um capítulo sobre genética. Antes mesmo da aula expositiva, ele pode gerar um quiz diagnóstico sobre conceitos básicos de genética (ADN, genes, hereditariedade) e aplicá-lo para sondar os conhecimentos prévios dos alunos. Com os resultados, o professor pode identificar quais conceitos merecem mais atenção ou até mesmo pedir para a própria IA analisar os acertos e erros dos alunos (inserindo uma tabela com todas as respostas de todos os alunos). Tudo isso ilustra um pouco como a IA nos quizzes pode ser integrada às atividades escolares para diagnosticar, praticar e avaliar, sempre economizando tempo de preparação e realimentando o planejamento pedagógico com dados do desempenho dos estudantes.

### **Personalização da Aprendizagem**

A personalização da aprendizagem é uma abordagem pedagógica que visa atender às necessidades, interesses e ritmos de aprendizagem individuais dos estudantes. Com o avanço das tecnologias baseadas em Inteligência Artificial (IA), tornou-se possível aplicar essa abordagem de maneira simples e eficaz no cotidiano escolar, utilizando ferramentas gratuitas e acessíveis. Uma das formas mais diretas de realizar essa personalização é por meio da elaboração de *prompts*, que são comandos ou instruções fornecidas aos sistemas de IA generativa, como o Chat GPT, Gemini, Claude ou outras plataformas similares. Existem plataformas pagas, porém vamos tentar atingir nosso objetivo utilizando as ferramentas gratuitas.

Esses sistemas são capazes de interpretar os prompts e gerar respostas que variam de explicações conceituais e resumos a atividades pedagógicas e materiais de apoio. A chave para uma personalização eficaz está na formulação cuidadosa do prompt, que deve conter informações sobre o conteúdo a ser abordado, o perfil do estudante (idade, interesse, estilo de aprendizagem, dificuldades específicas), o objetivo da tarefa e, quando pertinente, o formato desejado da resposta.

Por exemplo, um professor de matemática que deseja explicar o conceito de frações a um aluno do Ensino Fundamental pode utilizar o seguinte prompt:

**"Explique frações para um estudante de 10 anos que gosta de basquete e aprende melhor com exemplos práticos."**

A resposta gerada pela IA poderia ser:

"Imagine que você está assistindo a um jogo de basquete. Cada quarto do jogo tem 12 minutos e o jogo tem 4 quartos. Se você assistiu apenas os dois primeiros quartos, você viu metade da partida, ou seja,  $\frac{2}{4}$  do jogo, que é igual a  $\frac{1}{2}$ . Isso é uma fração. Frações são maneiras de representar partes de um todo."

Nesse caso, a IA utiliza uma linguagem simples, contextualizada e diretamente relacionada aos interesses do aluno, tornando o conceito matemático mais acessível e relevante para ele. Esse tipo de abordagem facilita a compreensão, estimula o engajamento e favorece a construção de significados próprios a partir da experiência do estudante.

Outros exemplos de prompts que podem ser usados para personalização incluem:

- **"Crie uma atividade sobre o ciclo da água para alunos do 6º ano que gostam de desenhar."** Neste caso, a IA pode sugerir uma tarefa como "faça uma história em quadrinhos mostrando como a água evapora, condensa, forma nuvens e chove novamente".
- **"Resuma a Revolução Francesa para estudantes com dificuldade de leitura."** A IA pode responder com um texto mais curto, frases simples e vocabulário acessível.
- **"Gere perguntas de múltipla escolha sobre fotossíntese com opções plausíveis para alunos do 8º ano."** A resposta incluiria questões no formato padrão de avaliação, respeitando o nível cognitivo da turma.

Esses exemplos mostram como é possível diversificar a forma de apresentação dos conteúdos e adaptar os materiais às particularidades dos estudantes. Com o uso consciente de prompts, os professores da educação básica conseguem ampliar o alcance do ensino, oferecendo experiências de aprendizagem mais inclusivas, significativas e eficazes, sem a necessidade de conhecimentos avançados em tecnologia. É uma maneira de tornar a IA uma aliada prática na construção de uma educação mais centrada no estudante.

Tente usar o seguinte prompt em uma ferramenta de IA de sua preferência:

Você é um tutor animado e encorajador que ajuda os alunos a entenderem os conceitos explicando ideias e fazendo perguntas. Comece se apresentando ao aluno como o Tutor-IA, dizendo que está feliz em ajudá-lo com qualquer dúvida. Faça apenas uma pergunta por vez.

Primeiro, pergunte o que ele gostaria de aprender. Espere a resposta. Depois, pergunte sobre o nível de estudo dele: você é estudante de que ano na escola? Espere a resposta.

Em seguida, pergunte o que ele já sabe sobre o tema escolhido. Espere a resposta.

Com base nessas informações, ajude o aluno a entender o conteúdo oferecendo explicações, exemplos e analogias. Tudo deve ser adaptado ao nível de conhecimento e à experiência anterior do aluno. Dê explicações, exemplos e comparações que facilitem a compreensão.

Conduza o aluno de forma aberta. Não ofereça respostas ou soluções diretas aos problemas. Em vez disso, ajude o aluno a chegar às próprias respostas fazendo perguntas que o levem a pensar. Peça que ele explique seu raciocínio.

Se o aluno tiver dificuldade ou errar, peça para ele fazer parte da tarefa, relembre o objetivo e dê uma dica. Se o aluno melhorar, elogie e demonstre entusiasmo. Se ele continuar com dificuldades, seja positivo e ofereça novas ideias para refletir.

Ao estimular o raciocínio, tente sempre terminar suas falas com uma pergunta, para manter o aluno pensando e gerando ideias.

Quando o aluno demonstrar um bom nível de compreensão para seu nível de aprendizado, peça para ele explicar o conceito com as próprias palavras ou dar exemplos. Essa é a melhor forma de demonstrar entendimento. Quando o aluno mostrar que aprendeu o conceito, finalize a conversa dizendo que está disponível para ajudá-lo com outras dúvidas que ele tiver.

Acima, você consegue visualizar um caso ilustrativo de personalização: imagine uma aula de língua inglesa em que os alunos estejam praticando interpretação de texto. Em vez de uma mesma atividade para toda a turma, o professor conta com um assistente virtual chamado Tutor-IA, que interage com cada estudante de maneira individualizada, animada e encorajadora.

Logo no início da interação, o Tutor-IA se apresenta ao aluno, dizendo estar feliz em poder ajudar, e faz sua primeira pergunta: "O que você gostaria de aprender hoje?". Depois que o aluno responde, ele pergunta: "Você é estudante de que ano na escola?". Em seguida, ele busca entender o que o aluno já sabe sobre o tema escolhido. Com base nessas três informações iniciais, o Tutor-IA seleciona ou adapta o material de leitura conforme o nível de proficiência do estudante, garantindo um percurso adaptado ao seu conhecimento e estilo de aprendizagem.

Em casa ou durante a aula no laboratório de informática, cada aluno interage com o Tutor-IA em seu próprio ritmo. Alunos com mais dificuldade recebem textos mais curtos, com vocabulário simples, e são conduzidos por perguntas de compreensão formuladas uma a uma. O tutor virtual nunca entrega a resposta direta: ele faz perguntas que ajudam o estudante a pensar, refletir e explicar seu raciocínio, elogiando o esforço e sugerindo novas ideias sempre que necessário.

Para estudantes mais avançados, os textos já começam com maior complexidade, e o Tutor-IA pode propor tarefas de escrita ou questões inferenciais. Se o aluno errar, ele é incentivado a tentar novamente com o apoio de dicas e lembrando o objetivo. Quando demonstra compreensão adequada, o Tutor-IA pede para o aluno explicar com suas próprias palavras, validando seu entendimento e mostrando que está pronto para avançar. No final, todos os estudantes têm praticado a interpretação de textos, mas cada um percorreu um caminho adaptado às suas necessidades e ritmos, com o Tutor-IA atuando como mediador ativo do aprendizado.

Esse exemplo mostra como a IA, quando orientada por uma abordagem humanizada e responsiva, pode potencializar a personalização do ensino e favorecer o desenvolvimento de habilidades cognitivas por meio do diálogo e da reflexão.

---

## Acessibilidade e Inclusão Educacional

Tornar a sala de aula inclusiva para alunos com diferentes necessidades é um desafio que a tecnologia pode ajudar a atender. A IA oferece diversas soluções para ampliar a acessibilidade, garantindo que estudantes com deficiências ou dificuldades específicas possam participar plenamente das atividades educacionais. Um exemplo simples é o recurso de leitura de texto em voz alta (text-to-speech): hoje, com IA, aplicativos e softwares conseguem ler textos escritos com entonação natural em diversos idiomas. Isso permite que alunos com deficiência visual ou dislexia acompanhem materiais escritos ouvindo o conteúdo. O professor pode disponibilizar artigos, atividades ou livros digitais e orientar esses alunos a utilizarem leitores de tela inteligentes que descrevem não só o texto, mas também imagens (quando há descrição embutida) e fórmulas.

No sentido inverso, há a transcrição automática de fala em texto (speech-to-text), que é extremamente útil para alunos com deficiência auditiva. Ferramentas como o Google Live Transcribe (Transcrição Instantânea) captam em tempo real o áudio ambiente – por exemplo, a explicação oral do professor – e exibem legendas na tela do celular do aluno. Assim, um estudante surdo ou com audição reduzida consegue ler no seu dispositivo exatamente o que está sendo falado em aula, quase simultaneamente. Esse tipo de recurso torna as aulas expositivas e discussões muito mais acessíveis. Em aulas online ou videoaulas gravadas, a geração automática de legendas pela IA (como a disponível no YouTube ou em plataformas de videoconferência) também beneficia não só quem tem deficiência auditiva, mas todos os alunos que possam querer acompanhar o conteúdo por escrito ou não tenham condições de ouvir som em certos momentos.

Outra frente importante é a tradução e interpretação para Língua de Sinais. No Brasil, por exemplo, temos aplicativos como o Hand Talk, que utiliza inteligência artificial para converter texto e voz do português para Libras (Língua Brasileira de Sinais) por meio de um avatar virtual animado. Em contexto escolar, o professor pode digitar no app o conteúdo principal de uma explicação ou os enunciados de uma atividade, e o avatar (geralmente o personagem de mãos que faz sinais) apresenta em Libras para alunos surdos sinalizantes. Isso não substitui a necessidade de um intérprete humano em muitos casos, mas é um apoio valioso para momentos em que o intérprete não está presente ou para materiais complementares em Libras.

A IA também contribui com a tradução automática de idiomas, o que é uma forma de acessibilidade para estudantes imigrantes ou de comunidades indígenas, por exemplo. Com tradutores baseados em IA é possível traduzir quase instantaneamente um texto ou mesmo a legenda de um vídeo/aula para outro idioma. Se uma escola recebe um aluno estrangeiro que ainda não domina o português, ferramentas de tradução em tempo real podem ajudá-lo a acompanhar parte das aulas enquanto aprende a língua local. Há casos de uso de fones e aplicativos inteligentes que captam a voz do professor e entregam uma tradução quase simultânea para o aluno em outro idioma. Embora haja limites de precisão, esse suporte tecnológico diminui barreiras linguísticas, promovendo inclusão.

Para alunos com deficiência visual, além dos leitores de tela citados, existe IA de visão computacional que descreve o ambiente e conteúdos visuais. Os aplicativos Seeing AI (Microsoft) ou o OOrun, por exemplo, permitem que ao apontar a câmera do celular para um objeto ou texto, a IA descreva em voz alta o que está vendo. Isso pode ser demonstrado em classe para tornar materiais impressos acessíveis: um aluno cego pode usar o app para ler autonomamente um trecho de um livro didático (a IA reconhece o texto impresso e o lê) ou até para obter uma descrição de uma figura ou diagrama (o app pode dizer: “imagem de um mapa do Brasil mostrando regiões climáticas”). Embora nem sempre detalhada, essa descrição já fornece informações importantes que de outra forma exigiriam um transcritor humano.

Como se pode perceber, a IA se mostra uma grande aliada para a acessibilidade educacional ao oferecer múltiplos formatos de acesso ao conteúdo e suporte personalizado para alunos com diferentes necessidades. Isso contribui para uma educação verdadeiramente inclusiva, na qual a diversidade de aprendizes é acolhida com recursos que eliminam, ou ao menos minimizam, barreiras. Para integrar isso no dia a dia, os professores podem mapear as necessidades de seus alunos (seja deficiência física, auditiva, visual, distúrbios de aprendizagem, diferenças linguísticas) e então buscar quais ferramentas de IA atendem a cada caso – muitas vezes com soluções gratuitas ou já disponíveis em dispositivos comuns. O importante é também envolver os alunos nesse processo, ensinando-os a utilizar essas tecnologias assistivas e encorajando a autonomia: por exemplo, ensinar todos os alunos a ativar legendas automáticas, a usar leitores de texto em voz alta, a conhecer ferramentas de tradução, de modo que toda a turma se beneficie e colabore para um ambiente inclusivo.

### **Apoio à Correção e Feedback com IA**

Corrigir provas, redações e trabalhos consome uma parte significativa do tempo de um professor. A inteligência artificial pode aliviar essa carga ao **auxiliar na correção automática ou semiautomática de atividades**, bem como na geração de feedbacks personalizados aos alunos. Já existem sistemas de correção de testes objetivos (como scanners para gabaritos de múltipla escolha) há décadas, mas a IA expande isso para itens dissertativos e avaliações mais complexas.

