

EDOS: métodos numéricos

Prof. Doherty Andrade

1. Método de Euler

O Método de Euler é o mais simples método numérico, mas é também o menos preciso.

O método de Euler é um método de discretização onde o domínio é dividido em n partes iguais a h , h é chamado o passo de discretização.

Se o domínio é o intervalo $[a, b]$, então discretizamos o domínio tomando $(n + 1)$ pontos igualmente espaçados do domínio dados por $x_j = a + jh$, $j = 0, 1, \dots, n$, em que $h = \frac{b-a}{n}$ é o passo de discretização. Note que $x_0 = a$ e $x_n = b$.

Consideremos o seguinte problema de valor inicial

$$y' = f(x, y(x)),$$

com $y(x_0) = y_0$.

O método de Euler gera aproximações dadas por

$$y(x_{k+1}) = y_k + hf(x_k, y_k), k \geq 0.$$

Note que y_{k+1} usa apenas o valor de y_k , isto é, a solução aproximada y_{k+1} para ser determinada necessita apenas y_k , a aproximação imediatamente anterior. Estes métodos são chamados de métodos de passo simples ou passo únicos ou passo un. les ou passo um.

Exemplo: Considere o pvi dado por

$$y' = x + y$$

com

$$y(0) = 1.$$

Observe que a solução exata é $y(x) = 2e^x - x - 1$.

```
In [11]: #euler com tabela
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt

def euler(f, x0, y0, h, n):
    """
    Método de Euler para resolver EDOS numericamente.

    Parâmetros:
        f - Função f(x, y) que define a EDO dy/dx = f(x, y)
    """

    # Criação de uma estrutura de dados para armazenar os resultados
    df = pd.DataFrame()
    df['x'] = np.linspace(x0, x0 + (n + 1) * h, n + 2)
    df['y'] = np.zeros(n + 2)

    # Inicialização dos valores iniciais
    df['y'][0] = y0

    # Aplicação do método de Euler
    for i in range(1, n + 1):
        df['y'][i] = df['y'][i - 1] + h * f(df['x'][i], df['y'][i])

    return df
```

```

x0 - Valor inicial de x
y0 - Valor inicial de y
h - Passo do método
n - Número de passos

Retorna:
    xs - Lista de valores de x
    ys - Lista de valores de y correspondentes
"""
xs = np.zeros(n+1)
ys = np.zeros(n+1)

xs[0], ys[0] = x0, y0

for i in range(n):
    ys[i+1] = ys[i] + h * f(xs[i], ys[i])
    xs[i+1] = xs[i] + h

return xs, ys

# Definição da EDO: dy/dx = f(x, y)
def f(x, y):
    return x + y # Exemplo: dy/dx = x + y

# Parâmetros iniciais
x0 = 0
y0 = 1 # y(0) = 1
h = 0.1 # Tamanho do passo
n = 20 # Número de passos

# Resolver a EDO usando Euler
xs, ys = euler(f, x0, y0, h, n)

# Criar um DataFrame com os valores calculados
df = pd.DataFrame({'x': xs, 'y': ys})

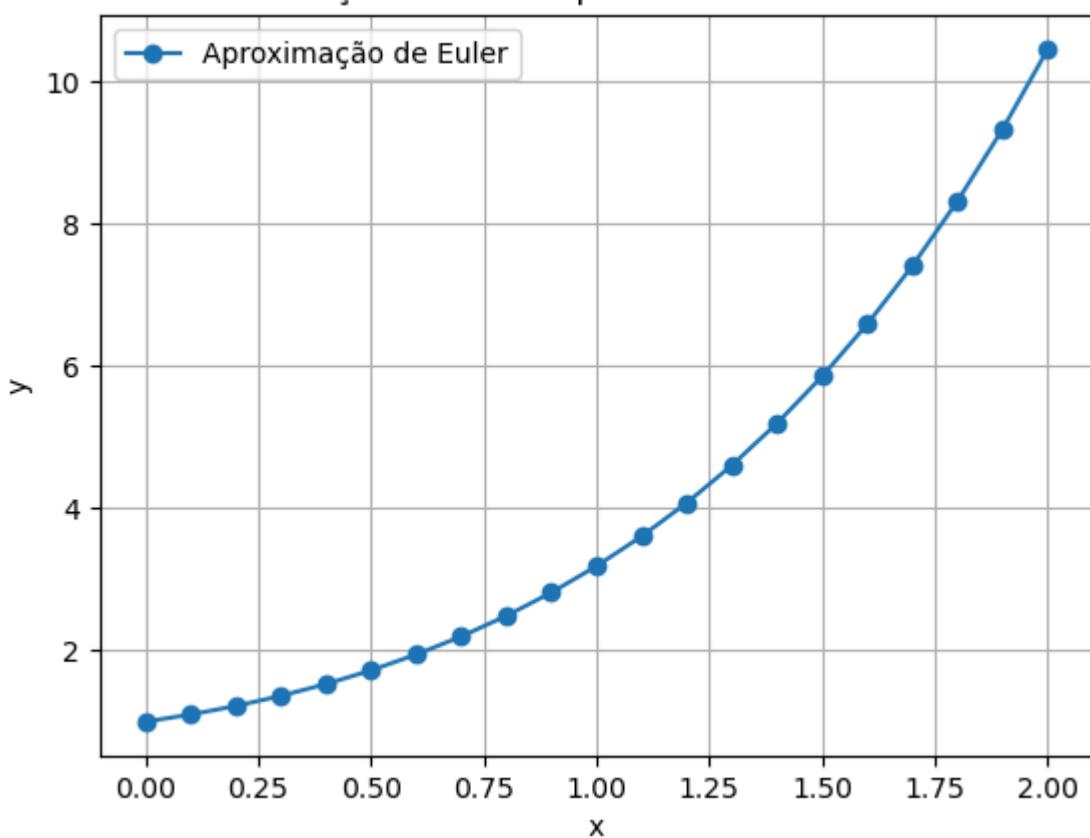
# Exibir a tabela
print(df.to_string(index=False))

# Plotar a solução
plt.plot(xs, ys, label="Aproximação de Euler", marker='o', linestyle='--')
plt.xlabel("x")
plt.ylabel("y")
plt.title("Solução Numérica pelo Método de Euler")
plt.legend()
plt.grid()
plt.show()

