

Programação em Python



CEFET-MG



• Biblioteca Numpy

- O pacote fundamental para computação científica com Python.
- Código otimizado (Escrito em C)
 - Funções matemáticas e estatísticas
 - Somatório.
 - Média e desvio padrão.
 - Logaritmos.
 - Manipulação de matrizes.
 - Leitura e escrita em arquivos txt e csv.
 - Multiplicação e divisão.
 - Transposta.

- **Biblioteca Numpy**

- Matrizes (array)
 - Multi-dimensões
 - Todos os elementos do array devem ser do mesmo tipo de dados.
 - Uma vez criado, o tamanho total do array não pode mudar.
 - O formato deve ser "retangular".

- **Biblioteca Numpy**

- Matrizes (array)

- Exemplo:

```
a = np.array([[1, 2, 3],  
              [4, 5, 6]])
```

```
b = np.array([2., 2., 3.1, 4.])
```

`a[1, 1] = ?`

`a[0, 0] = ?`

`a[0, 2] = ?`

`b[0] = ?`

`a[2, 2] = ?`

`b[: 3] = ?`

`b[:-1] = ?`

`a[2:] = ?`

- **Biblioteca Numpy**

- Atributos das matrizes:

- `ndim`: número de dimensões
- `shape`: número de linhas e colunas
- `size`: número de elementos
- `dtype`: tipo de dado.

- **Biblioteca Numpy**

- Atributos das matrizes:

- Exemplo:

- `a = np.array([[1, 2, 3, 4], [5, 6, 7, 8], [9, 10, 11, 12]])`

- `a.ndim == 2`

- `a.shape == 3, 4`

- `a.size == 12`

- `a.dtype == int64`

- **Biblioteca Numpy**

- Criando matrizes:

- `a = np.zeros(2, dtype=np.int64)`: matriz de zeros, dois elementos inteiros

- **Dica: tipo booleano `np.bool_`**

- `a = np.ones(10, np.float64)`: matriz de 1's, com 10 elementos reais

- `a = np.empty()`: matriz vazia

- `a = np.arange(inicio, fim, passo)`: intervalo

- `a = np.linspace(inicio, fim, num=X)`: intervalo de X numeros linearmente espessado.

- **Biblioteca Numpy**

- Ordenação de matrizes:

- `np.sort(array)` : retorna uma cópia ordenada de mesmo *shape*.

- Ex.:

- `a = np.array([4, 3, 2, 1])`

- `b = np.array([9, 8, 7, 6, 5])`

- `np.sort(a)`

- `np.sort(b)`

- **Biblioteca Numpy**

- Concatenação de matrizes:

- `c = np.concatenate((a, b))`: retorna a concatenação de a e b

- a e b: mesma dimensão, numero diferente de elementos.

- Ex.:

- `a = np.array([4, 3, 2, 1])`

- `b = np.array([9, 8, 7, 6, 5])`

- `c = np.concatenate((a, b))`

- **Biblioteca Numpy**

- Alterando o shape da matrizes:

- `c = a.reshape(3, 2)` : retorna uma nova matriz (3, 2).

- O número de elementos deve ser o mesmo.

- Ex.:

- `a = np.arange(6)`

- `b = a.reshape(3, 2)`

- `c = a.reshape(3, 3)`

- **Biblioteca Numpy**

- Visualização condicional de elementos da matrizes:

- Pode-se visualizar elementos que atendam condições especiais.

- Ex.:

- `a = np.array([[1 , 2, 3, 4], [5, 6, 7, 8], [9, 10, 11, 12]])`

- `print(a[a < 5])`

- `five_up = (a >= 5)`

- `print(a[five_up])`

- `divisible_by_2 = a[a%2==0]`

- `print(divisible_by_2)`

- `c = a[(a > 2) & (a < 11)]`

- `print(c)`

- **Como criar uma matriz a partir de outra existente**
 - Pegando um trecho específico
 - Ex.:
 - `a = np.array([1, 2, 3, 4, 5, 6, 7, 8, 9, 10])`
 - `b = a[3:8]`
 - `c = a[:-1]`
 - `d = a[1:-1]`
 - `e = a[-4:-1]`
 - `f = a[4:-1]`

- **Como criar uma matriz a partir de outra existente**
 - Pegando um trecho específico
 - Ex.:
 - **E se alteramos o valor de `b[0]`, o que acontece com a matriz `a`?**
 - `a = np.array([1, 2, 3, 4, 5, 6, 7, 8, 9, 10])`
 - `b = a[3:8]`
 - `b[0] = 11`
 - `print(a)`
 - **Agora teste: `b = a.copy()`**

- **Como criar uma matriz a partir de outra existente**
 - Pegando um trecho específico
 - Diagonal principal
 - `x = np.diag(matriz)`
 - Preenchendo a diagonal principal
 - `np.fill_diagonal(matriz, 0)`
 - Elementos únicos (retorna uma array com elementos)
 - `y = np.unique(matriz)`

- **Como criar uma matriz a partir de outra existente**
 - Repartir utilizando a coluna
 - `np.hsplit(array, # de colunas ou colunas específicas)`
 - Ex.:
 - `x = np.arange(1, 25).reshape(2, 12)`
 - `y = np.hsplit(x, 3) # reparte x em tres matrizes de dimensões iguais`
 - `z = np.hsplit(x, (3, 4)) # Quebra x em três, até a 3 coluna, até a coluna 4, restante`

- **Exercícios**
- **Criação e Ordenação de Matrizes**
 - Crie uma matriz 5x5 de números inteiros aleatórios no intervalo de 0 a 100.
 - Ordene os elementos de cada linha dessa matriz em ordem crescente.
 - Ordene a matriz inteira com base nos valores da primeira coluna (utilize `numpy.argsort`).