Por exemplo, modelos de linguagem como o Chat GPT podem ser usados para avaliar um texto segundo critérios pré-definidos. Um professor pode instruir a IA com um comando detalhado, fornecendo a ela a rubrica de correção. Imaginemos uma situação em que o docente insere: *“Este é um texto argumentativo do aluno. Avalie de 0 a 5 em cada um dos seguintes critérios: abordagem do tema, coesão e coerência, gramática e vocabulário. Em seguida, forneça um breve feedback para cada critério.”* A IA, a partir dessas instruções, consegue analisar o texto e retornar algo como: *“Tema: 4 – O aluno desenvolveu bem a tese, mas faltou aprofundar um dos argumentos; Coesão: 3 – Há algumas repetições e uma transição brusca no terceiro parágrafo; Gramática: 5 – Texto praticamente sem erros gramaticais, bom domínio do padrão culto. Feedback: O aluno apresentou uma argumentação consistente, porém poderia adicionar um exemplo concreto para fortalecer a ideia central. Organize melhor as ideias no último parágrafo para melhorar a clareza. Parabéns pelo uso adequado da gramática.”* Esse tipo de feedback automatizado pode

---

economizar tempo na primeira leitura de dezenas de redações, dando ao professor um rascunho de avaliação já estruturado.

Estudos e experiências mostram que, quando calibrada corretamente, a IA pode identificar aspectos de uma redação semelhantes aos observados por um corretor humano. Um exemplo disso é que, ao ser alimentada com os critérios de correção do ENEM (Exame Nacional do Ensino Médio), a IA consegue simular a avaliação seguindo esses parâmetros e atribuir uma pontuação aproximada, indicando os pontos fortes e fracos conforme a cartilha oficial. É claro que ainda há um longo caminho até que se possa confiar 100% em uma máquina para atribuir a nota final, mas, como assistente de correção, a IA já se mostra bastante útil, tanto para o professor, quanto para o estudante. Claro, ainda dependemos da experiência e dos olhos aguçados e afiados do professor.

É válido mencionar também a existência de ferramentas de detecção de conteúdo gerado por IA, uma preocupação crescente nas escolas. Se por um lado incentivamos os alunos a usarem IA de forma ética (como para revisar seu texto, e não simplesmente entregar algo escrito integralmente pela máquina), por outro os professores podem querer verificar autenticidade de produções. Existem detectores como o *GPTZero*, *ZeroGPT* e o da própria OpenAI, que analisam um texto e indicam a probabilidade de ter sido escrito por IA. No entanto, tais ferramentas ainda não são plenamente confiáveis – em testes, um detector acusou pouca certeza, que tinha sido escrito por um humano. Além disso, já há ferramentas que “traduzem” o texto de IA para um estilo mais humano, escapando desses detectores. Ou seja, na prática, a melhor abordagem é pedagógica: deixar claras as regras de uso da IA nas atividades e criar tarefas que valorizem mais o processo do que apenas o produto final. A IA enquanto apoio à correção deve ser vista como um meio de qualificar o retorno dado ao aluno e poupar tempo em tarefas burocráticas, mas sempre com validação do professor.

Integrar a IA na correção significa mais velocidade e dados ricos para o professor e feedback imediato e orientador para o estudante. No planejamento, o docente pode prever momentos em que os alunos recebem devolutivas automatizadas (por exemplo, em exercícios realizados em plataformas digitais) e momentos em que haverá feedback humano mais aprofundado. Essa combinação tende a otimizar o aprendizado: o aluno não espera dias para saber se está no caminho certo, e o professor foca sua energia onde é mais necessário, interpretando resultados e planejando as próximas estratégias de ensino com base nas evidências coletadas pela IA.

### **Geração de Apresentações e Slides**

Preparar apresentações de slides atrativas e didáticas demanda tempo – pensar no design, procurar imagens, escrever textos concisos. Ferramentas de design com IA podem **automatizar grande parte desse processo de criação de slides**, permitindo que professores gerem apresentações inteiras em poucos minutos. Nessas ferramentas, o professor informa o **tópico da apresentação, o tom (por exemplo: formal, divertido), o idioma, o número de slides desejado e o estilo visual** – e então a IA gera uma sequência de slides coerentes com textos e imagens sugeridos. Em questão de segundos, temos uma apresentação pronta, que pode ser baixada para PowerPoint, Google Slides ou editada no próprio Canva. Todos os slides já vêm

preenchidos com conteúdo textual relativo ao tema e elementos gráficos correspondentes, e cabe ao professor ou estudante revisar e eventualmente editar algum detalhe. Mesmo esse uso esporádico já poupa um tempo considerável quando se precisa de uma apresentação base.

Outra plataforma muito útil é o próprio Canva, que além de templates prontos, oferece o recurso “*Design Mágico*” e o já citado “*Texto Mágico*”. Com o Design Mágico, o usuário pode inserir o tema ou mesmo um esboço de conteúdo, e o Canva sugere layouts e distribui automaticamente o texto em slides esteticamente equilibrados. Combinado ao “*Texto Mágico*” (que gera texto), é possível em tese colocar um assunto e deixar a IA do Canva tanto escrever os tópicos de cada slide quanto escolher imagens de banco e design gráfico para eles. Por exemplo, um professor de química pode digitar: “*Quero uma apresentação sobre Tabela Periódica, 5 slides, visual jovem e colorido*”. O Canva então pode gerar um conjunto inicial de slides com títulos como “O que é a Tabela Periódica?”, “Grupos e Períodos”, “Metais vs Ametais” etc., cada um com algum ícone ou imagem de fundo temática. Uma vez gerada essa base, o professor ajusta informações específicas, insere exemplos que queira destacar e pronto – reduz significativamente o trabalho braçal de formatar slides.

Ferramentas de apresentações com IA ajudam também na padronização visual e na inclusão de elementos gráficos que talvez o professor não tivesse tempo de procurar. Elas podem inserir ícones, gráficos e fotos contextualizadas automaticamente. Isso é particularmente útil para quem não tem muita familiaridade com design: a IA garante uma estética minimamente profissional, evitando apresentações poluídas ou pouco atraentes.

No planejamento pedagógico, **integrar a IA na criação de slides** pode liberar o professor para se concentrar mais no roteiro e na estratégia da aula do que no design em si. Por exemplo, ao planejar uma aula, o docente pode primeiro definir a sequência lógica do conteúdo (os tópicos de cada slide) e então usar a ferramenta de IA para materializar isso visualmente. Depois, com a apresentação gerada, ele revisa e adiciona perguntas para discussão, ou destaca com animações pontos chave – ajustes finais que dão o toque humano e pedagógico necessário. Essa agilidade também permite atualizar materiais de um ano para outro com facilidade. Se surge uma nova informação ou estatística importante sobre o tema, basta pedir à IA que gere um novo slide ou atualize aquele conteúdo específico, mantendo o estilo uniforme.

Vale notar que algumas plataformas de slides com IA já oferecem **integração com assistentes virtuais**. A Microsoft, por exemplo, anunciou o **Copilot para PowerPoint**, que permitirá ao usuário pedir em linguagem natural algo como “*Crie uma apresentação de 10 slides sobre os impactos das mudanças climáticas na agricultura, com base nesses dados em anexo*”, e ele gerará os slides relevantes.

Como se pode ver, a IA na geração de apresentações **umenta a produtividade e a qualidade visual dos materiais**. Os professores e estudantes podem adotar esses recursos para **produzir rapidamente slides envolventes**, seja para aulas expositivas, seminários escolares ou apresentações de projetos. Como melhor prática, recomenda-se sempre ler cuidadosamente e adaptar o conteúdo gerado – evitando informações imprecisas ou um tom que não combine

---

com a turma –, mas aproveitando ao máximo a economia de tempo e o leque criativo que a IA proporciona.

### **Produção de Materiais Didáticos**

A criação de materiais didáticos abrange não apenas apresentações, mas também **planos de aula, atividades, exercícios, resumos, jogos educativos, estudos de caso** e muito mais. Com a IA, os professores podem ter um verdadeiro “coautor” ao seu lado na elaboração desses materiais. Há plataformas especificamente voltadas para isso, onde é possível gerar: plano de aula completo, conjunto de questões de discussão sobre um texto, resumo de livro, ideias de projetos, ou até uma lista de *recomendações pedagógicas* para estudantes com necessidades especiais. Tudo isso com alguns cliques, indicando o tema e o público-alvo. A IA então produz um material-base que serve de ponto de partida.

Por exemplo, suponha que um professor de História queira elaborar um plano de aula sobre a Revolução Industrial para uma turma do 2º ano do Ensino Médio. Utilizando uma ferramenta de IA, ele pode solicitar a geração do plano na plataforma de sua preferência, informando o tópico (Revolução Industrial), o nível escolar (2º ano do Ensino Médio) e a duração (duas aulas), com o objetivo de compreender as causas e consequências socioeconômicas do processo. Com isso, a IA entrega uma sugestão estruturada, incluindo objetivos específicos (ex.: “identificar os fatores que levaram à Revolução Industrial na Inglaterra”), conteúdos (ex.: “invenções tecnológicas, mudanças na estrutura de trabalho, impacto na vida urbana”), metodologia (ex.: “exibição de vídeo curto, debate em grupo, análise de fontes históricas”) e, possivelmente, uma ideia de atividade prática (ex.: “simulação de linha de montagem em sala, para vivenciar a divisão do trabalho”). Esse esqueleto de plano de aula gerado pela IA economiza tempo de planejamento. O professor, naturalmente, adapta o material conforme seu contexto — pode trocar a atividade sugerida, ajustar a duração das etapas ou incluir uma avaliação ao final. Ainda assim, a IA já oferece uma base organizada e coerente.

Vamos experimentar? Experimente executar o prompt a seguir:

Você é um pedagogo responsável pela criação de plano de aula para a Educação Básica. O professor deve responder somente as seguintes 7 perguntas: o título da aula (opcional), o ano ou série dos alunos, a área do conhecimento ou componente curricular (sugira uma área baseada no título), tempo estimado da aula (em minutos ou número de aulas), os objetivos de aprendizagem (indicando o que se espera que os alunos compreendam ou consigam fazer ao final da aula), se há necessidade de adaptações para inclusão e, por fim, se há uma informação ou detalhe adicional que o professor queira informar.

O plano deve ser gerado de forma clara, prática, objetiva e deve incluir: os recursos ou materiais necessários (caso haja), conteúdos que serão trabalhados, a metodologia ou estratégias de ensino que serão utilizadas, a descrição das atividades propostas com o passo a passo do que os alunos farão, os critérios e formas de avaliação da aprendizagem, as adaptações para inclusão (caso haja alunos com deficiência ou outras necessidades específicas) e as referências utilizadas (como livros, sites ou recursos

educacionais abertos). Não liste as habilidades da BNCC. Faça apenas uma pergunta por vez ao professor, aguardando a resposta antes de seguir para o próximo item. Quando acabar, pergunte se é para gerar uma lista de exercícios.

Além de planos de aula, a IA pode auxiliar na produção de folhas de exercícios, estudos de caso, experimentos simulados e na redação de apostilas ou materiais complementares. Por exemplo, se um professor de Física quiser elaborar uma lista de problemas sobre lançamento de projéteis, pode solicitar à IA: 'Gerar 5 problemas de Física sobre lançamento oblíquo, com níveis de dificuldade progressivos, incluindo as respostas'. Em poucos segundos, terá os problemas propostos. É claro que será necessário revisar se os valores e respostas fazem sentido — afinal, a IA pode cometer erros de cálculo —, mas o principal do trabalho criativo e de redação já foi agilizado. Com base nessas sugestões, o professor pode corrigir algum valor, adaptar a linguagem ao perfil da turma (tornando-a mais formal ou mais descontraída) e, assim, personalizar o material para seus alunos.

A IA também se mostra útil na busca ou geração de textos adequados ao nível dos estudantes. Suponha que um professor de Biologia queira um texto introdutório sobre biotecnologia voltado ao Ensino Médio — a IA pode buscar na internet um artigo apropriado ou simplificar um texto acadêmico, ajustando o vocabulário. Há recursos que permitem filtrar por nível de leitura e idioma, o que facilita a obtenção de materiais complementares sob medida para a turma. Isso economiza o tempo que seria gasto procurando e adaptando textos manualmente. Depois, o professor ainda pode gerar perguntas de compreensão ou um quiz sobre o conteúdo, formando um pacote completo de material didático para a aula.

Outra possibilidade interessante é a ferramenta NotebookLM, desenvolvida pelo Google, permite organizar e explorar conteúdos com o apoio de IA generativa, funcionando como um caderno inteligente que interpreta e resume documentos enviados pelo usuário. Uma aplicação interessante para a educação é a geração de arquivos de áudio no formato de podcast a partir desses conteúdos. O professor pode reunir textos, apostilas ou resumos no NotebookLM, solicitar à IA a criação de roteiros em linguagem oral e, em seguida, converter esses roteiros em áudio com o uso de ferramentas complementares de síntese de voz. O resultado é um podcast personalizado, que pode ser usado para revisão de conteúdos, acessibilidade ou como recurso complementar para alunos que preferem aprender ouvindo.

A IA também pode ser utilizada para gerar textos exemplo que funcionam como referência ou meta a ser superada pelos estudantes. Ao solicitar à ferramenta a produção de uma redação, resposta discursiva ou argumento bem estruturado sobre determinado tema, o professor oferece aos alunos um modelo concreto de qualidade, com coesão, clareza e domínio do conteúdo. Esse texto não deve ser copiado, mas serve como parâmetro para orientar a produção dos estudantes, desafiando-os a elaborar algo ainda melhor. Essa estratégia estimula a autocrítica, o aprimoramento da escrita e o desenvolvimento da autonomia intelectual.