```

x	y
0.0	1.000000
0.1	1.100000
0.2	1.220000
0.3	1.362000
0.4	1.528200
0.5	1.721020
0.6	1.943122
0.7	2.197434
0.8	2.487178
0.9	2.815895
1.0	3.187485
1.1	3.606233
1.2	4.076857
1.3	4.604542
1.4	5.194997
1.5	5.854496
1.6	6.589946
1.7	7.408941
1.8	8.319835
1.9	9.331818
2.0	10.455000

Solução Numérica pelo Método de Euler



2. O método de Runge-Kutta de ordem 2

Os métodos de Runge-Kutta de ordem 2 têm a forma geral dada por

$$y_{n+1} = y_n + ha_1 f(x_n, y_n) + ha_2 f(x_n + b_1 h, y_n + b_2 h y')$$

Tomando $a_1 = \frac{1}{2}$ e $b_1 = b_2 = 1$, obtemos o método de Euler melhorado ou Heun,

$$y_{k+1} = y_k + \frac{h}{2}[f(x_k, y_k) + f(x_k + h, y_k + hf(x_k, y_k))].$$

O exemplo é mesmo que o anterior.

```
In [5]: # runge - kutta 2 com tabela
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt

def runge_kutta2(f, x0, y0, h, n, exact_solution=None):
    """
    Método de Runge-Kutta de 2ª ordem para resolver EDOs numericamente.

    Parâmetros:
        f - Função f(x, y) que define a EDO dy/dx = f(x, y)
        x0 - Valor inicial de x
        y0 - Valor inicial de y
        h - Passo do método
        n - Número de passos
        exact_solution - (Opcional) Função da solução exata para cálculo do erro

    Retorna:
        DataFrame contendo xs, ys, K1, K2 e erro (se exata for fornecida)
    """
    xs = np.zeros(n+1)
    ys = np.zeros(n+1)
    k1_vals = np.zeros(n)
    k2_vals = np.zeros(n)
    errors = np.zeros(n+1) if exact_solution else None

    xs[0], ys[0] = x0, y0