- **Exercícios**

```
import numpy as np
```

```
matriz = np.random.randint(0, 101, size=(5, 5))
```

```
print(matriz)
```

```
matriz_linhas_ordenadas = np.sort(matriz, axis=1)
```

```
print(matriz_linhas_ordenadas)
```

```
indices_ordenados = np.argsort(matriz[:, 0]) # Índices ordenados pela primeira  
coluna
```

```
matriz_ordenada_por_coluna = matriz[indices_ordenados]
```

```
print(matriz_ordenada_por_coluna)
```

- **Exercícios**

- **Cópia e Modificação de Matrizes**

- Crie uma matriz 4x4 de números reais aleatórios no intervalo [0, 1].
- Faça uma cópia da matriz.
- Na matriz copiada, substitua todos os valores maiores que 0,5 pelo valor 1 e os demais por 0 (binarização da matriz).
- Exiba a matriz original e a matriz modificada.

- **Exercícios**

```
matriz = np.random.rand(4, 4)

print("Matriz original:")

print(matriz)

matriz_copiada = matriz.copy()

matriz_copiada[matriz_copiada > 0.5] = 1

matriz_copiada[matriz_copiada <= 0.5] = 0

print(matriz_copiada)
```

- **Exercícios**

- **Atributos de Matrizes**

- Crie uma matriz 3x4 contendo números inteiros de 1 a 12 e utilize os atributos do NumPy para:
 - Determinar o formato (shape) da matriz.
 - Obter o número total de elementos.
 - Identificar o tipo de dados da matriz.

- **Exercícios**

```
import numpy as np

# Criando a matriz
matriz = np.arange(1, 13).reshape(3, 4)

# Obtendo os atributos
formato = matriz.shape
num_elementos = matriz.size
tipo_dados = matriz.dtype

print("Matriz:\n", matriz)
print("Formato (shape):", formato)
print("Número de elementos:", num_elementos)
print("Tipo de dados:", tipo_dados)
```

- **Exercícios**

- **Cópias de Matrizes**

- Crie uma matriz 2×3 contendo números aleatórios entre 0 e 1. Em seguida:
 - Crie uma cópia da matriz.
 - Modifique os valores da cópia multiplicando-os por 10.
 - Verifique se a matriz original foi alterada.

- **Exercícios**

```
import numpy as np

# Criando a matriz original
matriz_original = np.random.random((2, 3))

# Criando uma cópia da matriz
matriz_copia = matriz_original.copy()

# Modificando a cópia
matriz_copia *= 10

print("Matriz Original:\n", matriz_original)
print("Cópia Modificada:\n", matriz_copia)
```

- **Exercícios**
- **Ordenação**
 - Crie uma matriz 4×4 com números inteiros aleatórios entre 1 e 50. Em seguida:
 - Ordene os elementos de cada linha.
 - Ordene os elementos de cada coluna.

• Exercícios

```
import numpy as np
```

```
# Criando a matriz
```

```
matriz = np.random.randint(1, 51, size=(4, 4))
```

```
# Ordenando por linha
```

```
matriz_linhas_ordenadas = np.sort(matriz, axis=1)
```

```
# Ordenando por coluna
```

```
matriz_colunas_ordenadas = np.sort(matriz, axis=0)
```

```
print("Matriz Original:\n", matriz)
```

```
print("Matriz com Linhas Ordenadas:\n", matriz_linhas_ordenadas)
```

```
print("Matriz com Colunas Ordenadas:\n", matriz_colunas_ordenadas)
```

- **Exercícios**

- **Manipulação de Matrizes**

- Crie uma matriz 5×5 com números inteiros aleatórios entre 10 e 100. Em seguida, faça o seguinte:
 - Extraia todos os elementos da diagonal principal da matriz.
 - Substitua os elementos da diagonal principal por 0.
 - Crie uma nova matriz contendo apenas os elementos menores do que 50 da matriz original (sem repetições) e os ordene em ordem crescente.

