

# Aula 3 – Matemática Essencial para Deep Learning (Parte 1)

## Desvendando a Linguagem da IA: Matemática Essencial para Deep Learning (Parte 1)

Você já se perguntou como a inteligência artificial consegue reconhecer rostos em fotos, traduzir idiomas em tempo real ou até mesmo dirigir carros autônomos? Por trás de toda essa magia tecnológica, existe uma linguagem fundamental que permite que os computadores "entendam" e processem o mundo ao seu redor. Essa linguagem é a matemática, e, no universo do Deep Learning, a Álgebra Linear é o seu alfabeto.

Entender os conceitos básicos da Álgebra Linear não é apenas um requisito acadêmico; é a chave para desmistificar como as redes neurais funcionam e, mais importante, como você pode começar a construí-las e otimizá-las. Imagine que você está aprendendo a cozinhar um prato complexo: antes de dominar as técnicas avançadas, você precisa conhecer os ingredientes e as ferramentas básicas. Aqui, os "ingredientes" são os dados, e as "ferramentas" são as operações matemáticas que os transformam.

Nesta aula, embarcaremos em uma jornada para solidificar sua compreensão dos pilares matemáticos que sustentam o Deep Learning. Nosso objetivo é que, ao final, você seja capaz de identificar e manipular os elementos fundamentais da Álgebra Linear – escalares, vetores, matrizes e tensores – e compreender como operações como o produto escalar e a multiplicação de matrizes são a espinha dorsal da representação e processamento de dados em redes neurais. Prepare-se para ver a matemática sob uma nova luz, conectada diretamente ao futuro da inteligência artificial.

# O Alfabeto da IA: Escalares e Vetores

No nosso dia a dia, lidamos com informações de diversas formas. Às vezes, uma única medida é suficiente para descrever algo, como a temperatura ambiente ou a sua idade. Outras vezes, precisamos de um conjunto de informações para ter uma imagem completa, como as coordenadas GPS de um local ou a lista de ingredientes de uma receita. No mundo da inteligência artificial, essa distinção é crucial para como os dados são representados e processados.

## Escalares

Um número único que representa uma magnitude ou quantidade. Exemplos: temperatura (25°C), idade, preço de um produto.

## Vetores

Uma lista ordenada de números. Cada número é uma "dimensão" ou "característica". Exemplo: [idade, nota\_matemática, nota\_português].

Pense nos dados como a matéria-prima para qualquer modelo de Deep Learning. Para que um computador possa "entender" essa matéria-prima, ela precisa ser traduzida para uma linguagem numérica. É aqui que entram os **escalares** e os **vetores**, os blocos de construção mais básicos da Álgebra Linear. Eles são o ponto de partida para qualquer representação de dados, desde um simples número até as características complexas de uma imagem ou um texto.

**Exemplo Prático:** Se quisermos representar um aluno em um sistema de recomendação, poderíamos usar um vetor como [idade, nota\_matemática, nota\_portugues]. O vetor [20, 8.5, 9.2] descreve um aluno de 20 anos com nota 8.5 em matemática e 9.2 em português.

Vamos começar com o mais simples: o **escalar**. Um escalar é apenas um número único. Ele representa uma magnitude, uma quantidade. Imagine o termômetro marcando 25°C. Esse "25" é um escalar. Ele nos dá uma informação completa sobre a temperatura em um único valor. Da mesma forma, sua idade, o preço de um produto ou a velocidade de um carro são exemplos de escalares. Eles são a unidade mais fundamental de informação numérica, sem direção ou múltiplas dimensões.

Agora, e se quisermos descrever algo mais complexo, como a localização de um ponto em um mapa? Um único número não seria suficiente. Precisaríamos de uma latitude e uma longitude. É aí que entra o **vetor**. Um vetor é uma lista ordenada de números. Cada número na lista é uma "dimensão" ou uma "característica" que descreve o objeto em questão. Pense em um vetor como uma "receita" para algo: se você está descrevendo um carro, um vetor pode conter sua velocidade, seu consumo de combustível e seu ano de fabricação. Cada item é uma característica, e a ordem importa.