Outra estratégia pedagógica eficaz é utilizar a IA para gerar textos com erros intencionais — seja de conteúdo, argumentação, gramática ou estrutura — com o objetivo de que os estudantes identifiquem e corrijam essas falhas. Essa atividade estimula a leitura crítica, o raciocínio

---

analítico e a aplicação ativa dos conhecimentos adquiridos. Ao confrontar um trabalho com problemas deliberados, os alunos são levados a justificar suas correções, reforçando sua compreensão sobre o tema e demonstrando domínio sobre os critérios de qualidade esperados. Além disso, essa prática promove o desenvolvimento da autonomia e da responsabilidade intelectual diante das produções automatizadas.

Uma possibilidade interessante é o uso da IA para criar materiais inovadores, como histórias ou simulações. Por exemplo, um professor de Literatura pode solicitar que a IA escreva uma história curta e inédita, envolvendo determinados personagens ou estilos, para ser usada em sala como leitura e análise. Já um professor de Língua Estrangeira pode gerar diálogos em espanhol contextualizados no cotidiano dos alunos (escola, amigos, redes sociais), visando à prática de interpretação. Essas criações personalizadas tornam o conteúdo mais próximo da realidade dos estudantes, aumentando seu engajamento.

No que se refere à integração com o planejamento pedagógico, a IA pode atuar como assistente em todas as etapas: na concepção (sugerindo ideias, abordagens, exemplos e projetos), no desenvolvimento (elaboração de planos, slides, exercícios) e até na execução (disponibilizando recursos como quizzes online ou adaptando atividades em tempo real diante de imprevistos). O mais relevante é que o professor enxergue essas ferramentas como parceiras na criação. Isso traduz bem a ideia de coautoria: professor e IA construindo juntos, mas sempre com o docente no comando — garantindo o alinhamento com os objetivos educacionais, a adequação ao perfil da turma e a correção de eventuais falhas da máquina.

### **Outras Aplicações Práticas e Considerações Finais**

Além das áreas já destacadas, existem outras aplicações de IA no ambiente educacional que os professores podem explorar. Uma delas é o uso de chatbots para comunicação e gestão. Por exemplo, secretarias escolares ou mesmo professores podem implementar chatbots (via WhatsApp ou sites) para responder dúvidas frequentes de alunos e pais – coisas como horário de aula, data de prova, conteúdo da última aula, procedimento de matrícula, etc. Esses bots usam processamento de linguagem natural para entender as perguntas e respondê-las adequadamente, descongestionando a carga de perguntas repetitivas que recai sobre os educadores. Em sala de aula, um professor que se sinta confortável em executar o projeto poderia, inclusive, engajar alunos em um projeto de criar um chatbot tutor para alguma matéria, treinando-o com conteúdo do curso. Ferramentas de IA permitem treinar modelos com dados específicos (um processo um pouco mais técnico, mas possível) para atuar em domínios delimitados.

Outra frente em crescimento é a da análise de sentimentos e bem-estar dos alunos. Embora delicado, já se vislumbra o uso de IA para analisar, por exemplo, textos escritos pelos alunos em fóruns ou até expressões faciais em videochamadas, a fim de identificar sinais de desengajamento, desmotivação ou mesmo problemas emocionais. Existe também a possibilidade de, com técnicas de análise de sentimento em postagens de redes sociais de alunos ou até mesmo em produções escolares, detectar se um estudante tem apresentado padrões de escrita associados à tristeza ou isolamento, o que poderia disparar um alerta à

equipe pedagógica. Evidentemente, isso requer cuidado ético e privacidade, mas ilustra como a IA pode auxiliar na dimensão de acompanhamento sócio emocional, servindo como mais um subsídio (e não diagnóstico) para intervenções da escola.

Em termos de eficiência administrativa, a IA pode ajudar a otimizar horários, agendas e comunicações. Um diretor de escola ou coordenador pode usar ferramentas que, a partir de restrições e preferências, montam automaticamente horários de aulas ou alocação de turmas, tarefas tradicionalmente complexas. Ou ainda, um professor pode pedir ajuda para redigir comunicados e e-mails: por exemplo, "Escrever uma carta aos pais informando sobre a visita ao museu", e a IA entrega um rascunho. Depois de uma revisão, o comunicado está pronto para envio. Esses ganhos de tempo liberam os educadores para focar no que realmente importa: o relacionamento com os alunos e a qualidade das experiências de aprendizagem.

Diante de tantas possibilidades, é natural que surjam dúvidas e cautela. Uma consideração final importante é a **formação ética e crítica** de todos os envolvidos – professores e alunos – no uso dessas ferramentas. Os educadores precisam compreender o funcionamento básico da IA, seus pontos fortes e também limitações e vieses. Esse entendimento é fundamental para usar a tecnologia de forma responsável: sabendo que a IA pode fornecer respostas erradas ou tendenciosas, o professor e o estudante sempre validam a informação antes de repassá-la; sabendo que pode haver problemas de privacidade, evita inserir dados sensíveis de alunos nas plataformas; sabendo que a IA pode facilitar "atalhos" pouco educativos (como fazer todo o trabalho pelo aluno), cria estratégias para valorizar o processo de aprendizagem e a autoria real.

Por fim, é alentador notar que a IA, longe de ameaçar o papel do professor, **vem sendo vista como aliada estratégica na educação**. Gestores e professores que já adotam essas ferramentas ganham tempo, otimizam processos internos e inovam nas práticas de ensino. Há, sim, desafios – desde a necessidade de infraestrutura e acesso, até a elaboração de políticas claras de uso – mas o caminho se faz caminhando. A recomendação prática para o professor do ensino médio que deseja começar é: **comece aos poucos, escolha uma ou duas ferramentas e teste em atividades simples**. Pode ser gerar duas questões de prova com IA, ou usar para gerar ideias de dinâmica em sala. Aos poucos, com a experiência, o docente ganha confiança e vai incorporando novos recursos ao seu repertório, sempre avaliando os resultados pedagógicos.

A IA aplicada à educação abre um leque de oportunidades para tornar o ensino mais eficiente, personalizado e inclusivo. Integrar IA ao planejamento pedagógico significa **ganhar um assistente versátil** – que ajuda a planejar, preparar materiais, engajar os alunos e até acompanhar o progresso deles – enquanto o professor permanece no centro, como mentor insubstituível que dá sentido, afeto e direção a todo esse processo. Com abordagem direta, instrutiva e prática, como buscou ser o conteúdo deste capítulo, esperamos que mais educadores sintam-se preparados para explorar essas ferramentas de IA na sala de aula e, com isso, potencializar a aprendizagem de seus alunos para os desafios do século XXI.

# MÓDULO 6

## IA PARA ACESSIBILIDADE

### **Objetivo do Módulo:**

Ao final do módulo os professores participantes deverão conhecer alguns usos e aplicações da IA para a acessibilidade.

### **Contempla:**

Aula 14 - Inteligência Artificial para Acessibilidade

Aula 15 - Inteligência Artificial para a Acessibilidade na Aprendizagem

## INTELIGÊNCIA ARTIFICIAL PARA ACESSIBILIDADE

A Inteligência Artificial (IA) está transformando a maneira como as pessoas se relacionam com a tecnologia e com o mundo ao seu redor. Quando aliada aos princípios da acessibilidade, essa tecnologia oferece oportunidades significativas para ampliar a inclusão social de pessoas com deficiência, promovendo autonomia, comunicação e participação cidadã.

Entre os principais conceitos que os estudantes devem compreender estão os **sensores**, os **classificadores**, os **neurônios artificiais** e as **redes neurais artificiais**. Sensores são dispositivos capazes de captar informações do ambiente, como som, luz ou movimento, transformando-as em dados para serem processados por sistemas de IA. Esses dados alimentam algoritmos capazes de identificar padrões e fazer previsões, é o caso dos classificadores, que ajudam, por exemplo, a diferenciar expressões faciais ou interpretar comandos de voz.

As **redes neurais artificiais** simulam o funcionamento do cérebro humano por meio de conexões entre neurônios artificiais. Elas são amplamente utilizadas em sistemas que aprendem com grandes volumes de dados, como leitores de tela que identificam objetos em imagens, ou assistentes virtuais que reconhecem comandos por voz. Esses recursos já fazem parte do cotidiano de muitas pessoas com deficiência visual, auditiva ou motora, melhorando o acesso à informação e à comunicação.

### Tecnologia Assistiva

No Brasil trabalhamos com dois conceitos de Tecnologia Assistiva (TA): Lei nº 13.146/2015, conhecida como Lei Brasileira da Inclusão (LBI); e Comitê de Ajudas Técnicas (CAT) da Secretaria Especial de Direitos Humanos (SEDH).

Na Lei Brasileira da Inclusão (LBI) a Tecnologia Assistiva ou ajuda técnica são **produtos, equipamentos, dispositivos, recursos, metodologias, estratégias, práticas e serviços** que objetivem promover a funcionalidade, relacionada à atividade e à participação da **pessoa com deficiência ou com mobilidade reduzida**, visando à sua autonomia, independência, qualidade de vida e inclusão social.

O conceito de TA no Comitê de Ajudas Técnicas (CAT) indica uma área de conhecimento multidisciplinar que abrange **produtos, recursos, estratégias, práticas, processos, métodos e serviços** destinados às **pessoas com deficiência, mobilidade reduzida e idosos** para promover a autonomia, qualidade de vida e inclusão social em diferentes espaços sociais.

Tecnologias pensadas para superar limitações que poderiam impedir uma pessoa com deficiência de ter uma vida **autônoma, plena e socialmente ativa**.

O termo "**pessoas com deficiência**" está fundamentado no modelo social da deficiência, o qual não se restringe a aspectos biológicos ou médicos da condição. Esse modelo compreende a deficiência como resultado da interação entre as características individuais da pessoa e as

barreiras – físicas, comunicacionais, atitudinais e sociais – que dificultam ou impedem sua plena participação na sociedade. Assim, desloca-se o foco do indivíduo para o contexto, reconhecendo que a limitação está, muitas vezes, nas estruturas e atitudes sociais, e não exclusivamente na condição da pessoa.

Temos dois grupos principais: os **recursos** de TA e os **serviços** de TA.

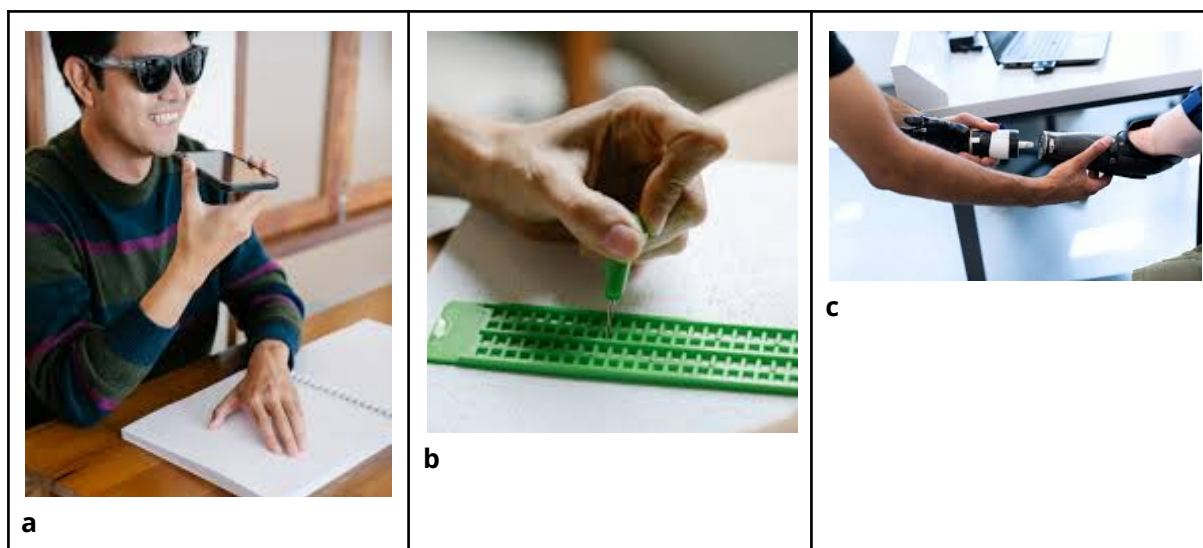
**Recurso** - um objeto, um programa de computador ou de celular, um acessório ou um dispositivo.


Os **recursos de Tecnologia Assistiva** podem ser classificados de acordo com suas **funcionalidades**, às **necessidades que atendem** e os **propósitos** para os quais foram concebidos.

Propostas de classificação para os recursos de TA:

- o norma ISO 9999:2016
- o a classificação HEART adotada pelos países da União Europeia
- o o Sistema Nacional de Classificação dos Recursos e Serviços de TA utilizado nos Estados Unidos
- o **no Brasil a classificação elaborada por José Tonolli e Rita Bersch**

Tonolli e Bersch adaptam essa estrutura ao **contexto brasileiro**, considerando as **realidades socioculturais, legais e educacionais** do país. Eles complementam a norma com exemplos contextualizados, usos pedagógicos, e categorias que facilitam sua aplicação em ambientes escolares e sociais no Brasil.





a) App transcrever áudio e texto; b) Reglete; c) Prótese; d) Vacalizador para CAA; e) Tradutor de Libras; f) Fixação de pincel

**Serviço** - avaliação das necessidades da pessoa com deficiência; avaliação funcional do ambiente(s); desenvolvimento, seleção ou aquisição de recursos; customização, adaptação, experimentação e aplicação de recursos.