    if exact_solution:
        errors[0] = abs(ys[0] - exact_solution(xs[0]))

    for i in range(n):
        k1 = f(xs[i], ys[i])
        k2 = f(xs[i] + h, ys[i] + h * k1)
        ys[i+1] = ys[i] + (h * k2)
        xs[i+1] = xs[i] + h

        k1_vals[i] = k1
        k2_vals[i] = k2

        if exact_solution:
            errors[i+1] = abs(ys[i+1] - exact_solution(xs[i+1]))

    # Criar um DataFrame com os valores calculados
    data = {
        'x_k': xs,
        'y_k': ys,
        'K_1': np.append(k1_vals, np.nan),
        'K_2': np.append(k2_vals, np.nan),
    }
    if exact_solution:
        data['Erro'] = errors

    df = pd.DataFrame(data)
```

```

    return df, xs, ys

# Definição da EDO: dy/dx = f(x, y)
def f(x, y):
    return x + y # Exemplo: dy/dx = x + y

# Definição da solução exata para erro (caso seja conhecida)
def exact_solution(x):
    return 2 * np.exp(x) - x - 1 # Solução exata da EDO dy/dx = x + y com y(0)

# Parâmetros iniciais
x0 = 0
y0 = 1 # y(0) = 1
h = 0.1 # Tamanho do passo
n = 20 # Número de passos

# Resolver a EDO usando Runge-Kutta de 2ª ordem e calcular a tabela
df, xs, ys = runge_kutta2(f, x0, y0, h, n, exact_solution)

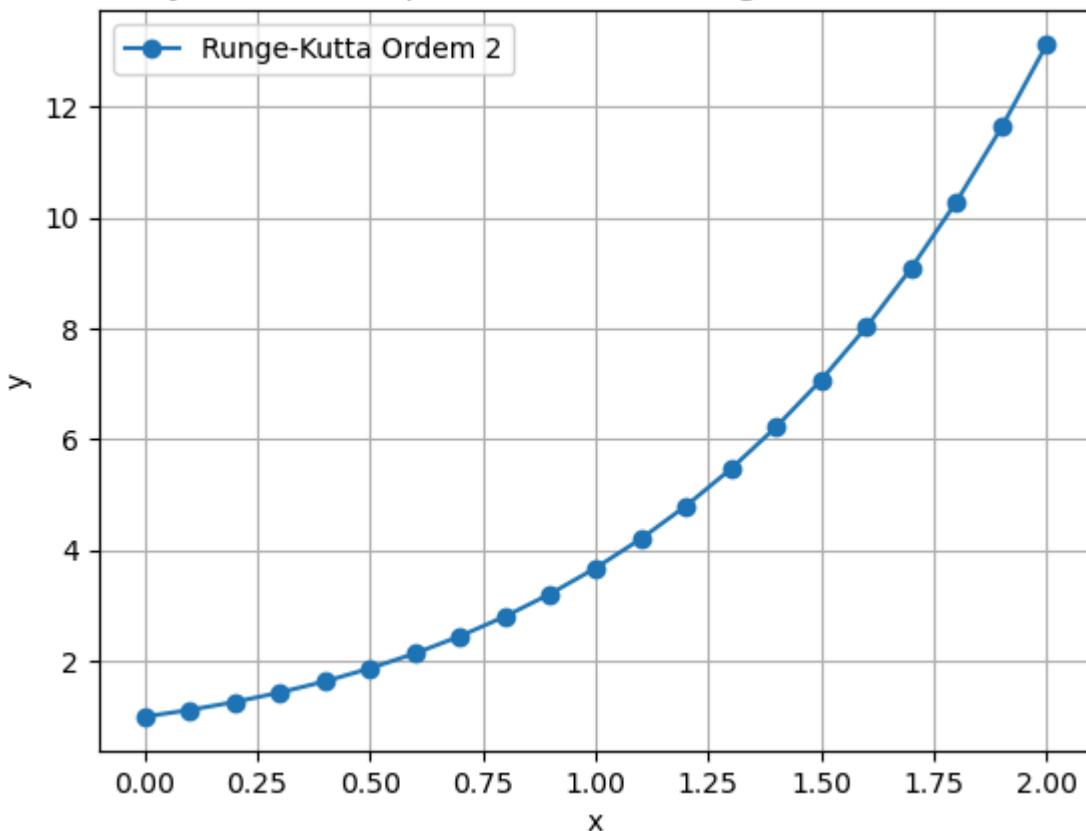
# Exibir a tabela
print(df.to_string(index=False))

# Plotar a solução
plt.plot(xs, ys, label="Runge-Kutta Ordem 2", marker='o', linestyle='--')
plt.xlabel("x")
plt.ylabel("y")
plt.title("Solução Numérica pelo Método de Runge-Kutta de 2ª Ordem")
plt.legend()
plt.grid()
plt.show()