Em Deep Learning, esses vetores são frequentemente usados para representar características de entrada (como pixels de uma imagem ou palavras em um texto) ou até mesmo os pesos de uma única conexão em uma rede neural. Eles são a base para a representação de dados multidimensionais, permitindo que os modelos capturem a complexidade do mundo real.


# Organizando o Conhecimento: Matrizes

Se um vetor é uma lista de características para um único item, o que acontece quando precisamos lidar com *muitos* itens, cada um com suas próprias características? Imagine que você não tem apenas um aluno, mas uma turma inteira, ou até mesmo uma escola. Representar cada aluno como um vetor separado seria ineficiente e difícil de gerenciar. Precisamos de uma estrutura que possa organizar múltiplos vetores de forma coesa.

É nesse ponto que as **matrizes** entram em cena. Uma matriz é, essencialmente, uma tabela retangular de números. Pense nela como uma planilha eletrônica, onde cada linha pode representar um item (como um aluno) e cada coluna pode representar uma característica (como idade ou nota). Essa organização tabular permite que os computadores processem grandes volumes de dados de forma estruturada e eficiente, o que é fundamental para o Deep Learning.

01	02	03
<b>Aluno 1</b>	<b>Aluno 2</b>	<b>Aluno N</b>
[20, 8.5, 9.2]	[21, 7.0, 8.0]	[19, 9.0, 7.5]

Considere o exemplo dos alunos novamente. Se temos 100 alunos e para cada um queremos registrar a idade, a nota de matemática e a nota de português, podemos criar uma matriz de 100 linhas por 3 colunas. Cada linha é um vetor de características de um aluno, e todas as linhas juntas formam a matriz. Essa matriz encapsula todo o nosso conjunto de dados de forma organizada.

 **Aplicação Prática:** Uma imagem em escala de cinza pode ser representada como uma matriz onde cada número corresponde à intensidade de um pixel. Se a imagem tem 100 pixels de altura por 100 pixels de largura, ela é uma matriz 100x100.

Essa coleção de vetores, quando empilhada, forma uma matriz. No Deep Learning, as matrizes são onipresentes. Além disso, os pesos e os vieses (parâmetros que a rede neural "aprende") dentro de uma rede neural são frequentemente armazenados como matrizes, permitindo que as operações matemáticas sejam realizadas de forma paralela e otimizada. A capacidade de manipular e transformar essas matrizes é o que permite que as redes neurais aprendam padrões complexos e façam previsões precisas.

# A Dimensão Extra: Tensores

Se escalares são pontos, vetores são linhas e matrizes são tabelas, o que vem depois? O mundo real é tridimensional, quadridimensional e, muitas vezes, muito mais complexo. Como representamos dados que têm mais de duas dimensões, como um vídeo (que é uma sequência de imagens), ou uma imagem colorida (que tem canais de cor)? A resposta está nos **tensores**, a generalização de todas as estruturas que vimos até agora.

## Tensor de Rank 0

Escalar - um único número

## Tensor de Rank 1

Vetor - uma lista de números

## Tensor de Rank 2

Matriz - uma tabela de números

## Tensor de Rank 3+

Arranjos multidimensionais

Um tensor é, em sua essência, um arranjo multidimensional de números. Ele pode ter qualquer número de dimensões, que chamamos de "eixos" ou "rank". Pense em um tensor como uma "caixa" que pode conter outras "caixas" dentro dela, e essas "caixas" podem conter ainda mais "caixas", e assim por diante, até chegarmos aos números individuais.

Para ilustrar, vamos pegar uma imagem colorida. Diferente de uma imagem em escala de cinza (que é uma matriz 2D de altura x largura), uma imagem colorida geralmente tem três canais: Vermelho (R), Verde (G) e Azul (B). Cada canal é, por si só, uma matriz de pixels. Então, uma imagem colorida pode ser vista como uma pilha de três matrizes, uma para cada cor. Isso forma um tensor de rank 3, com dimensões (altura, largura, canais de cor).