• Exercícios

```
import numpy as np
```

```
matriz = np.random.randint(10, 101, size=(5, 5))
```

```
# Extraíndo os elementos da diagonal principal
```

```
diagonal_principal = np.diag(matriz)
```

```
# Substituindo os elementos da diagonal principal por 0
```

```
matriz_sem_diagonal = matriz.copy()
```

```
np.fill_diagonal(matriz_sem_diagonal, 0)
```

```
elementos_menores_50 = np.unique(matriz[matriz < 50])
```

```
elementos_menores_50_ordenados =
```

```
np.sort(elementos_menores_50)
```

• Operações com matrizes

- Matriz com mesmo shape
- Elemento a elemento.
- `data = np.array([1, 2])`
- `ones = np.ones(2, dtype=int)`

`data = np.array([1, 2])`

data

1
2

`ones = np.ones(2)`


ones

1
1

- Operações com matrizes

- Soma:

- data + ones



- Operações com matrizes

- Subtração:

- data - ones

data

1
2

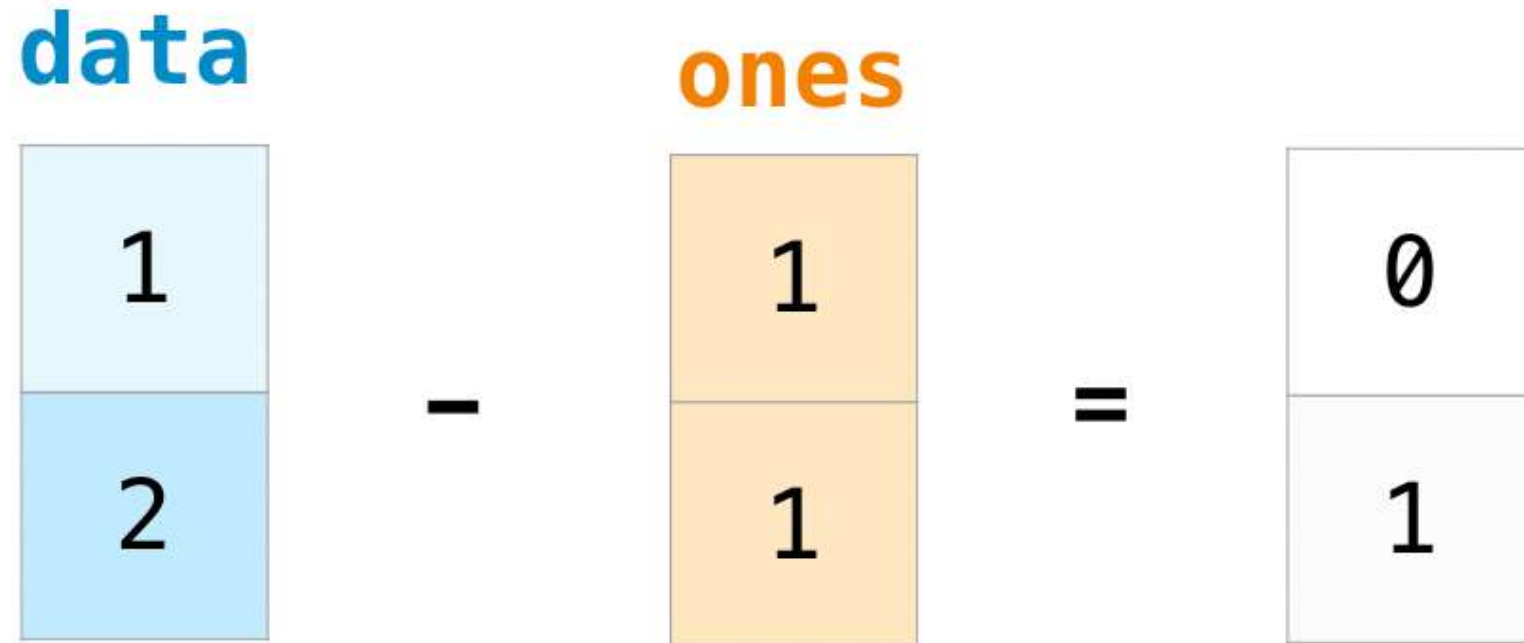
-

ones

1
1

=

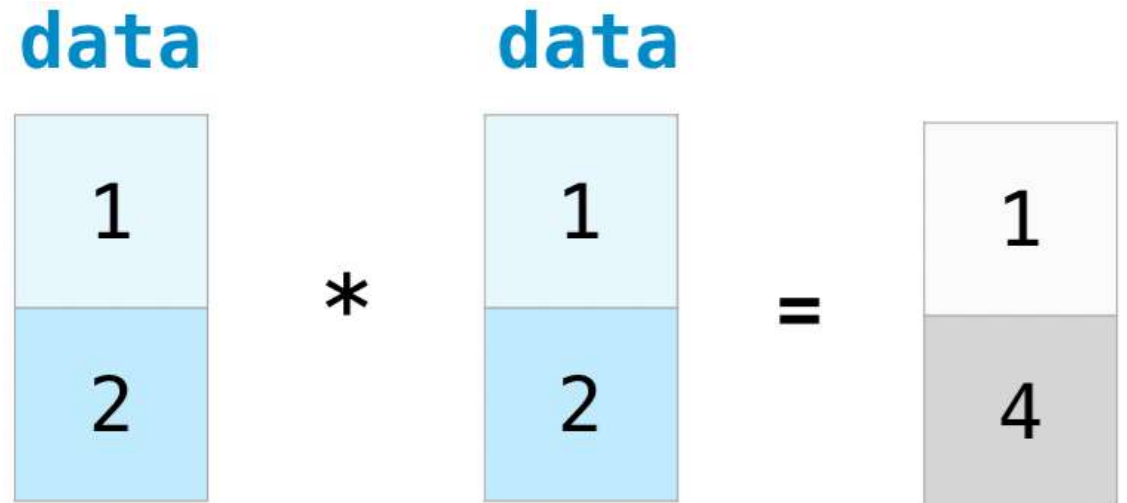
0
1



- Operações com matrizes

- Multiplicação:

- $\text{data} * \text{data}$



- Operações com matrizes

- Divisão:

- data / data

$$\begin{array}{|c|} \hline \text{data} \\ \hline 1 \\ \hline 2 \\ \hline \end{array} / \begin{array}{|c|} \hline \text{data} \\ \hline 1 \\ \hline 2 \\ \hline \end{array} = \begin{array}{|c|} \hline 1 \\ \hline 1 \\ \hline \end{array}$$

- **Operações com matrizes**

- Multiplicação entre matrizes (linhas = colunas)

- `A @ B`

- `A.dot(B)`

A

1	1
0	1

B

2	0
3	4

$1 \times 2 + 1 \times 3$	$1 \times 0 + 1 \times 4$	=	5	4
$0 \times 2 + 1 \times 3$	$0 \times 0 + 1 \times 4$		3	4

- **Operações com matrizes**

- **Somatório dos elementos**

- `a = np.array([1, 2, 3, 4])`

- `x = a.sum()`

- Somatório de um eixo específico:

- `b = np.array([[1, 1], [2, 2]])`

- `x = b.sum(axis=0)`

- **Operações com matrizes**

- **Outras funções:**

- `a = np.array([1, 2, 3, 4])`
- `x = a.max():` máximo
- `x = a.min():` mínimo
- `x = a.mean():` média
- `x = a.std():` desvio padrão

- **Exercícios**

- Cálculo da Média e Desvio Padrão (Estatística de Dados): No monitoramento de sensores industriais, é comum calcular estatísticas para identificar anomalias em medições. Um sensor registra as temperaturas de uma máquina ao longo do dia. As medições estão armazenadas em um array NumPy:
 - `temperaturas = np.array([22.4, 23.1, 22.8, 23.0, 22.7, 22.9, 23.2, 22.7, 23.1, 23.6])`
 - Calcule a média das temperaturas.
 - Calcule o desvio padrão das temperaturas.
 - Plot um gráfico boxplot e verifique se existe algum outlier.

```
import numpy as np
import matplotlib.pyplot as plt

# Dados de temperatura
temperaturas = np.array([22.4, 23.1, 22.8, 23.0, 22.7, 22.9, 23.2, 22.7, 23.1, 23.6])

# Cálculo da média
media = np.mean(temperaturas)
print(f"Média das temperaturas: {media:.2f} °C")

# Cálculo do desvio padrão
desvio_padrao = np.std(temperaturas)
print(f"Desvio padrão das temperaturas: {desvio_padrao:.2f} °C")

# Plot do boxplot
plt.figure(figsize=(6,4))
plt.boxplot(temperaturas)
plt.title("Boxplot das Temperaturas do Sensor")
plt.ylabel("Temperatura (°C)")
plt.grid(True)
plt.show()
```

- **Exercícios**

- A soma de matrizes é usada em processamento de imagens, por exemplo, ao combinar filtros aplicados a uma imagem. Considere duas matrizes que representam partes processadas de uma imagem:
 - `A = np.array([[1, 2, 3], [4, 5, 6], [7, 8, 9]])`
 - `B = np.array([[9, 8, 7], [6, 5, 4], [3, 2, 1]])`
- Escreva um programa que utilize NumPy para somar as matrizes somente

```
import numpy as np

# Matrizes da imagem
A = np.array([[1, 2, 3],
              [4, 5, 6],
              [7, 8, 9]])

B = np.array([[9, 8, 7],
              [6, 5, 4],
              [3, 2, 1]])

# Soma das matrizes
C = A + B

print("\nSoma das Matrizes (A + B):")
print(C)
```

- **Matriz transposta**

- `a = np.array([1, 2, 3, 4],
 [4, 5, 6, 7])`
- `x = a.transpose()`
- `x = a.T`
- `x = a.reshape(4, 2)` **# a: 2 x 4**

- **Matriz Inversa**

```
np.linalg.inv(matriz)
```

Ex.:

```
a = np.array([[1, 2, 3, 4], [4, 5, 6, 7]])
```

try:

```
    a_inversa = np.linalg.inv(a)
```

```
except np.linalg.LinAlgError: print("A matriz não é inverssível (determinante é zero).")
```

- **Determinante da Matriz**

```
np.linalg.det(matriz)
```

Ex.:

```
a = np.array([[1, 2, 3, 4], [4, 5, 6, 7]])
```

```
x = np.linalg.det(a)
```

- **Solução de sistemas lineares**

- **Seja o sistema $Ax = B$**

- A matriz quadrada.
- B é o vetor (ou matriz) de termos constantes
- x é o vetor (ou matriz) de incógnitas que será calculado.
- `x = np.linalg.solve(A, B)`

• Interpolação

- Dado um conjunto de dados.
- Ajuste um polinômio de grau n : $P(x) = a_n x^n + a_{n-1} x^{n-1} + \dots + a_1 x^1 + a_0$.
 - `np.polyfit(x, y, n)`
 - `x`: Array dos valores das variáveis independentes.
 - `y`: Array dos valores das variáveis dependentes.
 - `deg`: Grau do polinômio que você deseja ajustar.
 - `w` (opcional): Pesos a serem aplicados aos dados, para dar mais relevância a certos pontos.