```

x_k	y_k	K_1	K_2	Erro
0.0	1.000000	1.000000	1.200000	0.000000
0.1	1.120000	1.220000	1.442000	0.009658
0.2	1.264200	1.464200	1.710620	0.021394
0.3	1.435262	1.735262	2.008788	0.035544
0.4	1.636141	2.036141	2.339755	0.052491
0.5	1.870116	2.370116	2.707128	0.072674
0.6	2.140829	2.740829	3.114912	0.096592
0.7	2.452320	3.152320	3.567552	0.124815
0.8	2.809076	3.609076	4.069983	0.157994
0.9	3.216074	4.116074	4.627681	0.196868
1.0	3.678842	4.678842	5.246726	0.242278
1.1	4.203515	5.303515	5.933866	0.295183
1.2	4.796901	5.996901	6.696591	0.356667
1.3	5.466560	6.766560	7.543216	0.427967
1.4	6.220882	7.620882	8.482970	0.510482
1.5	7.069179	8.569179	9.526097	0.605801
1.6	8.021789	9.621789	10.683968	0.715724
1.7	9.090185	10.790185	11.969204	0.842291
1.8	10.287106	12.087106	13.395816	0.987811
1.9	11.626687	13.526687	14.979356	1.154899
2.0	13.124623	NaN	NaN	1.346511

Solução Numérica pelo Método de Runge-Kutta de 2^a Ordem



3. Método de Runge-Kutta de ordem 4: simplicidade + precisão + economia

O método de Runge-Kutta de quarta ordem é baseado na ideia de tomarmos combinações de $f(x, y)$ em vários pontos do intervalo $x_k \leq x \leq x_{k+1}$ e arranjarmos os parâmetros para que a nossa aproximação de y_{k+1} coincida com a expansão de Taylor de ordem 4.

Resultando em:

$$y_{k+1} = y_k + \frac{1}{6}(K_1 + 2K_2 + 2K_3 + K_4)$$

onde

$$K_1 = hf(x_k, y_k),$$

$$K_2 = hf\left(x_k + \frac{1}{2}h, y_k + \frac{1}{2}K_1\right),$$

$$K_3 = hf\left(x_k + \frac{1}{2}h, y_k + \frac{1}{2}K_2\right),$$

$$K_4 = hf(x_k + h, y_k + K_3).$$

In [6]:

```
#runge-kutta 4 com tabela
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
```

```

def runge_kutta4(f, x0, y0, h, n, exact_solution=None):
    """
    Método de Runge-Kutta de 4ª ordem para resolver EDOs numericamente.

    Parâmetros:
        f - Função f(x, y) que define a EDO dy/dx = f(x, y)
        x0 - Valor inicial de x
        y0 - Valor inicial de y
        h - Passo do método
        n - Número de passos
        exact_solution - (Opcional) Função da solução exata para cálculo do erro

    Retorna:
        DataFrame contendo xs, ys, K1, K2, K3, K4 e erro (se exata for fornecida)
    """
    xs = np.zeros(n+1)
    ys = np.zeros(n+1)
    k1_vals = np.zeros(n)
    k2_vals = np.zeros(n)
    k3_vals = np.zeros(n)
    k4_vals = np.zeros(n)
    errors = np.zeros(n+1) if exact_solution else None

    xs[0], ys[0] = x0, y0
    if exact_solution:
        errors[0] = abs(ys[0] - exact_solution(xs[0]))

    for i in range(n):
        k1 = f(xs[i], ys[i])
        k2 = f(xs[i] + h/2, ys[i] + (h/2) * k1)
        k3 = f(xs[i] + h/2, ys[i] + (h/2) * k2)
        k4 = f(xs[i] + h, ys[i] + h * k3)

        ys[i+1] = ys[i] + (h/6) * (k1 + 2*k2 + 2*k3 + k4)
        xs[i+1] = xs[i] + h

        k1_vals[i] = k1
        k2_vals[i] = k2
        k3_vals[i] = k3
        k4_vals[i] = k4

        if exact_solution:
            errors[i+1] = abs(ys[i+1] - exact_solution(xs[i+1]))

    # Criar um DataFrame com os valores calculados
    data = {
        'x_k': xs,
        'y_k': ys,
        'K_1': np.append(k1_vals, np.nan),
        'K_2': np.append(k2_vals, np.nan),
        'K_3': np.append(k3_vals, np.nan),
        'K_4': np.append(k4_vals, np.nan),
    }
    if exact_solution:
        data['Erro'] = errors

    df = pd.DataFrame(data)

    return df, xs, ys