Imagem Colorida (Tensor 3D):

```
[  
  [[R_pixel1, R_pixel2, ...], // Matriz do canal Vermelho  
   [R_pixelN, R_pixelM, ...]],  
  [[G_pixel1, G_pixel2, ...], // Matriz do canal Verde  
   [G_pixelN, G_pixelM, ...]],  
  [[B_pixel1, B_pixel2, ...], // Matriz do canal Azul  
   [B_pixelN, B_pixelM, ...]]  
]
```

No Deep Learning, especialmente em redes neurais convolucionais (CNNs) usadas para visão computacional, os dados de entrada são quase sempre tensores. Um vídeo, por exemplo, seria um tensor de rank 4: (número de quadros, altura, largura, canais de cor). Os tensores são a forma universal de representar dados em Deep Learning, permitindo que os modelos lidem com a complexidade e a riqueza de informações do mundo real. Compreender a estrutura dos tensores é fundamental para entender como os dados fluem através das camadas de uma rede neural e como as operações são aplicadas.

# Interagindo com os Dados: Operações Fundamentais

Até agora, exploramos os "substantivos" da Álgebra Linear: escalares, vetores, matrizes e tensores, que são as formas como os dados são organizados. Mas para que a inteligência artificial possa realmente "pensar" e "aprender", esses dados precisam ser processados, transformados e combinados. É aqui que entram os "verbos" da Álgebra Linear: as operações matemáticas. Elas são as ferramentas que permitem que as redes neurais manipulem as informações, extraiam padrões e tomem decisões.

Imagine que você tem dois conjuntos de informações e precisa entender a relação entre eles, ou talvez combiná-los de uma forma específica. No Deep Learning, essa necessidade surge constantemente. Por exemplo, quando uma rede neural tenta decidir se uma imagem contém um gato, ela precisa comparar as características da imagem com os padrões que ela "aprendeu" sobre gatos. Essa comparação é feita através de operações matemáticas.

📌 **Produto Escalar:** Para dois vetores  $A = [a_1, a_2, \dots, a_n]$  e  $B = [b_1, b_2, \dots, b_n]$ , o produto escalar é  $A \cdot B = a_1 \cdot b_1 + a_2 \cdot b_2 + \dots + a_n \cdot b_n$ .

Uma das operações mais fundamentais e amplamente utilizadas é o **produto escalar** (também conhecido como produto interno ou *dot product*). Ele é uma operação entre dois vetores que resulta em um único escalar. Mas o que ele realmente nos diz? O produto escalar pode ser interpretado como uma medida de similaridade ou alinhamento entre dois vetores. Se dois vetores apontam na mesma direção, seu produto escalar será grande e positivo. Se apontam em direções opostas, será negativo. Se são perpendiculares, o produto escalar será zero.

## Exemplo prático:

Suponha que temos dois vetores de características de filmes:

- Filme A = [ação: 0.8, comédia: 0.2, drama: 0.1]
- Filme B = [ação: 0.7, comédia: 0.3, drama: 0.0]

O produto escalar Filme A · Filme B =  $(0.8 * 0.7) + (0.2 * 0.3) + (0.1 * 0.0) = 0.56 + 0.06 + 0 = 0.62$ .

**Interpretação:** Um valor de 0.62 indica uma boa similaridade entre os filmes.

No Deep Learning, o produto escalar é a base para o cálculo da ativação de um neurônio (onde os pesos são um vetor e as entradas são outro), e é crucial em mecanismos de atenção, como os encontrados na arquitetura Transformer, que revolucionou o Processamento de Linguagem Natural (PLN). Ele permite que a rede determine o quão "relevante" uma parte da entrada é para outra, um conceito central para a compreensão contextual.

# A Dança das Matrizes: Multiplicação de Matrizes

Se o produto escalar é a base para medir a relação entre dois vetores, a **multiplicação de matrizes** é a operação que permite transformar e combinar grandes conjuntos de dados de forma massiva. Esta é, sem dúvida, a operação mais importante em Deep Learning, pois ela simula o fluxo de informações através das camadas de uma rede neural. Imagine que você tem um conjunto de dados (uma matriz de entrada) e precisa aplicar um conjunto de "regras" ou "transformações" (outra matriz, geralmente de pesos) a esses dados. A multiplicação de matrizes faz exatamente isso.