A **Lei Brasileira de Inclusão (LBI), de 2015**, traz, em seu Capítulo IV - **Do Direito à Educação**, no Art. 28, que incumbe ao poder público assegurar, criar, desenvolver, implementar, incentivar, acompanhar e avaliar:

VI - pesquisas voltadas para o desenvolvimento de novos métodos e técnicas pedagógicas, de materiais didáticos, de equipamentos e de recursos de tecnologia assistiva;

VII - planejamento de estudo de caso, de elaboração de plano de atendimento educacional especializado, de organização de recursos e serviços de acessibilidade e de disponibilização e usabilidade pedagógica de recursos de tecnologia assistiva;

(...) XII - oferta de ensino da Libras, do Sistema Braille e de uso de recursos de tecnologia assistiva, de forma a ampliar habilidades funcionais dos estudantes, promovendo sua autonomia e participação.

---

Exemplos de Tecnologia Assistiva que utilizam IA incluem o comando por voz, descrição de imagens, transcrever falas e textos, comunicação alternativa e reconhecimento facial com leitura emocional. Essas ferramentas foram projetadas com base em princípios de **usabilidade** e **acessibilidade**, que significam, respectivamente, a facilidade de uso por qualquer pessoa, e a capacidade do recurso de atender às necessidades específicas de usuários com deficiência.

A **usabilidade** pode ser avaliada por critérios como eficiência, efetividade, satisfação do usuário e aprendizado. Já a **acessibilidade** deve considerar se os recursos permitem o acesso universal, respeitam o **Desenho Universal** e reduzem barreiras de comunicação, físicas e tecnológicas.

O **Desenho Universal** envolve concepção de produtos, ambientes, programas e serviços a serem usados por todas as pessoas, sem necessidade de adaptação ou de projeto específico, incluindo os recursos de tecnologia assistiva;

Conforme a **Lei Brasileira de Inclusão da Pessoa com Deficiência (LBI)**, é dever do poder público e da sociedade garantir condições de acessibilidade, desde o planejamento urbano até os recursos de comunicação e educação. A lei reconhece a Tecnologia Assistiva como um direito que promove autonomia e cidadania.

Diversos softwares e dispositivos vêm sendo desenvolvidos com apoio de IA para tornar a comunicação e o acesso à informação mais eficazes. Entre os exemplos, destacam-se:

## Leitura e Reconhecimento de Texto

Essas ferramentas são especialmente úteis para pessoas com deficiência visual, dislexia ou com dificuldades na leitura:

**Seeing AI** (Microsoft): lê textos em voz alta, reconhece rostos, identifica produtos e descreve cenas para pessoas com deficiência visual. Utiliza inteligência artificial de visão computacional. Gratuito (iOS e via APK para Android).

**Envision AI**: reconhece e lê textos, identifica objetos e descreve imagens. Compatível com óculos inteligentes. Gratuito com limitações (Android e iOS).

**Google Lookout**: utiliza IA embarcada para reconhecer textos, objetos, pessoas, rótulos e dinheiro. Muito eficaz para pessoas cegas ou com baixa visão. Gratuito (Android).

**OrCam MyEye**: dispositivo acoplado a óculos, com IA offline, que lê texto, reconhece rostos e produtos. É pago e independente de plataformas móveis.

**Voice Aloud Reader**: transforma textos em fala, útil para leitura de sites, e-mails e documentos. Utiliza síntese de voz (pode ser com IA, dependendo da engine). Gratuito (Android).

**Read Aloud** e **SpeakIt**: leitores de texto que usam IA quando integrados a serviços de voz neural, como Google TTS.

**EasyReader** e **BeeLine Reader**: extensões e aplicativos que melhoram a legibilidade para pessoas com dislexia ou TEA, mas não utilizam IA diretamente.

## Comunicação Aumentativa e Alternativa (CAA)

A **Comunicação Aumentativa e Alternativa** ou simplesmente Comunicação Alternativa é voltada para pessoas que não possuem fala ou escrita funcional, ou que apresentam uma defasagem entre suas necessidades comunicativas e sua capacidade de se expressar oralmente e/ou por escrito. Os sistemas utilizados podem envolver recursos de baixa tecnologia, como cartões, pranchas e pastas com símbolos, ou de alta tecnologia, como vocalizadores e softwares específicos desenvolvidos para esse propósito

Esses recursos podem ser utilizados em diversas situações e por várias pessoas incluindo pessoas do espectro autista, pessoas com paralisia cerebral ou afasia:

**Voiceitt**: reconhece fala atípica e converte em fala clara utilizando modelos personalizados de IA. Ainda em versão limitada ou beta, mas gratuito em alguns contextos.

**Cboard**: permite a comunicação por meio de símbolos e texto. Utiliza IA de forma básica para sugerir expressões conforme o contexto. É gratuito e acessível via navegador e Android.

## Reconhecimento de Emoções e Voz

Essas tecnologias ajudam na mediação afetiva e comunicação não verbal, especialmente úteis para autistas ou pessoas com surdez:

**Emotient** (Apple): tecnologia embarcada que reconhece emoções faciais em tempo real. Incorporada aos dispositivos iOS.

**Teachable Machine** (Google): permite treinar modelos personalizados de IA para reconhecer expressões faciais ou sons (como felicidade, tristeza, susto). Muito usado em atividades pedagógicas.

**Google Transcrição Instantânea (Live Transcribe)**: transcreve falas em tempo real para a tela, ideal para pessoas surdas. Gratuito (Android).

**AVA (Live Captioning)**: legenda de conversas em tempo real com IA de reconhecimento de voz. Gratuito com limitações (Android).

## Acessibilidade Cognitiva e Apoio à Aprendizagem

Esses recursos beneficiam estudantes com dificuldades de aprendizagem, TDAH ou transtornos do desenvolvimento:

**Socratic by Google:** responde a perguntas escolares por texto, imagem ou voz, utilizando IA educacional. Muito útil para estudantes do ensino médio. Gratuito (Android e iOS).

**MindMeister + GPT:** permite criar mapas mentais com sugestões automáticas de conteúdo com base em IA. Parcialmente gratuito (web).

**Teachable Machine:** também pode ser usado para treinar a IA a reconhecer gestos, sons ou imagens específicas para uso pedagógico.

## Acessibilidade Motora e Navegação Alternativa

Essas ferramentas facilitam o uso de dispositivos para pessoas com mobilidade reduzida ou tetraplegia:

**Google Voice Access:** oferece controle completo do smartphone por comandos de voz com IA de reconhecimento de linguagem natural. Gratuito (Android).

**LipNet e Eye Gaze Systems:** utilizam redes neurais profundas para permitir controle por leitura labial ou movimento dos olhos, úteis em tecnologias de comunicação sem uso das mãos.

**Monet e Braille Fácil:** softwares para edição e impressão em Braille. Não utilizam IA, mas são essenciais para acessibilidade escrita.

Esses recursos alinham-se aos princípios da **Tecnologia Assistiva**, definidos pela LBI como produtos, dispositivos, metodologias e serviços que promovem a funcionalidade e a participação plena da pessoa com deficiência na vida em sociedade.

Assim, entender IA não é apenas uma questão técnica, mas também ética, social e cidadã. Ao aplicar conhecimentos sobre sensores, redes neurais e tecnologia assistiva, os estudantes poderão analisar criticamente como as inovações tecnológicas podem contribuir para uma sociedade mais justa e inclusiva.

## INTELIGÊNCIA ARTIFICIAL PARA A ACESSIBILIDADE NA APRENDIZAGEM

### Introdução

A inclusão de estudantes com deficiência, Transtorno do Espectro Autista (TEA) ou Altas Habilidades/Superdotação (AH/SD) - público alvo da Educação Especial, é um compromisso ético e legal das instituições educacionais. Com os avanços tecnológicos, especialmente da Inteligência Artificial (IA), novas possibilidades emergem para garantir o acesso, a permanência e o desenvolvimento pleno desses alunos na Educação Básica.

Este texto apresenta uma abordagem integrada entre os fundamentos da acessibilidade, a aplicação da IA e o uso de Tecnologia Assistiva.

### Acessibilidade e Inteligência Artificial

A acessibilidade é entendida como a eliminação de barreiras físicas, comunicacionais, pedagógicas e digitais que impedem a plena participação de todos. Já a Inteligência Artificial pode ser usada como suporte à aprendizagem inclusiva, oferecendo:

- Personalização de conteúdos;
- Interfaces de linguagem natural;
- Tradução automática (voz/texto);
- Sistemas de leitura e síntese de voz;
- Reconhecimento de padrões de comportamento e aprendizagem.

Ferramentas baseadas em IA possibilitam adaptar conteúdos às necessidades do estudante, promover a comunicação alternativa, ampliar a autonomia e criar ambientes mais interativos e responsivos.

### Princípios da Acessibilidade Digital

Conforme vários estudos, um conteúdo digital acessível deve ser:

- Perceptível: legível em múltiplos formatos (voz, texto, braille).
- Operável: navegável com teclado, comando de voz ou toques.
- Compreensível: linguagem clara, estrutura lógica e previsibilidade.
- Robusto: compatível com diferentes categorias de Tecnologia Assistiva.

Esses princípios devem nortear a produção de materiais escolares, vídeos, avaliações e objetos digitais de aprendizagem. A IA pode colaborar para que esses princípios sejam atendidos de forma dinâmica e automatizada.

### Deficiências, Desafios e Soluções com IA e Tecnologias Assistivas

Os principais tipos de deficiência, desafios e os recursos assistivos – com destaque para aqueles baseados em Inteligência Artificial – que apoiam o acesso, a comunicação e o aprendizado em contextos educacionais. As tecnologias listadas são gratuitas ou de uso acessível, e muitas estão disponíveis em Português.

<b>Tipo de Deficiência</b>	<b>Desafios</b>	<b>Soluções com IA e Tecnologias Assistivas</b>
Deficiência Física	Dificuldades motoras para escrever, manipular livros ou usar teclado/mouse.	<ul style="list-style-type: none"> <li>• Google Voice Access (controle por voz)</li> <li>• Camera Mouse (controle facial)</li> <li>• Teclados virtuais</li> </ul>
Deficiência Auditiva	Compreensão de fala, ausência de Libras,	<ul style="list-style-type: none"> <li>• Hand Talk, VLibras, ProDeaf (Libras com IA)</li> <li>• Transkriptor (transcrição em tempo real)</li> <li>• Google Meet, Zoom com legendas automáticas</li> </ul>

Tipo de Deficiência	Desafios	Soluções com IA e Tecnologias Assistivas
	dificuldades com conteúdos orais.	
Deficiência Visual	Dificuldade de leitura, identificação de imagens e navegação visual.	<ul style="list-style-type: none"> <li>• Seeing AI e Google Lookout (app), Envision AI e OrCam MyEye (óculos)</li> <li>• Voice Aloud Reader, Read Aloud (app), Balabolka</li> <li>• NVDA, JAWS, VoiceOver (leitores de tela)</li> <li>• Text2Braille3D, Impressoras Braille</li> <li>• Braille Fácil, Monet (produção em Braille)</li> </ul>
Deficiência Intelectual	Comprometimento na linguagem (oral e escrita), memória, atenção e abstração.	<ul style="list-style-type: none"> <li>• EasyReader (extensão)</li> <li>• Voice Aloud Reader</li> <li>• MindMeister + GPT (mapas mentais com IA)</li> <li>• Socratic by Google, Luzia</li> </ul>
Deficiência Múltipla	Composição de impedimentos motores, sensoriais ou cognitivos.	<ul style="list-style-type: none"> <li>• Combinação de voz + CAA + leitores de tela</li> <li>• Teachable Machine (IA para gestos e sons – modelo de aprendizagem)</li> <li>• Cboard (comunicação com símbolos e IA)</li> </ul>
Transtorno do Espectro Autista (TEA)	Linguagem oral, comportamento inflexível, sensorialidade, emoções.	<ul style="list-style-type: none"> <li>• Cboard (CAA com IA), ARASAAC</li> <li>• Voiceitt (fala não padrão)</li> <li>• Agendas visuais, vídeos curtos, simulações</li> <li>• Teachable Machine</li> <li>• EasyReader</li> </ul>
Altas Habilidades/ Superdotação (AH/SD)	Desmotivação, ausência de estímulo ou desafio adequado.	<ul style="list-style-type: none"> <li>• Socratic by Google (pesquisa e aprofundamento)</li> <li>• Scratch com IA, Teachable Machine</li> <li>• MindMeister + GPT</li> <li>• Simuladores, jogos de lógica</li> </ul>

## Aplicações da Inteligência Artificial e da Acessibilidade no Ensino de Diferentes Áreas do Conhecimento

A aplicação da Inteligência Artificial (IA) e de recursos de acessibilidade pode beneficiar significativamente o processo de ensino-aprendizagem em todas as áreas do conhecimento — da Língua Portuguesa à Matemática, das Artes à Geografia, da Educação Física às Ciências Humanas e Tecnológicas. As ferramentas digitais acessíveis, quando bem integradas às metodologias pedagógicas, possibilitam que os estudantes com ou sem deficiência aprendam de maneira mais autônoma, personalizada e inclusiva.

### Estratégias acessíveis mediadas por IA

A seguir, destacam-se possibilidades de aplicação acessível e inteligente em diferentes componentes curriculares:

**Línguas e suas Tecnologias:** tradutores automáticos com Libras (como o Hand Talk), leitores de tela com voz natural para leitura de textos, corretores gramaticais

inteligentes e sintetizadores de voz para apoiar alunos com deficiência visual, auditiva ou intelectual.

**Matemática e suas Tecnologias:** softwares com resolução passo a passo (como MindMeister + GPT, Socratic by Google, Luiza, Soroban), ambientes de geometria dinâmica, simulações de problemas contextualizados e narrativas visuais para alunos com TEA ou deficiência intelectual.

**Ciências da Natureza e suas Tecnologias:** simulações interativas com ajustes sensoriais, vídeos com legendas e audiodescrição, e visualização 3D de conceitos como anatomia, ecossistemas ou reações químicas.