```

```

# Definição da EDO: dy/dx = f(x, y)
def f(x, y):
    return x + y # Exemplo: dy/dx = x + y

# Definição da solução exata para erro (caso seja conhecida)
def exact_solution(x):
    return 2 * np.exp(x) - x - 1 # Solução exata da EDO dy/dx = x + y com y(0)

# Parâmetros iniciais
x0 = 0
y0 = 1 # y(0) = 1
h = 0.1 # Tamanho do passo
n = 20 # Número de passos

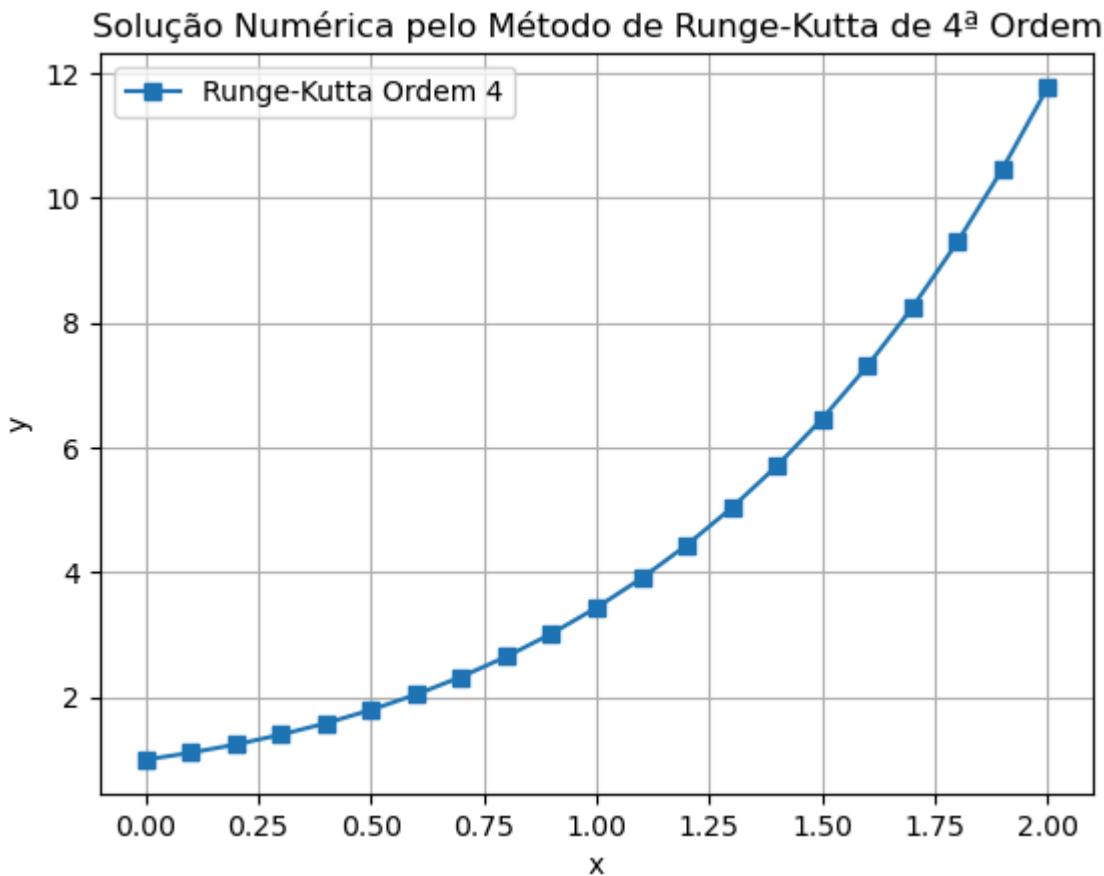
# Resolver a EDO usando Runge-Kutta de 4ª ordem e calcular a tabela
df, xs, ys = runge_kutta4(f, x0, y0, h, n, exact_solution)

# Exibir a tabela
print(df.to_string(index=False))

# Plotar a solução
plt.plot(xs, ys, label="Runge-Kutta Ordem 4", marker='s', linestyle='--')
plt.xlabel("x")
plt.ylabel("y")
plt.title("Solução Numérica pelo Método de Runge-Kutta de 4ª Ordem")
plt.legend()
plt.grid()
plt.show()