• Interpolação

- Dado um conjunto de dados.
- Ajuste um polinômio de grau n : $P(x) = a_n x^n + a_{n-1} x^{n-1} + \dots + a_1 x^1 + a_0$.
- Previsões futuras
 - `coef = np.polyfit(x, y, n)`
 - `previsão = np.polyval (coef, prev)`
 - `prev`: valor para o qual deve-se fazer a previsão.

- **Lendo e escrevendo em arquivos**

- Arquivos Numpy (Mais eficiente)

- Arquivo npy: Armazena um único array em um arquivo binário.

- Arquivo npz: múltiplos arrays em um único arquivo compactado.

- `np.save('filename', matriz)` **# Salva em um arquivo npy**

- `np.savez('filename', matriz1, matriz2)` **# Salva em um arquivo npz**

- `np.load('filename')` **# Lê matriz do arquivo npz ou npy**

- **Lendo e escrevendo em arquivos**

- Ex.:

```
a = np.array([[1, 1, 1], [2, 2, 2], [3, 3, 3], [4, 4, 4]])
```

```
np.save("matriz.npy",a)
```

```
b = np.load("matriz.npy")
```

```
print(b)
```

- **Lendo e escrevendo em arquivos**

- Ex.:

```
a = np.array([[1, 1, 1], [2, 2, 2], [3, 3, 3], [4, 4, 4]])
```

```
b = np.array([[0, 0, 0], [0, 0, 0], [5, 5, 5], [6, 6, 6]])
```

```
np.savez("matriz.npz",a, b)
```

```
dados = np.load("matriz.npz")
```

```
c = dados['arr_0'] #'arr_0': nome padrão (quando não explicitado)
```

```
d = dados['arr_1'] #'arr_1': nome padrão (quando não explicitado)
```

```
print(c)
```

```
print(d)
```

- **Lendo e escrevendo em arquivos**

- Ex.:

```
a = np.array([[1, 1, 1], [2, 2, 2], [3, 3, 3], [4, 4, 4]])
```

```
b = np.array([[0, 0, 0], [0, 0, 0], [5, 5, 5], [6, 6, 6]])
```

```
np.savez("matriz.npz", m1=a, m2=b) #m1 e m2: nomes explícitos
```

```
dados = np.load("matriz.npz")
```

```
c = dados['m1']
```

```
d = dados['m2']
```

```
print(c)
```

```
print(d)
```

- **Lendo e escrevendo em arquivos**

- Arquivos texto (.txt ou .csv)

- `np.savetxt('filename', matriz)` **#Uma matriz por arquivo**

- `np.loadtxt('filename')` **#Todo o conteúdo: matriz única**

Para .csv: melhor usar o Pandas

- **Lendo e escrevendo em arquivos**

- Ex.:

```
a = np.array([[1, 1, 1], [2, 2, 2], [3, 3, 3], [4, 4, 4]])
```

```
b = np.array([[0, 0, 0], [0, 0, 0], [5, 5, 5], [6, 6, 6]])
```

```
np.savetxt("matriza.txt",a)
```

```
np.savetxt("matrizb.txt",b)
```

```
c = np.loadtxt("matriza.txt")
```

```
d = np.loadtxt("matrizb.txt")
```

```
print(c)
```

```
print(d)
```

- **Lendo e escrevendo em arquivos**

- Ex.:

```
a = np.array([[1, 1, 1], [2, 2, 2], [3, 3, 3], [4, 4, 4]])
```

```
b = np.array([[0, 0, 0], [0, 0, 0], [5, 5, 5], [6, 6, 6]])
```

```
np.savetxt("matriza.csv",a)
```

```
np.savetxt("matrizb.csv",b)
```

```
c = np.loadtxt("matriza.csv")
```

```
d = np.loadtxt("matrizb.csv")
```

```
print(c)
```

```
print(d)
```

- **Outras funções do Numpy**

- **Funções Trigonômicas**

- `np.sin(x)` – Calcula o seno.
- `np.cos(x)` – Calcula o cosseno.
- `np.tan(x)` – Calcula a tangente.
- `np.arcsin(x)` – Calcula o arco-seno (seno inverso).
- `np.arccos(x)` – Calcula o arco-cosseno (cosseno inverso).
- `np.arctan(x)` – Calcula o arco-tangente (tangente inversa).
- `np.hypot(x, y)` – Calcula a hipotenusa de x e y.
- `np.deg2rad(x)` – Converte graus para radianos.
- `np.rad2deg(x)` – Converte radianos para graus.

- **Outras funções do Numpy**

- **Funções Exponenciais e Logarítmicas**

- `np.exp(x)` – Calcula e^x para cada elemento.
- `np.log(x)` – Calcula o logaritmo natural de x .
- `np.log10(x)` – Calcula o logaritmo base 10.
- `np.log2(x)` – Calcula o logaritmo base 2.
- `np.power(base, expoente)` – Calcula $base^{expoente}$.