## Regra Fundamental

Para multiplicar duas matrizes, o número de colunas da primeira matriz deve ser igual ao número de linhas da segunda matriz.

## Resultado

A matriz resultante terá o número de linhas da primeira e o número de colunas da segunda matriz.

A multiplicação de matrizes não é tão simples quanto multiplicar números individuais. Ela envolve uma série de produtos escalares. Pense nisso como uma "dança" coreografada: cada elemento da matriz resultante é o produto escalar de uma linha da primeira matriz por uma coluna da segunda matriz.

❏ **Exemplo:** Se temos uma matriz A (2x3) e uma matriz B (3x2):

$$A = \begin{bmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \end{bmatrix}$$

$$B = \begin{bmatrix} 7 & 8 \\ 9 & 1 \\ 2 & 3 \end{bmatrix}$$

A matriz resultante C será (2x2):

$$C[0,0] = (1*7) + (2*9) + (3*2) = 7 + 18 + 6 = 31$$

$$C[0,1] = (1*8) + (2*1) + (3*3) = 8 + 2 + 9 = 19$$

$$C[1,0] = (4*7) + (5*9) + (6*2) = 28 + 45 + 12 = 85$$

$$C[1,1] = (4*8) + (5*1) + (6*3) = 32 + 5 + 18 = 55$$

$$C = \begin{bmatrix} 31 & 19 \\ 85 & 55 \end{bmatrix}$$

No contexto do Deep Learning, a multiplicação de matrizes é o coração do que acontece em cada camada de uma rede neural. Quando os dados de entrada (representados como uma matriz ou tensor) passam por uma camada, eles são multiplicados pela matriz de pesos dessa camada. Essa operação é o que permite que a rede combine as características de entrada de maneiras complexas para aprender padrões. Por exemplo, em uma rede neural densa (ou *fully connected*), a saída de uma camada é calculada multiplicando a entrada pela matriz de pesos da camada e adicionando um vetor de vieses. Essa capacidade de realizar transformações lineares complexas é o que dá às redes neurais seu poder de modelar relações não-lineares quando combinadas com funções de ativação.

# Invertendo a Perspectiva: Transposição

No mundo da Álgebra Linear, a flexibilidade é fundamental. Muitas vezes, para que duas matrizes possam ser multiplicadas, ou para que os dados se encaixem em uma determinada operação, precisamos "reorganizar" sua estrutura. É como se você tivesse uma planilha de dados e precisasse girá-la para que as linhas se tornem colunas e as colunas se tornem linhas. Essa operação de "girar" é conhecida como **transposição**.

## Matriz Original A

$A = [[1, 2, 3], [4, 5, 6]]$  (matriz 2x3)

## Transposta $A^T$

$A^T = [[1, 4], [2, 5], [3, 6]]$  (matriz 3x2)

A transposição de uma matriz é uma operação simples, mas extremamente útil. Ela consiste em trocar as linhas pelas colunas (e vice-versa). Se você tem uma matriz A com m linhas e n colunas (uma matriz m x n), sua transposta, denotada como  $A^T$ , será uma matriz n x m. O elemento que estava na linha i e coluna j de A passará para a linha j e coluna i de  $A^T$ .

Observe como a primeira linha de A ([1, 2, 3]) se tornou a primeira coluna de  $A^T$ , e a segunda linha ([4, 5, 6]) se tornou a segunda coluna.



## Compatibilidade Dimensional

A transposição é frequentemente usada para garantir que as dimensões das matrizes sejam compatíveis para a multiplicação.



## Arquiteturas Avançadas

Em Transformers, a transposição é crucial para o cálculo de atenção, onde a similaridade entre diferentes partes da entrada é computada.