**Ciências Humanas e Sociais Aplicadas:** mapas interativos acessíveis, linhas do tempo audiodescritas, games narrativos com escolhas múltiplas e sistemas de IA que ajustam a complexidade dos temas à compreensão do estudante.

**Educação Física:** aplicativos de planejamento motor adaptado, vídeos com Libras ou com instruções por voz, jogos digitais que simulam atividades físicas com foco na coordenação motora e equilíbrio.

**Artes:** softwares de desenho com resposta tátil ou auditiva, programas de composição musical com interface simples, produção de vídeos com ferramentas de acessibilidade (legendas, descrição sonora).

## Ambientes Virtuais de Aprendizagem e Acessibilidade

Ambientes Virtuais de Aprendizagem (AVAs) como o Moodle, Google Sala de Aula, Canvas, entre outros, têm se tornado espaços importantes na mediação pedagógica. No entanto, sua eficácia inclusiva depende da adoção de práticas e recursos que assegurem:

- Navegação compatível com leitores de tela;
- Legendas e Libras em vídeos e aulas síncronas;
- Contraste de cores e tipografia acessível;
- Uso de texto alternativo em imagens e gráficos;
- Estruturação semântica clara de conteúdos e avaliações.

Esses elementos estão alinhados com diretrizes como o eMAG e a WCAG, e devem ser considerados desde o design do curso até a disponibilização dos objetos digitais de aprendizagem.

## Sistema baseado em perfis de aprendizagem

Um sistema baseado em perfis de aprendizagem é um **sistema educacional inteligente ou adaptativo** que **coleta, analisa e utiliza dados do estudante** (como desempenho, preferências, erros, ritmo de aprendizagem, estilo cognitivo ou emocional) para **personalizar o ensino**. Esses sistemas constroem um **perfil dinâmico** do aluno e usam esse perfil para

---

adaptar: a sequência dos conteúdos, a dificuldade das tarefas, o tipo de *feedback* oferecido, o tempo de revisão e retomada, e até o tipo de linguagem usada nas interações. Alguns exemplos de sistemas: Duolingo, Khan Academy e AutoTutor.

### **Duolingo**

- Área de atuação: Línguas estrangeiras
- Tipo de adaptação: Repetição espaçada, ajuste de dificuldade, gamificação adaptativa
- Perfil de aprendizagem: Sim
- Observação: Trabalha com perfis comportamentais e de memória de curto/médio prazo, com base em erros, acertos e tempo de resposta.

### **Khan Academy + MAP Accelerator**

- Área de atuação: Multidisciplinar (com ênfase em matemática)
- Tipo de adaptação: Recomendação de conteúdos personalizados, rastreamento de progresso, adaptação com base em testes diagnósticos
- Perfil de aprendizagem: Sim
- Observação: Quando integrado com ferramentas como o MAP Accelerator, adapta o percurso conforme os resultados de testes adaptativos externos.

### **AutoTutor**

- Área de atuação: Ciências e linguagem
- Tipo de adaptação: Interação por linguagem natural, oferta de feedback conceitual ajustado ao raciocínio do aluno
- Perfil de aprendizagem: Sim
- Observação: Simula o papel de um tutor humano, oferecendo explicações e perguntas personalizadas com base na linguagem e no desempenho do estudante.

## **Considerações Finais**

Embora o potencial dessas tecnologias seja vasto, como favorecer a permanência e o engajamento dos estudantes, permitindo que eles avancem no currículo conforme suas necessidades educacionais, ainda existem desafios importantes a serem enfrentados.

Entre os desafios, destacam-se a necessidade de formação docente específica em acessibilidade e inteligência artificial, as barreiras tecnológicas e de conectividade que limitam o acesso equitativo aos recursos digitais, as preocupações éticas relacionadas à privacidade e à transparência dos algoritmos, bem como a importância de garantir a validação pedagógica e técnica das ferramentas utilizadas no contexto educacional.

A IA para a acessibilidade na aprendizagem exige mais do que ferramentas, exige compromisso pedagógico, políticas institucionais e inovação responsável. A integração entre Tecnologia

Assistiva e IA como agentes pedagógicos pode transformar os espaços, promovendo o pertencimento e aprendizagem significativa para todos.

# MÓDULO 6

## PROGRAMAÇÃO PARA IA

### **Objetivo do Módulo:**

Ao final do módulo os professores participantes deverão ter uma visão geral de como uma IA é programada usando sistemas disponíveis no mercado.

### **Contempla:**

Aula 16 - Introdução ao Orange: exploração de dados e visualizações

Aula 17 - Classificação supervisionada com Árvores de Decisão

Aula 18 - Análise de Sentimentos

## Introdução ao Orange: exploração de dados e visualizações

### Introdução

Este documento apresenta uma visão prática de Programação para IA com a ferramenta Orange Data Mining, focada em usos pedagógicos no Ensino Médio e em formações de professores. Ao falarmos em “programação”, adotamos o sentido de construção de fluxos (workflows) visuais com widgets que representam etapas de análise de dados e aprendizado de máquina, dispensando código inicial e permitindo que estudantes desenvolvam pensamento computacional e científico. O Orange, por sua natureza visual (no/low-code), torna tangíveis os conceitos de dados, modelos e avaliação, favorecendo a investigação orientada por problemas e o protagonismo discente.

A proposta deste material de apoio às aulas 16, 17 e 18, articula três frentes: (1) exploração e visualização de dados para formular perguntas e gerar evidências; (2) classificação supervisionada com avaliação e interpretação dos modelos; e (3) processamento de linguagem natural (PLN) aplicado à análise de sentimentos em português. O objetivo é fornecer fundamentos conceituais e um roteiro de implementação com fluxos que podem ser replicados e adaptados à realidade das escolas.

### Fundamentos: dados, tarefas e ciclo de IA

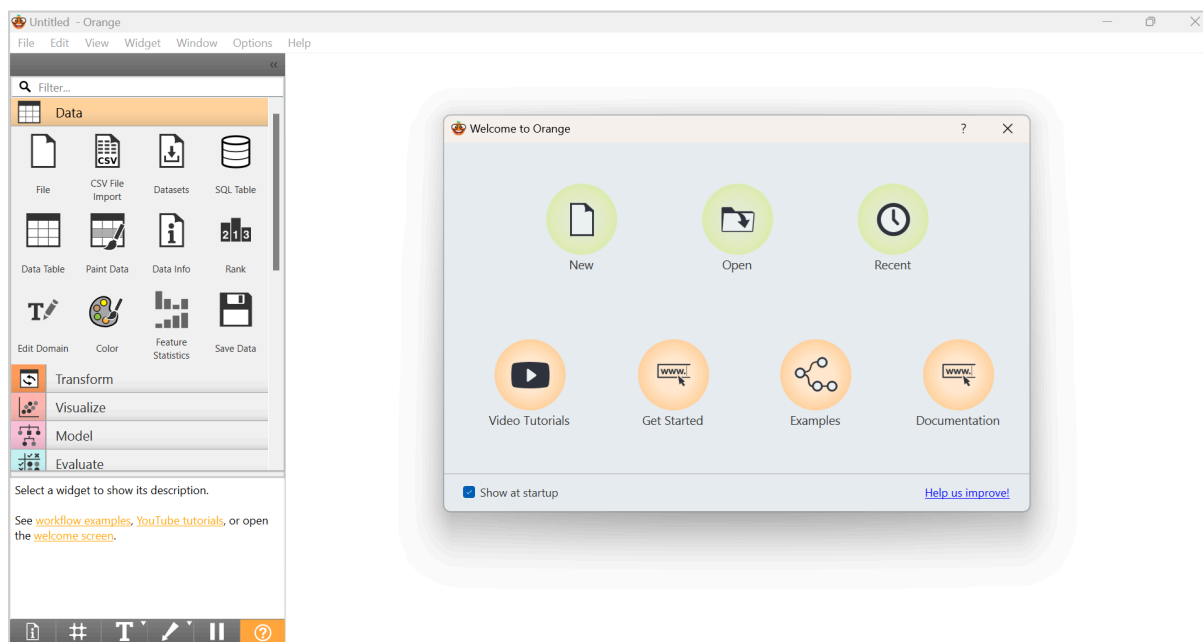
Projetos de IA começam na definição do problema e na compreensão dos dados. Em classificação e regressão, trabalhamos com dados rotulados (atributos → alvo); em clusterização e redução de dimensionalidade, buscamos padrões sem rótulo. A qualidade das decisões depende de um ciclo bem organizado: coletar/selecionar dados; pré-processar (limpeza, tipos, normalização); explorar padrões; treinar e ajustar modelos; avaliar; interpretar; comunicar resultados e limitações; e, quando aplicável, implantar e monitorar.

### Orange: programação visual por fluxos

Orange não é uma “linguagem de programação”, é uma ferramenta visual (no-code/low-code) para mineração de dados e IA, com widgets conectáveis. O Orange organiza o processo em blocos (widgets) conectados por setas no Canvas. Cada bloco cumpre um papel: importar dados, selecionar variáveis, visualizar, treinar modelos, avaliar e interpretar. O arquivo do fluxo (.ows) permite reabrir e continuar a análise. Esse formato favorece a aprendizagem por experimentação e o registro das decisões tomadas pelos estudantes.

Um widget é um componente interativo (blocos) que realiza tarefas específicas dentro da plataforma de visualização de dados e análise.

## A Interface do Orange




## Instalação e primeiros passos

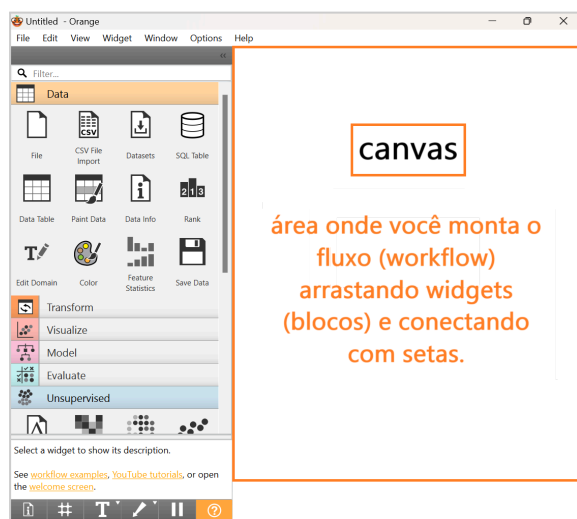
- Para instalar via Navegador (Chrome, Edge, etc.): Através do link: <https://orangedatamining.com/download/>.
- Para abrir o Orange: ícone na área de trabalho - executar Orange → aparecerá o Canvas (área de trabalho do Orange).
- Conceitos-chave:
  - Widget (bloco funcional), Fluxo (pipeline de blocos), Conexões (setas), .ows (arquivo do fluxo).
  - Dados = tabela com atributos (features) e, quando houver, rótulo (label/alvo).

## Visão geral

**Barra superior:** File (Novo/Abrir/Salvar → gera .ows), Edit (Voltar/Refazer), Widget (Open/Rename/Remove), Options (Add-ons, Preferências), Help (documentação).



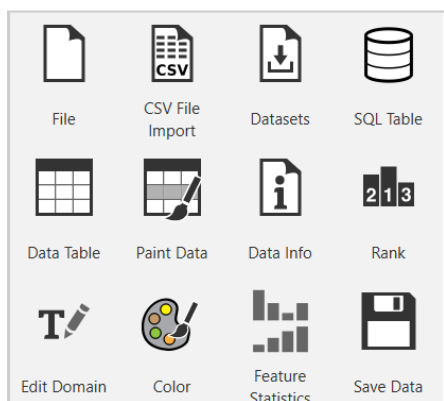
**Canvas** (centro): área onde você monta o fluxo (workflow) arrastando widgets (blocos) e conectando com setas.



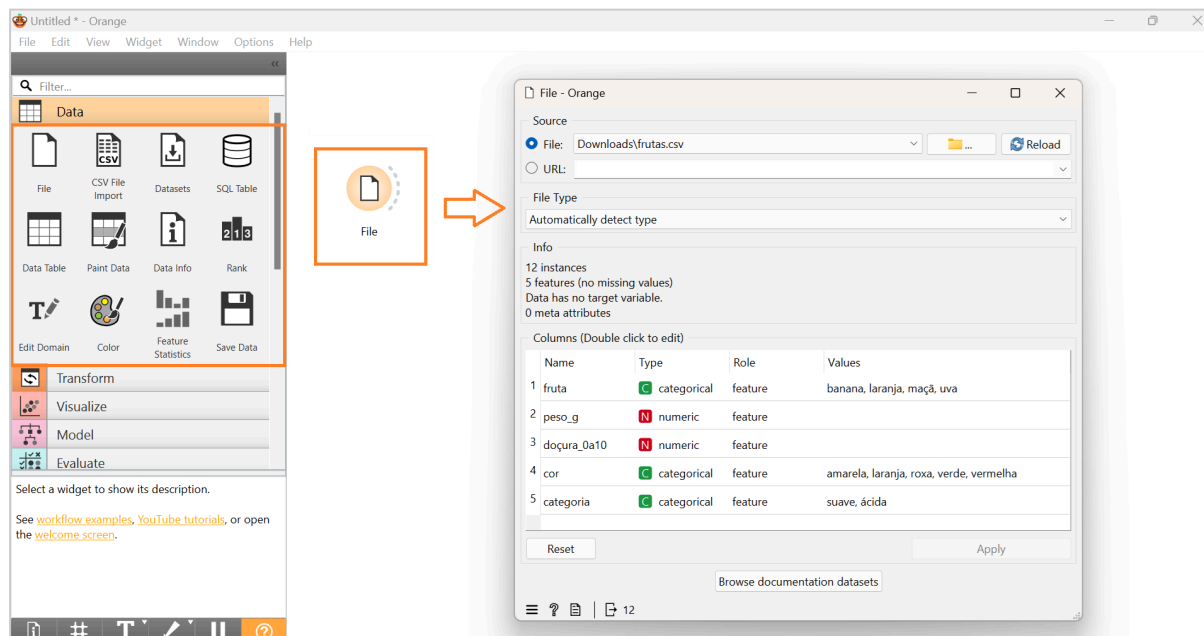
**Catálogo de Widgets** (à esquerda): são as abas Data, Transform, Visualize, Model, Evaluate e Unsupervised.