- **Outras funções do Numpy**

- **Funções de Arredondamento**

- `np.round(x, decimals=n)` – Arredonda para n casas decimais.
- `np.floor(x)` – Arredonda para baixo.
- `np.ceil(x)` – Arredonda para cima.
- `np.trunc(x)` – Trunca os valores (remove a parte decimal).
- `np rint(x)` – Retorna o inteiro mais próximo.

- **Outras funções do Numpy**

- **Funções de Distribuições Aleatórias (usando `numpy.random`)**

- `np.random.uniform(low, high, size)` – Gera valores aleatórios uniformemente em um intervalo.

- `np.random.normal(mean, std, size)` – Gera valores de uma distribuição normal com média e desvio padrão especificados.

- **Exercícios**

- Movimentos aleatórios, como o passeio aleatório, são usados para modelar partículas em física ou movimentos financeiros.
- Simule o movimento aleatório de uma partícula em uma linha reta por 100 passos, onde cada passo é +1 ou -1, com igual probabilidade. Plote o deslocamento cumulativo.
- **Dica use:** `np.random.choice()` para descrever o caminho.
`np.cumsum()` para o deslocamento cumulativo

- **Exercícios**

```
import numpy as np
import matplotlib.pyplot as plt

np.random.seed(42) # Para resultados reproduzíveis

passos = np.random.choice([-1, 1], size=100)
deslocamento = np.cumsum(passos)

plt.plot(deslocamento)
plt.title("Movimento Aleatório")
plt.xlabel("Passos")
plt.ylabel("Deslocamento")
plt.grid()
plt.show()
```

- **Exercícios**

- Converter imagens para tons de cinza é um passo comum em análise de imagens. Dada uma matriz representando uma imagem colorida em formato 3 x 3, onde cada célula contém valores RGB:

```
imagem = np.array([  
    [[100, 150, 200], [50, 100, 150], [200, 250, 100]],  
    [[150, 200, 50], [100, 50, 200], [250, 150, 50]],  
    [[200, 100, 150], [50, 200, 250], [150, 50, 100]]  
])
```

- Converta a imagem para tons de cinza usando a fórmula:
 - Cinza= $0.2989R + 0.5870G + 0.1140B$

- **Exercícios**

```
import numpy as np
```

```
imagem = np.array([  
    [[100, 150, 200], [50, 100, 150], [200, 250, 100]],  
    [[150, 200, 50], [100, 50, 200], [250, 150, 50]],  
    [[200, 100, 150], [50, 200, 250], [150, 50, 100]]  
])
```

```
cinza = 0.2989 * imagem[:, :, 0] + 0.5870 * imagem[:, :, 1] + 0.1140 *  
imagem[:, :, 2]
```

```
print("Imagem em tons de cinza:")  
print(cinza)
```

• Exercícios

• Um engenheiro da computação está analisando um circuito elétrico que contém três malhas interligadas. Cada malha tem resistores e uma fonte de tensão, e as correntes I_1 , I_2 , e I_3 precisam ser determinadas usando as Leis de Kirchhoff.

• Esquema do Circuito:

• Malha 1: $5I_1 + 2I_2 = 10$ (tensão da fonte é 10V).

• Malha 2: $2I_1 + 4I_2 - I_3 = 12$ (tensão da fonte é 12V).

• Malha 3: $-I_2 + 3I_3 = 5$ (tensão da fonte é 5V).

• Determine o valor das correntes I_1 , I_2 , e I_3 .

```
import numpy as np

A = np.array([[5, 2, 0],
              [2, 4, -1],
              [0, -1, 3]], dtype=float)

b = np.array([10, 12, 5], dtype=float)

I = np.linalg.solve(A, b)

print("I1 = {:.6f} A".format(I[0]))
print("I2 = {:.6f} A".format(I[1]))
print("I3 = {:.6f} A".format(I[2]))

# Verificação (resíduo)
residuo = A.dot(I) - b
print("\nResíduo (deve ser ~0):", residuo)
```

• Exercícios

- A geração de sinais aleatórios é usada em simulações de ruídos em comunicações ou modelos financeiros.
- Gere um vetor de 100 valores aleatórios seguindo uma distribuição normal com média 0 e desvio padrão 1.
- Calcule a média e o desvio padrão dos valores gerados.

```
import numpy as np
```

```
# Geração do vetor com 100 valores de distribuição normal (média=0,  
desvio=1)
```

```
valores = np.random.normal(loc=0, scale=1, size=100)
```

```
# Cálculo da média e do desvio padrão
```

```
media = np.mean(valores)
```

```
desvio = np.std(valores)
```

```
print("Média dos valores gerados:", media)
```

```
print("Desvio padrão dos valores:", desvio)
```

• Exercícios

- Antes de alimentar um modelo de aprendizado de máquina, é comum normalizar os dados para melhorar a performance.
- Dado o vetor de dados:
 - `dados = np.array([50, 60, 70, 80, 90])`
- Normalize os dados para que fiquem no intervalo [0, 1]

$$x_{norma} = \frac{x - x_{min}}{x_{max} - x_{min}}$$

```
import numpy as np
```

```
dados = np.array([50, 60, 70, 80, 90])
```

```
# Normalização Min-Max
```

```
min_val = np.min(dados)
```

```
max_val = np.max(dados)
```

```
dados_normalizados = (dados - min_val) / (max_val - min_val)
```

```
print("Dados normalizados:", dados_normalizados)
```

- **Exercícios**

- Um aluno está trabalhando na análise estrutural de um sistema de treliças simples. O sistema é composto por três barras interconectadas, formando um triângulo, onde forças atuam nos nós. O objetivo é determinar as forças internas em cada barra usando métodos de álgebra linear.
- Um nó de treliça está sujeito a:
 - Uma força horizontal de 100 N à direita.
 - Uma força vertical de 200 N para baixo.