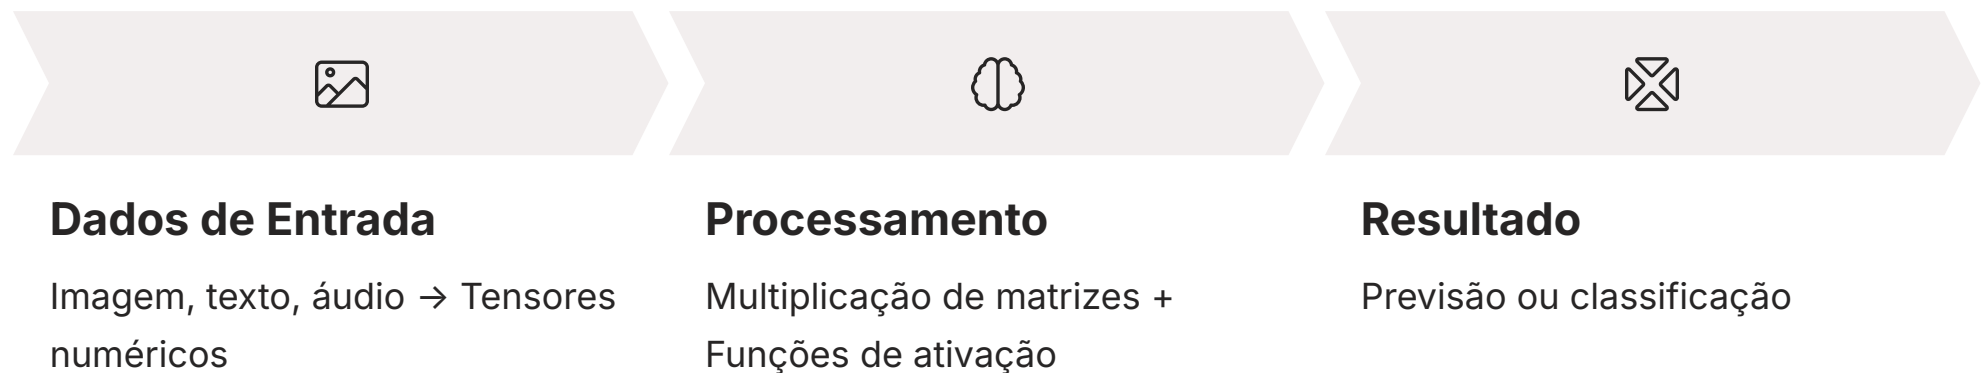
## Backpropagation

A transposição é fundamental em algoritmos de otimização para o cálculo dos gradientes durante o aprendizado.

No Deep Learning, a transposição é frequentemente usada para garantir que as dimensões das matrizes sejam compatíveis para a multiplicação. Como vimos, para multiplicar  $A * B$ , o número de colunas de A deve ser igual ao número de linhas de B. Se as dimensões não se encaixam, muitas vezes podemos transpor uma das matrizes para torná-las compatíveis. Além disso, a transposição é fundamental em algoritmos de otimização, como o *backpropagation*, que é como as redes neurais aprendem. Durante o cálculo dos gradientes (que indicam como ajustar os pesos da rede), operações envolvendo matrizes transpostas são comuns para propagar os erros de volta através da rede. É uma ferramenta matemática simples, mas indispensável para a flexibilidade e eficiência das operações em larga escala que caracterizam o Deep Learning.

# O Coração da IA: Álgebra Linear em Redes Neurais

Agora que desvendamos os blocos de construção e as operações fundamentais da Álgebra Linear, é hora de conectar os pontos e entender por que essa matemática é o verdadeiro coração do Deep Learning. Você pode ter se perguntado: "Por que eu preciso saber sobre vetores e matrizes para construir um modelo de IA que reconhece gatos?". A resposta é que, para um computador, um gato não é uma criatura fofo, mas sim um conjunto de números.



Tudo o que uma rede neural processa – seja uma imagem, um texto, um áudio ou dados tabulares – precisa ser convertido em uma representação numérica. Uma imagem, como vimos, torna-se um tensor de pixels. Um texto, após ser tokenizado, pode ser transformado em vetores numéricos (chamados *embeddings*). Esses vetores e tensores são a "linguagem" que a rede neural entende. A Álgebra Linear fornece as ferramentas para essa tradução e, mais importante, para a manipulação desses dados.