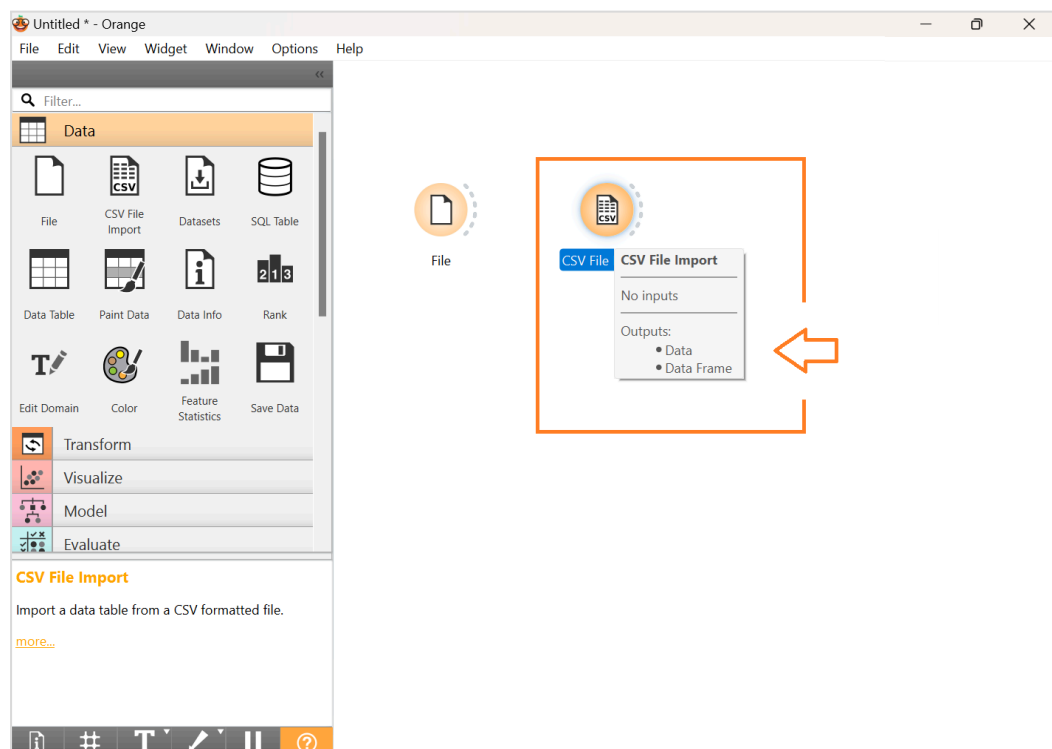
**Widgets:** É um componente interativo (blocos) que realiza tarefas específicas dentro da plataforma de visualização de dados e análise. São encontrados dentro de cada aba do catálogo.



**Janela do widget:** ao dar duplo clique num bloco, abre a janela com configurações e visualizações; muitos têm botão Report para capturar imagens.



**Status/indicadores:** alguns widgets mostram “bolinhas”/ícones indicando atividade, erros ou que esperam dados.



## Núcleo conceitual

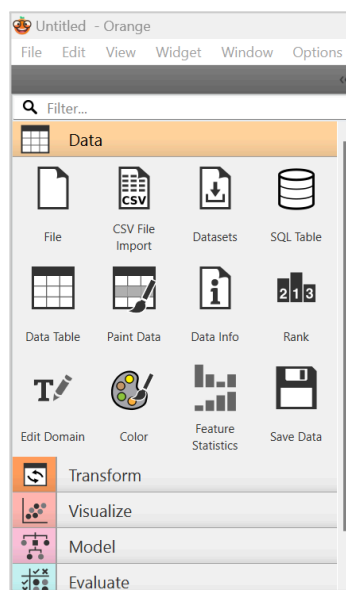
Aqui tem-se uma breve descrição sobre os componentes básicos que compõem a utilização da ferramenta Orange.

- Canvas: a “mesa” do seu pipeline<sup>2</sup>.
- *Widgets*: cada bloco faz uma tarefa (ex.: File, Impute, Tree, Test & Score).
- Sinais/Conexões: o que sai de um widget entra em outro (ex.: Data, Learner, Evaluation Results, Selected Data).
- **.ows**: é o arquivo do fluxo (reprodutível/compartilhável).
- Categorias (lado esquerdo): Data (importar/organizar), Transform (pré-processar/engenharia), Visualize (gráficos), Model (learners), Unsupervised (clusters/projeções), Evaluate (métricas/erros). Add-ons adicionam novas categorias.

Dá pra programar em Python usando a biblioteca do Orange, mas, para sala de aula, o foco é o canvas de fluxos.

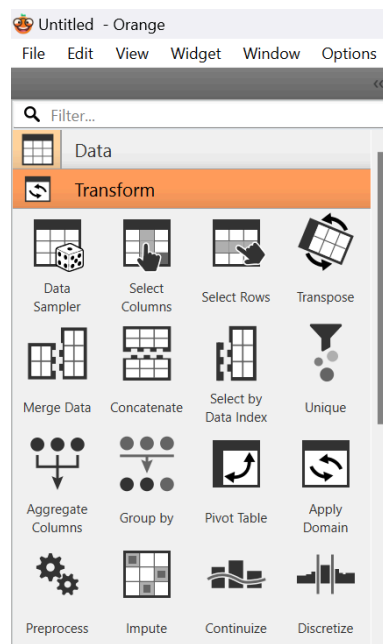
## O quê e para que serve cada aba do catálogo?

**Widgets de dados:** A aba Data é a “porta de entrada” dos dados no Canvas. É a categoria de *widgets* usada para importar, inspecionar, organizar e salvar conjuntos de dados antes da modelagem.

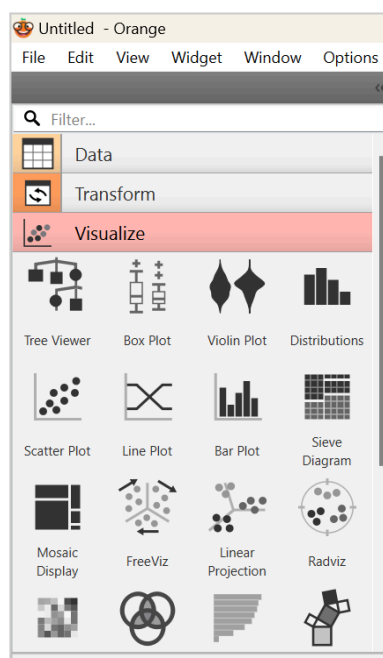


<sup>2</sup> O pipeline (também chamado de fluxo ou workflow) é a sequência de *widgets* conectados no Canvas que especifica, passo a passo, como os dados entram, são preparados, modelados, avaliados e visualizados. É o “programa” da sua análise, só que visual, e pode ser salvo/aberto como .ows.

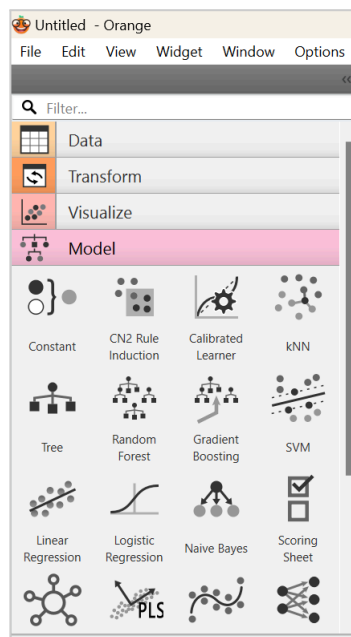
**Widgets de Transform:** A aba Transform é o conjunto de widgets para preparar, transformar e organizar os dados antes da modelagem: seleção/filtragem, reestruturação de tabelas, pré-processamento (imputação, codificação, discretização, normalização) e engenharia de atributos.



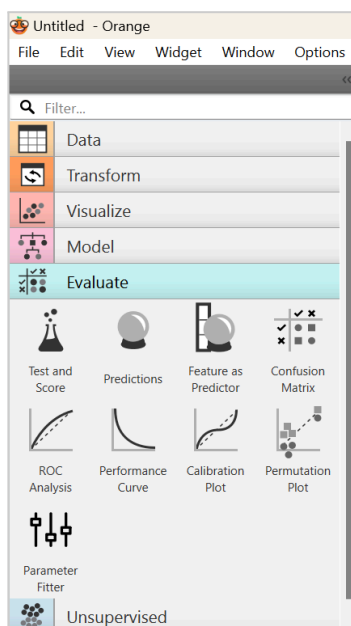
**Widgets de Visualize:** A aba Visualize é onde é reunido os widgets de visualização interativa — ou seja, ferramentas para explorar e comunicar padrões nos dados (distribuições, relações entre variáveis, grupos), antes ou depois da modelagem.



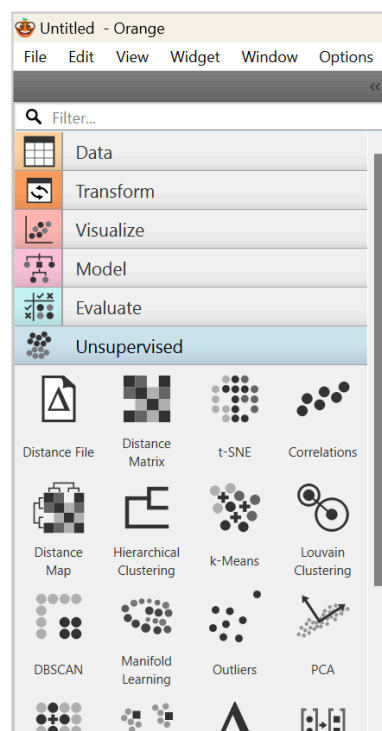
**Widgets de Model:** A aba Model reúne os “learners” — os widgets de algoritmos de aprendizado supervisionado que aprendem a partir de dados rotulados (classificação e regressão). É nesta aba que se escolhe qual modelo treinar no seu pipeline.



**Widgets de Evaluate:** A aba Evaluate é a categoria de widgets para avaliar e comparar modelos. Nela é possível medir desempenho (métricas), inspecionar erros (matriz de confusão), analisar limiar/curvas (ROC/PR) e escolher o melhor modelo para seu objetivo — sempre de forma reprodutível.



**Widgets de Unsupervised:** A aba Unsupervised é a categoria (e o tipo de tarefa) para aprender com dados sem rótulo. Em vez de prever uma classe, busca-se padrões, grupos e estruturas “escondidas” nos dados.



## Conclusão

Programar para IA com a ferramenta Orange Data Mining significa estruturar o pensamento computacional em fluxos claros, com foco em dados, modelos e evidências. Ao integrar exploração, classificação e PLN, criamos experiências de aprendizagem que desenvolvem análise crítica, argumentação e comunicação de resultados. A ferramenta Orange oferece o equilíbrio entre acessibilidade e profundidade: permite começar sem código e, conforme o interesse, avançar para explicabilidade, avaliação robusta e extensão para Python. Ao ter o cuidado de abordar a ética, LGPD e vieses, reforçamos a responsabilidade no uso de IA em contextos educacionais.

Para os próximos passos, ao utilizar a ferramenta Orange, recomenda-se consolidar um repositório local de datasets e fluxos (.ows), registrar artefatos de cada atividade (prints, métricas, sínteses) e fomentar projetos interdisciplinares. Esse ciclo contínuo — investigar, modelar, avaliar, interpretar e comunicar — forma estudantes capazes de ler o mundo por meio dos dados e de utilizar a IA de modo crítico, criativo e responsável.

Anexo — Materiais de apoio (nesta conversa)

- Fluxos .ows: Plano 1, Plano 2 e Plano 3 (Text Mining).
- Datasets CSV: frutas.csv, clima.csv, desempenho\_escolar.csv, sentimentos.csv.
- Tutoriais em slides (PPTX) e PDF de bolso.

# MÓDULO 8

## REDES NEURAIS ARTIFICIAIS: AVANÇADO

### **Objetivo do Módulo:**

Ao final do módulo os professores participantes deverão ter uma noção do funcionamento de Redes Neurais Convolutivas, podendo compreender como a arquitetura da rede pode impactar o seu funcionamento.