• Exercícios

- As forças nas barras F_1 , F_2 , e F_3 precisam ser determinadas para que o sistema esteja em equilíbrio (somatório das forças é zero).
- As equações de equilíbrio resultantes são:
 - $F_1 \cos(30) + F_2 - 100 = 0$ (equilíbrio na direção x).
 - $F_1 \sin(30) + F_3 - 200 = 0$ (equilíbrio na direção yy).
 - $F_3 - F_2 = 0$ (equilíbrio no nó).
- Resolva o sistema de equações

```
import numpy as np

# Ângulos em radianos
cos30 = np.cos(np.deg2rad(30))
sin30 = np.sin(np.deg2rad(30))

# Matriz do sistema
A = np.array([
    [cos30, 1, 0],
    [sin30, 0, 1],
    [0, -1, 1]
], dtype=float)

# Vetor de termos independentes
b = np.array([100, 200, 0], dtype=float)

# Solução do sistema
F = np.linalg.solve(A, b)

F1, F2, F3 = F

print("F1 =", F1)
print("F2 =", F2)
print("F3 =", F3)
```

• Exercícios

- Um engenheiro da computação está desenvolvendo um sistema para analisar dados coletados por um sensor de temperatura que registra medições a cada segundo por 1 minuto. O objetivo é realizar operações estatísticas para identificar padrões e possíveis anomalias.
- Gere 60 valores aleatórios entre 20°C e 30°C para simular as leituras do sensor.
- Calcule a média, mediana e desvio padrão das temperaturas.
- Calcule a temperatura máxima e mínima registradas.
- Identifique quantas leituras estão fora de 2σ da média (dois desvios-padrão).
- Plote um gráfico simples (usando matplotlib) para visualizar as leituras

```
import numpy as np
import matplotlib.pyplot as plt

# Gerando dados simulados de temperatura
temperaturas = np.random.uniform(20, 30, 60)

# Estatísticas básicas
media = np.mean(temperaturas)
mediana = np.median(temperaturas)
desvio_padrao = np.std(temperaturas)
max_temp = np.max(temperaturas)
min_temp = np.min(temperaturas)

# Identificando leituras fora de  $2\sigma$ 
fora_2sigma = np.sum((temperaturas < media - 2 *
    desvio_padrao) | (temperaturas > media
    + 2 * desvio_padrao))
```

```
# Exibindo os resultados
print(f"Média: {media:.2f}°C")
print(f"Mediana: {mediana:.2f}°C")
print(f"Desvio padrão: {desvio_padrao:.2f}°C")
print(f"Temperatura máxima: {max_temp:.2f}°C")
print(f"Temperatura mínima: {min_temp:.2f}°C")
print(f"Leituras fora de  $2\sigma$ : {fora_2sigma}")

# Gráfico opcional
plt.plot(temperaturas, marker='o', label=
    "Temperaturas")
plt.axhline(media, color='red', linestyle='--',
    label="Média")
plt.xlabel("Tempo (segundos)")
plt.ylabel("Temperatura (°C)")
plt.legend()
plt.show().
```

• Exercícios


- A população de uma cidade cresce ao longo dos anos de acordo com os seguintes dados:
 - Ano=[2000, 2005, 2010, 2015, 2020, 2025]
 - População=[50000, 60000, 72000, 85000, 100000, 120000]
- Ajuste um polinômio de grau 3 aos dados fornecidos e Use o modelo para prever a população em 2030.
- Plote os dados originais como pontos.
- Plote a curva ajustada no intervalo de 2000 a 2030.
- Indique no gráfico a previsão para o ano de 2030.
- Discuta se o modelo ajustado parece adequado para prever valores futuros.

```
anos = np.array([2000, 2005, 2010, 2015, 2020, 2025])
populacao = np.array([50000, 60000, 72000, 85000,
100000, 120000])
# Ajuste de polinômio (grau 3)
coef = np.polyfit(anos, populacao, 3)
# Extensão até 2030
anos_ext = np.arange(2000, 2031)
pop_pred = np.polyval(coef, anos_ext)
# Previsão para 2030
pop_2030 = np.polyval(coef, 2030)
print(f"População estimada para 2030: {pop_2030:.2f}")
```

```
plt.scatter(anos, populacao, color='blue',
label='Dados Reais')
plt.plot(anos_ext, pop_pred, color='red',
label='Modelo (Grau 3)')
plt.axvline(2030, color='green', linestyle='--',
label='Ano 2030')
plt.scatter(2030, pop_2030, color='purple',
label=f'Previsão: {pop_2030:.0f}')
plt.title("Modelagem de Crescimento
Populacional")
plt.xlabel("Ano")
plt.ylabel("População")
plt.legend()
plt.grid(True)
plt.show()
```

• Exercícios

Grafo bipartido, é um grafo em que os vértices podem ser divididos em dois conjuntos disjuntos, de forma que cada aresta conecte um vértice de um conjunto a um vértice do outro, como na imagem.