Dentro de uma rede neural, os "conhecimentos" que ela adquire são armazenados na forma de **pesos** e **vieses**, que são, por sua vez, representados como matrizes e vetores. Quando a rede recebe uma entrada (um tensor de dados), ela realiza uma série de operações de multiplicação de matrizes e adição de vetores. Essa sequência de operações é o que chamamos de **passagem para frente** (*forward pass*). Cada camada da rede pega a saída da camada anterior, multiplica-a por sua própria matriz de pesos e adiciona seu vetor de vieses, gerando uma nova representação dos dados.

- 📌 **Analogia da Linha de Montagem:** Pense em uma rede neural como uma linha de montagem em uma fábrica. Os dados de entrada são as matérias-primas. Cada "estação" na linha de montagem é uma camada da rede, equipada com "máquinas" (as matrizes de pesos) que transformam essas matérias-primas.

A compreensão da Álgebra Linear também é crucial para a **IA Explicável (XAI)**. Ao entender como os dados são representados e transformados por meio de operações matriciais, podemos começar a investigar quais partes da entrada mais influenciaram a decisão da rede, ou quais "caminhos" matemáticos levaram a um determinado resultado. Isso é vital para construir modelos mais transparentes e confiáveis, especialmente em aplicações críticas como medicina ou finanças, onde a ética em IA e a capacidade de justificar decisões são cada vez mais demandadas.

# Além do Básico: Álgebra Linear e as Tendências (Transformers)

A Álgebra Linear não é apenas a base para as redes neurais mais simples; ela é a fundação que permitiu o surgimento das arquiteturas mais avançadas e revolucionárias do Deep Learning. Uma das tendências mais impactantes dos últimos anos é a arquitetura **Transformer**, que transformou completamente o campo do Processamento de Linguagem Natural (PLN) e está se expandindo para outras áreas, como a visão computacional. E adivinhe? A Álgebra Linear está no cerne de seu funcionamento.

O grande diferencial dos Transformers é o seu mecanismo de **atenção**. Em vez de processar sequências de dados (como palavras em uma frase) de forma linear, um Transformer permite que o modelo "preste atenção" a diferentes partes da entrada simultaneamente, ponderando a importância de cada parte para a compreensão do todo. Essa capacidade de focar em relações complexas e de longo alcance é o que os torna tão poderosos.

01

## Query (Q)

Representa "o que estamos procurando"

02

## Key (K)

Representa "onde procurar"

03

## Value (V)

Representa "o que extrair"

Mas como essa "atenção" é calculada? Exatamente: através de operações de Álgebra Linear. O mecanismo de atenção é, em sua essência, uma série de produtos escalares e multiplicações de matrizes. As palavras de uma frase são transformadas em vetores (embeddings). Esses vetores são então usados para gerar três novas representações: **Query (Q)**, **Key (K)** e **Value (V)**, cada uma sendo uma matriz. A "atenção" é calculada multiplicando a matriz de Query pela transposta da matriz de Key ( $Q \cdot K^T$ ), seguida de uma normalização e, finalmente, a multiplicação pela matriz de Value. Essa sequência de operações matriciais permite que o modelo determine a "similaridade" entre cada palavra (Query) e todas as outras palavras (Key), e use essa similaridade para ponderar as informações (Value) que serão passadas adiante.

$$Atenção(Q, K, V) = Softmax(Q \cdot K^T) \cdot V$$

Essa elegante combinação de operações de Álgebra Linear é o que permite aos Transformers capturar nuances contextuais e relações complexas em dados sequenciais, algo que era muito mais difícil com arquiteturas anteriores. A capacidade de manipular e transformar tensores de forma eficiente é o que torna os Transformers escaláveis e eficazes para tarefas como tradução automática, geração de texto e até mesmo criação de imagens.

A compreensão desses fundamentos matemáticos não só o capacita a entender como essas arquiteturas funcionam, mas também a contribuir para o campo. À medida que a IA se torna mais complexa, a necessidade de **IA Explicável (XAI)** e discussões sobre **Ética em IA** se intensificam. Saber que um viés em um modelo pode ser rastreado até uma operação matricial específica ou uma representação vetorial inadequada é o primeiro passo para desenvolver soluções mais justas e transparentes. A matemática é a lente através da qual podemos inspecionar e aprimorar o futuro da inteligência artificial.