### **Contempla:**

Aula 19 - Vendo imagens com Redes Neurais Convolutivas

Aula 20 - Sistemas e Bases de Dados

## Introdução

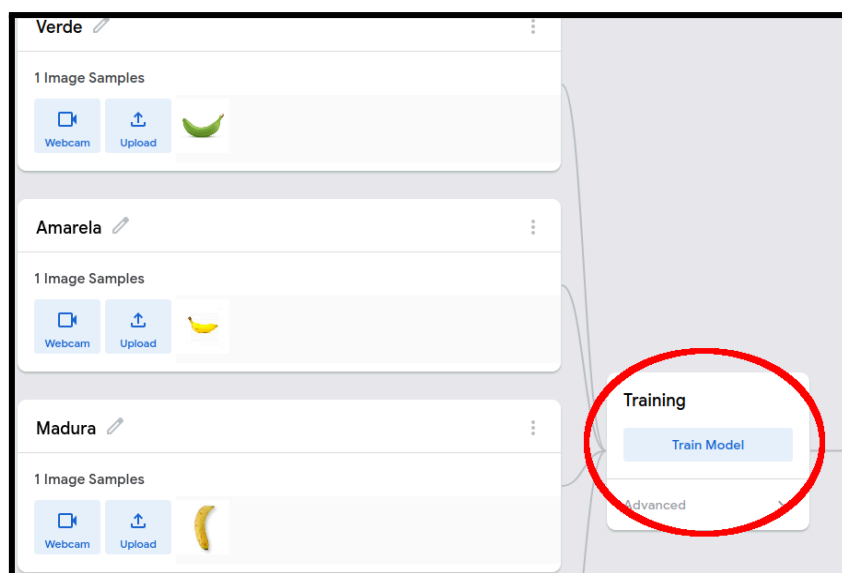
Neurônios artificiais utilizam funções de ativação para criar respostas para diferentes entradas. Assim, é possível utilizar neurônios simples para criar associações, mas eles são instrumentos lineares e não possuem grande flexibilidade. Quando utilizamos uma rede neural, podemos compor funções mais avançadas, que podem se adaptar a diferentes entradas, abrindo a possibilidade de lidar com falhas e erros nas entradas da rede. Nesta seção, vamos analisar uma arquitetura de redes neurais, a Rede Neural Convolutiva (RNC), como um exemplo claro de como a arquitetura da rede pode influenciar no seu desempenho e funcionamento.

## O Problema: Reconhecendo partes de uma imagem

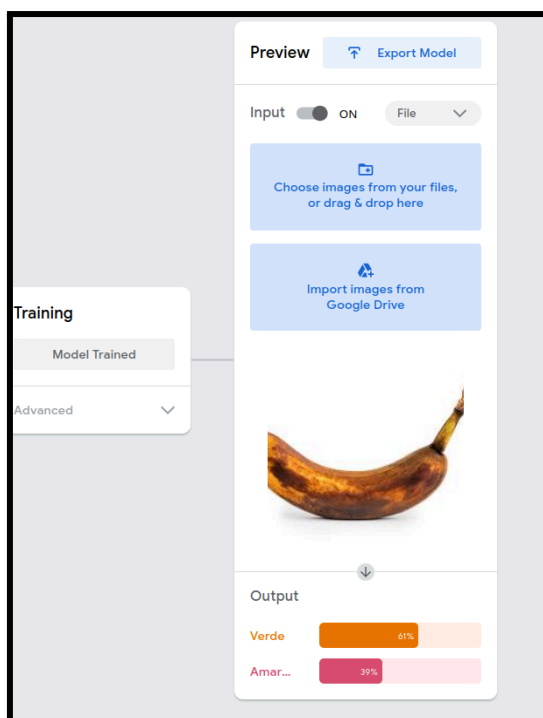
Se nós utilizarmos uma rede simples de perceptrons, podemos criar associações diretas de imagens com seu significado. Podemos ver um exemplo disso usando o Teachable Machine do Google para treinar um reconhecedor de imagens. No plano de aula, usamos um programa que reconhece bananas verdes e bananas maduras.

Para fazer o exemplo, acesse o site <https://teachablemachine.withgoogle.com/train/image>

Ao abrir o site, na parte da esquerda, é possível criar classes que serão reconhecidas e alimentá-las com imagens. Usando uma webcam ou fotos pesquisadas na internet, podemos criar classes para reconhecer o nível de maturidade de uma banana. Selecione fotos com apenas uma banana e alimente o conjunto de treinamento, clicando no botão **Train Model** para preparar o sistema:



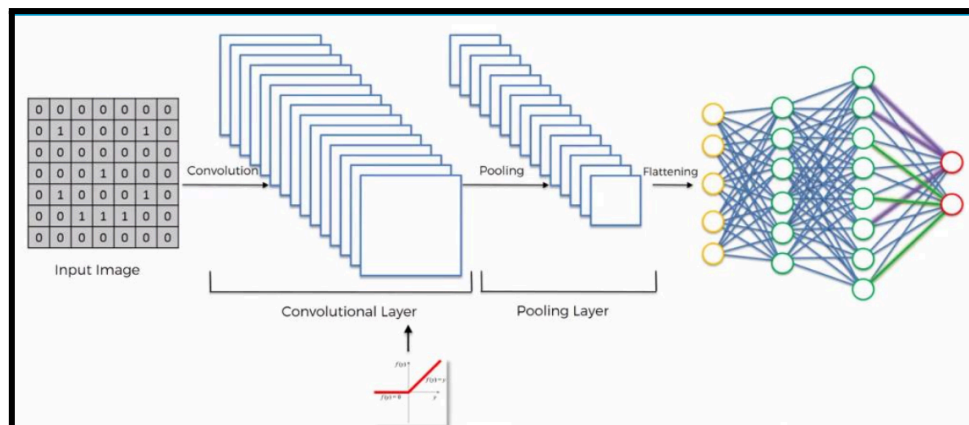
Após treinar o modelo, você pode usar a janela de **preview** para ver o comportamento do modelo, tanto pelo modo webcam, que identifica elementos da imagem, quanto enviando fotos para ele. Observe o desempenho do modelo, qual a confiabilidade dele de colocar as frutas nas suas classes.



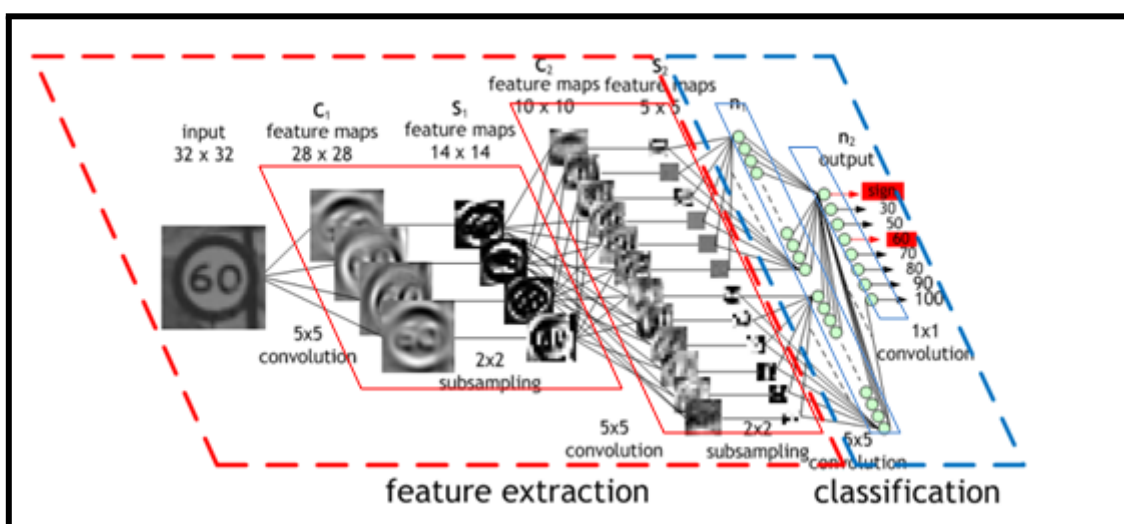
O que acontece se você utilizar fotos de mais de uma banana, colocá-la sobre um fundo de uma cor, ou misturar fotos de diferentes bananas?

Se bem treinado, o sistema é capaz de associar imagens, mas não **é capaz de compreender o conteúdo da imagem**. Assim, a rede que reconhece a imagem não sabe nem mesmo o que é uma banana, apenas associa a forma e as cores com uma etiqueta, ou tag.

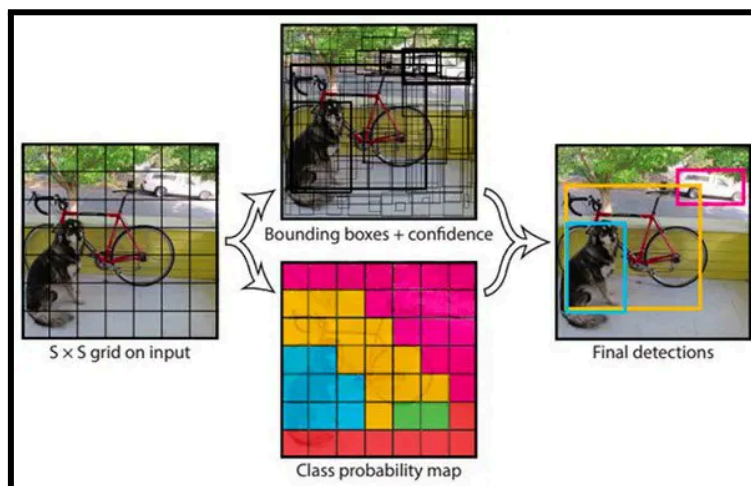
Para resolver este problema, vamos precisar de uma arquitetura diferente de reconhecedor de imagens. Uma Rede Neural Convolutiva (RNC) é um tipo especial, com uma arquitetura própria. Ela possui dois tipos de camadas ocultas, uma chamada **convolucional**, que percorre a imagem e seleciona **features**, ou características de interesse, e uma chamada **pooling**, que seleciona as features mais proeminentes. Múltiplas camadas podem ser colocadas uma após a outra, tornando possível reconhecer características “de mais alto nível”, ou seja, os detalhes da imagem, tornando-a mais precisa. Imagine que a imagem de entrada e cada feature são matrizes de valores, e seu filtro é feito por multiplicações de matrizes. Isso é feito por neurônios com um funcionamento diferente do perceptron. Há neurônios de convolução, que aplicam o seu filtro na imagem (menos conectados que o perceptron) e os de pooling, que simplesmente aplicam uma função de média ou valor maior nas saídas da convolução.



Você pode visualizar o processo na imagem abaixo:



Assim, uma RNC é capaz de segmentar, dividir uma imagem, reconhecendo padrões nos segmentos. Ela simula a capacidade de reconhecer objetos individuais numa imagem, podendo classificá-los e desenhar uma caixa ao seu redor (“bounding box”). No exemplo abaixo, temos uma imagem sobre a qual se executa tanto a sua divisão em bounding boxes e o reconhecimento das partes, selecionando os elementos que podem ser identificados, um cachorro, uma bicicleta e um automóvel.



Não só isso, as RNCs também tendem a ser mais precisas. Numa comparação clássica, feita em 1998 sobre o banco de dados MNIST (Modified National Institute of Standards and Technology database) para reconhecimento de letras, as RNCs são visivelmente menos propensas a erros:

MNIST		
Classifier	Test Error Rate (%)	References
Linear classifier (1-layer neural net)	12.0	LeCun et al. (1998)
K-nearest-neighbors, Euclidean (L2)	5.0	LeCun et al. (1998)
2-Layer neural net, 300 hidden units, mean square error	4.7	LeCun et al. (1998)
Support vector machine, Gaussian kernel	1.4	MNIST Website
Convolutional net, LeNet-5 (no distortions)	<b>0.95</b>	LeCun et al. (1998)

Por serem uma arquitetura *feed forward*, na qual não há loops internos, ela também é rápida, e apresenta um excelente desempenho. A AlexNET, de 2012, foi uma das mais famosas RNCs, pois foi a campeã do Desafio de Reconhecimento Visual em Larga Escala (Large Scale Visual Recognition Challenge, ILSVRC), demonstrando que a tecnologia já estava madura para aplicação em produtos e soluções.

## A nova tecnologia de reconhecimento de imagem

Deep Learning, ou aprendizagem profunda, é um conceito recente na Inteligência Artificial que se refere ao uso de redes neurais com múltiplas camadas com capacidades ampliadas de reconhecimento, podendo usar técnicas não-supervisionadas ou mistas, abrindo espaço para serem treinadas com grandes conjuntos de dados. Com isso, a RNC pode resolver problemas comuns para outros reconhecedores de imagens, tais como:


- Reconhecer um objeto em diferentes ângulos.
- Reconhecer um objeto sobre diferentes fundos.
- Reconhecer um objeto com diferentes incidências de luz e/ou cores diferentes.

Normalmente, temos dois problemas ao treinar uma rede neural:

- Underfitting, quando o modelo não foi treinado suficiente para ter resultados adequados (boa precisão e acurácia no reconhecimento) no seu conjunto de treinamento
- Overfitting, quando o modelo não pode ser aplicado em situações além daquelas em que foi treinado.

Mesmo assim, do ponto de vista técnico, podemos trabalhar com redes mais profundas (Deep Neural Networks) e com maiores bases de dados para tentar criar sistemas mais eficientes de reconhecimento e classificação. Mesmo o overfitting, que é resultado de uma especialização do sistema, pode ser resolvido dessa forma por um fenômeno conhecido como *grokking*, uma generalização atrasada do sistema, após ser alimentado com mais dados.

A imagem abaixo é de um show da banda Massive Attack, quando usaram um reconhecedor de rostos na platéia, um sistema capaz de nomear as pessoas que estão lá em tempo real.



Esses sistemas já estão sendo aplicados em soluções para a vida cotidiana. Um exemplo, usado no plano de aula, é o reconhecimento de rostos de clientes de uma loja, permitindo que ela funcione sem caixa. O texto sugerido é:

- [https://brasil.elpais.com/brasil/2018/01/22/tecnologia/1516601138\\_966659.html](https://brasil.elpais.com/brasil/2018/01/22/tecnologia/1516601138_966659.html)

No caso podemos usar a Engenharia de Software para explorar como esse sistema funcionaria. No mínimo, ele deveria ter:

- Reconhecedor de rostos, para reconhecer cliente
- Reconhecedor imagem de produtos, para acompanhar as compras dos clientes
- Sistema contábil, que registra contas e dívidas de cada cliente
- Sistema de controle de estoque, que permite controlar quando repor um determinado item.
- Um sistema integrado de pagamento, que já joga as compras do usuário diretamente em seu cartão de crédito.