Verifique se o grafo representado pela matriz de adjacência abaixo é bipartido:

- `grafo = np.array([[0, 1, 0, 1], [1, 0, 1, 0], [0, 1, 0, 1], [1, 0, 1, 0]])`

```
import numpy as np
```

```
grafo = np.array([
    [0, 1, 0, 1],
    [1, 0, 1, 0],
    [0, 1, 0, 1],
    [1, 0, 1, 0]
], dtype=int)
```

```
def eh_bipartido(adj):
```

```
    n = adj.shape[0]
```

```
    color = [-1] * n # -1 = não colorido
```

```
    for start in range(n):
```

```
        if color[start] != -1:
```

```
            continue
```

```
        # Usando lista como fila
```

```
        fila = [start]
```

```
        color[start] = 0
```

```
        while fila:
```

```
            u = fila.pop(0) # remove o primeiro elemento
```

```
            for v in range(n):
```

```
                if adj[u, v] == 0:
```

```
                    continue
```

```
                if color[v] == -1:
```

```
                    color[v] = 1 - color[u]
```

```
                    fila.append(v)
```

```
                elif color[v] == color[u]:
```

```
                    return False, None
```

```
    part0 = [i for i in range(n) if color[i] == 0]
```

```
    part1 = [i for i in range(n) if color[i] == 1]
```

```
    return True, (part0, part1)
```

```
bip, partes = eh_bipartido(grafo)
```

```
print("É bipartido?", bip)
```

```
if bip:
```

```
    print("Partições:", partes)
```

- Na construção de uma rede neural, uma função de ativação comum é a **sigmoid**. Um engenheiro precisa calcular a saída da sigmoid para diferentes valores de entrada (pesos e bias).
 - Crie um array com 50 valores igualmente espaçados entre -10 e 10.
 - Implemente a função sigmoid: $sigmoid = 1/(1 + e^{-x})$
 - Calcule o valor da sigmoid para cada entrada.
 - Determine os valores de entrada para os quais a saída está acima de 0.9.
 - Plote o gráfico da função sigmoid.

```
import numpy as np
import matplotlib.pyplot as plt
```

1. Criar array com 50 valores de -10 a 10

```
x = np.linspace(-10, 10, 50)
```

2. Função sigmoid

```
def sigmoid(x):
```

```
    return 1 / (1 + np.exp(-x))
```

3. Calcular valores da sigmoid

```
y = sigmoid(x)
```

4. Determinar valores de entrada cuja saída > 0.9

```
indices_acima_09 = np.where(y > 0.9)[0]
```

```
valores_acima_09 = x[indices_acima_09]
```

```
print("Valores de entrada para os quais a  
sigmoid > 0.9:")
```

```
print(valores_acima_09)
```

5. Plotar gráfico da sigmoid

```
plt.plot(x, y)
```

```
plt.title("Função Sigmoid")
```

```
plt.xlabel("x")
```

```
plt.ylabel("sigmoid(x)")
```

```
plt.grid(True)
```

```
plt.show()
```

- **DESAFIO: enviar para SIGAA**

- O algoritmo de Dijkstra é usado para encontrar o caminho mais curto em grafos ponderados, como em mapas de rotas. Dado o grafo representado pela matriz de adjacência ponderada:

```
grafo = np.array([[0, 10, 0, 30, 100], [10, 0, 50, 0, 0], [0, 50, 0, 20, 10], [30, 0, 20, 0, 60], [100, 0, 10, 60, 0] ])
```

- Implemente o algoritmo de Dijkstra para encontrar o menor caminho do nó 0 para todos os outros nós.

```
import numpy as np
```

```
# Grafo dado
```

```
grafo = np.array([  
    [0, 10, 0, 30, 100],  
    [10, 0, 50, 0, 0],  
    [0, 50, 0, 20, 10],  
    [30, 0, 20, 0, 60],  
    [100, 0, 10, 60, 0]  
])
```

```
def dijkstra(grafo, origem):
    n = grafo.shape[0]
    visitado = np.zeros(n, dtype=bool)

    # Inicializa distâncias com infinito
    distancia = np.full(n, np.inf)
    distancia[origem] = 0

    for _ in range(n):
        # Seleciona o nó não visitado com menor distância
        u = np.argmin(np.where(visitado, np.inf, distancia))
        visitado[u] = True

        # Atualiza as distâncias dos vizinhos
        for v in range(n):
            peso = grafo[u, v]
            if peso > 0 and not visitado[v]:
                nova_distancia = distancia[u] + peso
                if nova_distancia < distancia[v]:
                    distancia[v] = nova_distancia

    return distancia
```

```
# Executando Dijkstra a partir do nó 0  
dist = dijkstra(grafo, 0)  
print("Menores distâncias a partir do nó 0:")  
print(dist)
```