# Consolidação e Próximos Passos

Chegamos ao fim da primeira parte da nossa jornada pela matemática essencial para Deep Learning. Vimos que, por trás da complexidade aparente da inteligência artificial, existe uma base sólida e elegante de Álgebra Linear. Começamos com os blocos de construção mais simples – escalares e vetores – que nos permitem representar quantidades únicas e listas ordenadas de características. Em seguida, avançamos para as matrizes, que organizam grandes conjuntos de dados de forma tabular, e os tensores, que generalizam essa organização para múltiplas dimensões, permitindo que a IA lide com dados complexos como imagens coloridas e vídeos.

Exploramos também as operações fundamentais que dão vida a esses dados: o produto escalar, que mede a similaridade entre vetores e é crucial para a ativação de neurônios e mecanismos de atenção; a multiplicação de matrizes, a espinha dorsal do processamento de informações em camadas de redes neurais; e a transposição, uma ferramenta vital para garantir a compatibilidade dimensional e otimizar cálculos. Finalmente, conectamos tudo isso ao funcionamento das redes neurais, desde a representação de dados e parâmetros até o fluxo de informações em arquiteturas de ponta como os Transformers, e a importância da Álgebra Linear para a IA Explicável e a Ética.

## Representação de Dados

Todo dado em Deep Learning é um número, organizado em escalares, vetores, matrizes ou tensores.

## Operações Fundamentais

Produto escalar e multiplicação de matrizes são a base para o "pensamento" da IA.

## Arquiteturas Avançadas

A Álgebra Linear é fundamental para desmistificar modelos complexos como os Transformers.

## IA Explicável

A matemática é fundamental para a interpretabilidade e a ética em sistemas de IA.

## Autoavaliação

- Qual das seguintes opções representa um escalar?
  - a) [1, 2, 3]
  - b) [[1, 2], [3, 4]]
  - c) A temperatura atual de 28°C
  - d) Uma imagem RGB
- Em uma rede neural, a operação principal que ocorre quando a entrada passa por uma camada de pesos é:
  - a) Produto escalar
  - b) Transposição
  - c) Multiplicação de matrizes
  - d) Adição de vetores
- Um vídeo colorido de 10 segundos, com 30 quadros por segundo e resolução de 1920x1080 pixels, seria mais apropriadamente representado como um:
  - a) Escalar
  - b) Vetor
  - c) Matriz
  - d) Tensor de rank 4 ou superior
- O mecanismo de atenção na arquitetura Transformer utiliza intensivamente qual operação da Álgebra Linear para calcular a similaridade entre diferentes partes da entrada?
  - a) Transposição
  - b) Produto escalar
  - c) Adição de matrizes
  - d) Inversão de matrizes

**Gabarito:** 1. c) 2. c) 3. d) 4. b)

**Questão Discursiva:** Explique, com suas próprias palavras, por que a Álgebra Linear é considerada a "linguagem" fundamental do Deep Learning, citando pelo menos dois conceitos ou operações abordados nesta aula.

# Recursos e Próxima Aula

**Próxima Aula:** [Aula 4 – Matemática Essencial para Deep Learning \(Parte 2\)](#)

Na próxima aula, aprofundaremos em outros pilares matemáticos cruciais, como o Cálculo Diferencial e a Probabilidade, que são essenciais para entender como as redes neurais aprendem e otimizam seus parâmetros.



## **Khan Academy - Álgebra Linear**

Para revisar conceitos básicos com exemplos interativos.



## **"Deep Learning" por Goodfellow, Bengio e Courville**

Capítulo 2 - Para uma visão mais aprofundada e formal dos conceitos matemáticos em Deep Learning.



## **3Blue1Brown - Essência da Álgebra Linear**

YouTube - Para uma compreensão visual e intuitiva dos conceitos.

# Nota Importante

- ❏ **NOTA IMPORTANTE:** As informações técnicas desta aula estão atualizadas até 2025. Consulte sempre fontes oficiais e publicações recentes para verificar alterações e avanços na área de Deep Learning.