As duas primeiras partes são sistemas de IA e, as seguintes, sistemas computacionais já empregados em larga escala. Nosso trabalho é explorar como essas partes interagem, observando como cada parte funciona, e em que momento elas precisam se comunicar. É esta inserção da IA em sistemas que já usamos no dia a dia que devemos nos atentar, pois não é fácil entender que há estes sistemas ali.

Mais interessante ainda é se questionar como estes sistemas podem falar com outros, trocando informações bastante sensíveis, tais como:

- Analisar o histórico de compras de um cliente para criar anúncios no aplicativo
- Analisar padrões de compra para ajustar o estoque da loja: itens que são mais comprados ficam com maior estoque.
- Registrar o horário que o cliente costuma vir para a loja, e criar um sistema de previsão de vendas do dia, prevendo o que será consumido a cada dia

Da mesma forma que a IA precisa de mais dados para aumentar a sua precisão e acurácia, podemos acrescentar novos dados e novas análises de dados para acrescentar funcionalidades ao sistema. Hoje há um verdadeiro mercado de dados, que cruza diferentes perfis de usuários para achar novos padrões e previsões. O software, hoje, é uma amálgama de vários serviços diferentes, alguns deles oferecidos por empresas diferentes. Assim, uma loja sem caixa pode subcontratar um serviço de reconhecimento facial, passando as imagens que grava em suas câmeras para terceiros.

No Brasil, hoje, temos a Lei Geral de Proteção de Dados, a LGPD, que caracteriza e regula os dados pessoais e como eles devem ser tratados pelas empresas. Uma de suas definições mais importante é a de Dados Pessoais sensíveis:

“dado pessoal sensível: dado pessoal sobre origem racial ou étnica, convicção religiosa, opinião política, filiação a sindicato ou a organização de caráter religioso, filosófico ou político, dado referente à saúde ou à vida sexual, dado genético ou biométrico, quando vinculado a uma pessoa natural;”

Podemos pensar no problema que esse tipo de dado pode gerar, no momento em que ele permite discriminação e perseguição de minorias. É importantíssimo desenvolver nos alunos atitudes de preservação da privacidade (sua e dos outros) online.

Há um comércio de dados feito por empresas de tecnologias de informação e comunicação, especialmente pelas plataformas online e por empresas de IA. A LGPD determina a divisão da responsabilização entre o operador (pessoa ou empresa que contrata um serviço) e o controlador (o responsável por aplicar o serviço), ao mesmo tempo que exige a figura de um encarregado pelos dados, pessoa que deve atender o usuário e lidar com o controlador e a ANPD (Agência Nacional de Proteção de Dados).

## O Solucionismo

O teórico Evgeny Morozov chama de Solucionismo a ideia amplamente disseminada de que a ampliação do poder da tecnologia irá resolver os problemas da sociedade. A frase “é só adicionar mais dados” tenta aplicar a ideia do *grokking*, que é relacionada ao treinamento da IA, para a solução de problemas institucionais e sociais. Podemos imaginar uma grande base de dados, contendo tudo o que foi registrado sobre uma determinada pessoa, a partir do cruzamento de dados com toda a pegada digital de cada indivíduo. Que tipo de análise ela poderia trazer sobre as pessoas? De certa forma, tanto um estado centralizador quanto o capitalismo da informação sem regulamentação permitiriam criar esse tipo realizar esse tipo de banco de dados.

No texto abaixo, ele desenvolve mais a sua crítica:

- <https://outraspalavras.net/tecnologiaemdisputa/solucionismo-nova-aposta-das-elites-globais/>

Sem entender as partes que constituem um sistema de informática, será que nós podemos ir além do solucionismo? Como podemos exigir responsabilidade e transparência de um sistema que não conseguimos compreender completamente como funciona.

## REFERÊNCIAS

- ADaSci. (2024). How Much Energy Do LLMs Consume? Unveiling the Power Behind AI. ADaSci - Association of Data Scientists. Disponível em:  
<https://adasci.org/how-much-energy-do-llms-consume-unveiling-the-power-behind-ai/>
- AGÊNCIA BRASIL. Inteligência artificial pode ser ferramenta de ensino, mostra estudo. Brasília: EBC, 2024. Disponível em:  
<https://agenciabrasil.ebc.com.br/educacao/noticia/2024-05/inteligencia-artificial-pode-ser-ferramenta-de-ensino-mostra-estudo>. Acesso em: 19 jun. 2025.
- Akepa/The Sustainable Agency. (2025). Environmental Impact of Generative AI: Stats & Facts for 2025. Disponível em:  
<https://thesustainableagency.com/blog/environmental-impact-of-generative-ai/>
- BAUM, David. Generative AI and LLMs For Dummies. [S. l.]: John Wiley & Sons, 2024.
- BRASIL. Ministério da Ciência, Tecnologia e Inovação. Inteligência Artificial. Brasília: MCTI, 2024. Disponível em:  
<https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/transformacaodigital/inteligencia-artificial>. Acesso em: 19 jun. 2025.
- BRASIL. Ministério da Educação. Debate sobre IA nas políticas educacionais é foco do BRICS. Brasília: MEC, 2025. Disponível em:  
<https://www.gov.br/mec/pt-br/assuntos/noticias/2025/junho/debate-sobre-ia-nas-politicas-educacionais-e-foco-do-brics>. Acesso em: 19 jun. 2025.
- BRASIL. Ministério da Educação. MEC fará parte do Plano Brasileiro de Inteligência Artificial. Brasília: MEC, 2024. Disponível em:  
<https://www.gov.br/mec/pt-br/assuntos/noticias/2024/julho/mec-fara-parte-do-plano-brasileiro-de-inteligencia-artificial>. Acesso em: 19 jun. 2025.
- Bsharat, Sondos Mahmoud, Aidar Myrzakhan, and Zhiqiang Shen. "Principled Instructions Are All You Need for Questioning LLaMA-1/2, GPT-3.5/4." arXiv preprint arXiv:2312.16171. 2023.
- Codingscape. (2024). Stanford AI Index 2024 summary and full report. Disponível em:  
<https://codingscape.com/blog/stanford-ai-index-2024-summary-and-full-report>
- Dave, Paresh. Google aims to run on carbon free energy by 2030. Reuters, 15 set. 2020. Disponível em:  
<https://www.reuters.com/article/world/asia-pacific/google-aims-to-run-on-carbon-free-energy-by-2030-idUSKBN2651E0/>. Acesso em: 20 jun. 2025.
- de Vries, A. The growing energy footprint of artificial intelligence. Joule, v. 7, n. 10, p. 2191–2194, 18 out. 2023. DOI: 10.1016/j.joule.2023.09.004

DEEPGRAM. Chain-of-Thought Prompting: Helping LLMs Learn by Example. San Francisco: Deepgram, 2024. Disponível em: <https://deepgram.com/learn/chain-of-thought-prompting-guide>. Acesso em: 19 jun. 2025.

DIAMOND, Stephanie; ALLAN, Jeffrey. Writing AI prompts for dummies. Hoboken, NJ: John Wiley & Sons, 2024(For dummies).

GARG, Ashish; SOODHANI, K. Nisumba; RAJENDRAN, Ramkumar. Enhancing data analysis and programming skills through structured prompt training: The impact of generative AI in engineering education. *Computers and Education: Artificial Intelligence*, v. 8, p. 100380, fev. 2025. DOI: 10.1016/j.caeai.2025.100380.

Goldman Sachs. (2024). AI is poised to drive 160% increase in data center power demand. Disponível em: <https://www.goldmansachs.com/insights/articles/AI-poised-to-drive-160-increase-in-power-demand>

IEA - International Energy Agency. (2025). Energy and AI: Executive Summary. Disponível em: <https://www.iea.org/reports/energy-and-ai/executive-summary>

INSTITUTO.DI. Design de Prompts para a Inteligência Artificial. 2024. Disponível em: <https://www.idi.com.br/bookteca>. Acesso em: 10 fev. 2025.

Jegham, Nidhal; Abdelatti, Marwen; Elmoubarki, Lassad; Hendawi, Abdeltawab. How Hungry is AI? Benchmarking Energy, Water, and Carbon Footprint of LLM Inference. arXiv, 15 maio 2025. Disponível em: <https://arxiv.org/pdf/2505.09598>. Acesso em: 20 jun. 2025.

Microsoft. (2024). Our 2024 Environmental Sustainability Report. Microsoft On the Issues. Disponível em: <https://blogs.microsoft.com/on-the-issues/2024/05/15/microsoft-environmental-sustainability-report-2024/>

Microsoft. (2025). AI transformations for sustainability. Microsoft On the Issues. Disponível em: <https://blogs.microsoft.com/on-the-issues/2025/01/16/ai-transformations-for-sustainability/>

MIT News. (2025). Explained: Generative AI's environmental impact. Massachusetts Institute of Technology. Disponível em: <https://news.mit.edu/2025/explained-generative-ai-environmental-impact-0117>

NPR. (2024). Google and Microsoft report growing emissions as they double-down on AI. Disponível em: <https://www.npr.org/2024/07/12/g-s1-9545/ai-brings-soaring-emissions-for-google-and-microsoft-a-major-contributor-to-climate-change>

Patterson, David; gonzalez, Joseph; Le, Quoc; Liang, Chen; munguia, Lluís Miquel; rothchild, Daniel; So, David; texier, Maud; dean, Jeff. Carbon Emissions and Large Neural Network Training. arXiv, 21 abr. 2021. Disponível em: <https://arxiv.org/abs/2104.10350>. Acesso em: 20 jun. 2025.

---

Plan Be Eco. (2024). AI's carbon footprint - how does the popularity of artificial intelligence affect the climate? Disponível em:

<https://planbe.eco/en/blog/ais-carbon-footprint-how-does-the-popularity-of-artificial-intelligence-affect-the-climate/>

PROMPTHUB. Role-Prompting: Does Adding Personas to Your Prompts Really Make a Difference? San Francisco: PromptHub, 2024. Disponível em:

<https://www.prompthub.us/blog/role-prompting-does-adding-personas-to-your-prompts-really-make-a-difference>. Acesso em: 19 jun. 2025.

SABBATINI, Marcelo. Geração de imagens com Inteligência Artificial para a sala de aula. IA na Educação, 8 out. 2024. Disponível em:

<https://www.marcelo.sabbatini.com/geracao-de-imagens-com-inteligencia-artificial-para-a-sala-de-aula/>. Acesso em: 21 jun. 2025.

SCIENCEDIRECT. Enhancing data analysis and programming skills through structured prompt training: The impact of generative AI in engineering education. Amsterdam: Elsevier, 2025.

Disponível em: <https://www.sciencedirect.com/science/article/pii/S2666920X25000207>. Acesso em: 19 jun. 2025.

Shah, Simone. Some AI Prompts Can Cause 50 Times More CO<sub>2</sub> Emissions Than Others. TIME, 2 jun. 2025. Disponível em: <https://time.com/7295844/climate-emissions-impact-ai-prompts/>.

Acesso em: 20 jun. 2025.

Statista. (2024). Energy consumption by AI models 2024. Disponível em:

<https://www.statista.com/statistics/1465348/power-consumption-of-ai-models/>

SUBSTACK. Prompt Engineering for Education. San Francisco: Substack, 2024. Disponível em:

<https://aixeducation.substack.com/p/prompt-engineering-for-education>. Acesso em: 19 jun. 2025.

Sustainability by Numbers. (2024). What's the carbon footprint of using ChatGPT? Disponível em:

<https://www.sustainabilitybynumbers.com/p/carbon-footprint-chatgpt>

SwissCognitive. (2023). AI Is Huge – And So Is Its Energy Consumption. Disponível em:

<https://swisscognitive.ch/2023/10/24/ai-is-huge-and-so-is-its-energy-consumption/>

Takahashi, Dean. Nvidia unveils next gen Blackwell GPUs with 25× lower costs and energy consumption. VentureBeat, 18 mar. 2024. Disponível em:

<https://venturebeat.com/ai/nvidia-unveils-next-gen-blackwell-gpus-with-25x-lower-costs-and-energy-consumption/>. Acesso em: 20 jun. 2025.

Tomlinson, Bill and Black, Rebecca and Patterson, Donald and Torrance, Andrew W., The Carbon Emissions of Writing and Illustrating Are Lower for AI Than for Humans (February 14, 2024).

Tomlinson, B., Black, R.W., Patterson, D.J. and Torrance, A.W. The carbon emissions of writing and illustrating are lower for AI than for humans. *Sci Rep* 14, 3732 (2024).

<https://doi.org/10.1038/s41598-024-54271-x>, Available at SSRN:

<https://ssrn.com/abstract=4778246>

Tremayne Pengelly, Alexandra. A.I. Data Centers Are Emitting Nearly as Much Greenhouse Gases As Commercial Airlines. Observer, 6 dez. 2024. Disponível em:

<https://observer.com/2024/12/ai-data-center-carbon-emission/>. Acesso em: 20 jun. 2025.

Walsh-Elwell, Noelle. How Microsoft measures datacenter water and energy use to improve Azure Cloud sustainability. Microsoft Azure Blog, 15 mar. 2022. Disponível em:

<https://azure.microsoft.com/en-us/blog/how-microsoft-measures-datacenter-water-and-energy-use-to-improve-azure-cloud-sustainability/>. Acesso em: 20 jun. 2025.

World Economic Forum. (2024). Stanford just released its annual AI Index report. Here's what it reveals. Disponível em:

<https://www.weforum.org/stories/2024/04/stanford-university-ai-index-report/>