```

x_k	y_k	K_1	K_2	K_3	K_4	Erro
0.0	1.000000	1.000000	1.100000	1.105000	1.210500	0.000000e+00
0.1	1.110342	1.210342	1.320859	1.326385	1.442980	1.694846e-07
0.2	1.242805	1.442805	1.564945	1.571052	1.699910	3.746190e-07
0.3	1.399717	1.699717	1.834703	1.841452	1.983862	6.210269e-07
0.4	1.583648	1.983648	2.132831	2.140290	2.297677	9.151212e-07
0.5	1.797441	2.297441	2.462313	2.470557	2.644497	1.264207e-06
0.6	2.044236	2.644236	2.826448	2.835558	3.027792	1.676597e-06
0.7	2.327503	3.027503	3.228878	3.238947	3.451398	2.161747e-06
0.8	2.651079	3.451079	3.673633	3.684761	3.919555	2.730400e-06
0.9	3.019203	3.919203	4.165163	4.177461	4.436949	3.394754e-06
1.0	3.436559	4.436559	4.708387	4.721979	5.008757	4.168648e-06
1.1	3.908327	5.008327	5.308743	5.323764	5.640703	5.067775e-06
1.2	4.440228	5.640228	5.972239	5.988840	6.339112	6.109917e-06
1.3	5.038586	6.338586	6.705515	6.723862	7.110972	7.315211e-06
1.4	5.710391	7.110391	7.515911	7.536187	7.964010	8.706447e-06
1.5	6.463368	7.963368	8.411536	8.433945	8.906762	1.030941e-05
1.6	7.306053	8.906053	9.401355	9.426120	9.948665	1.215323e-05
1.7	8.247881	9.947881	10.495275	10.522644	11.100145	1.427086e-05
1.8	9.299278	11.099278	11.704242	11.734490	12.372727	1.669949e-05
1.9	10.471769	12.371769	13.040358	13.073787	13.779148	1.948111e-05
2.0	11.778090	NaN	NaN	NaN	NaN	2.266311e-05



4. O método de Adams-Bashforth de 4a ordem

é obtido aproximando f por um polinômio de grau 3 interpolador em $x_i, x_{i-1}, x_{i-2}, x_{i-3}$ e usando a regra de integração

$$\int_{x_i}^{x_{i+1}} f(x)dx \approx \frac{h}{24}[55f(x_i) - 59f(x_{i-1}) + 37f(x_{i-2}) - 9f(x_{i-3})]$$

onde $h = x_{i+1} - x_i$

O método é dado por:

$$y_{i+1} = y_i + \frac{h}{24}[55f(x_i, y_i) - 59f(x_{i-1}, y_{i-1}) + 37f(x_{i-2}, y_{i-2}) - 9f(x_{i-3}, y_{i-3})]$$

que é a fórmula do Método de Adams-Bashforth de quarta ordem.

Observe que para determinar y_4 precisamos conhecer y_0, y_1, y_2, y_3 ; como y_0 já é dado precisamos determinar os demais. Fazemos isto usando um método numérico de passo simples.

```
In [12]: import numpy as np
import matplotlib.pyplot as plt

def f(t, y):
    return -y + np.sin(t) # Exemplo de EDO: y' = -y + sin(t)

def adams_bashforth_4(f, t0, y0, t_final, h):
    """
```

```

Método de Adams-Bashforth de 4a ordem para resolver EDOs.
:param f: Função da EDO  $y' = f(t, y)$ 
:param t0: Tempo inicial
:param y0: Condição inicial
:param t_final: Tempo final
:param h: Passo de integração
:return: Arrays de tempos e soluções aproximadas
"""

# Criando os valores de t
t_values = np.arange(t0, t_final + h, h)
n = len(t_values)
y_values = np.zeros(n)
y_values[0] = y0

# Usar Runge-Kutta de ordem 4 para obter os primeiros 3 valores
y_values[1] = y_values[0] + h * f(t_values[0], y_values[0])
y_values[2] = y_values[1] + h * f(t_values[1], y_values[1])
y_values[3] = y_values[2] + h * f(t_values[2], y_values[2])

# Método de Adams-Bashforth de 4a ordem
for i in range(3, n - 1):
    y_values[i + 1] = y_values[i] + (h / 24) * (
        55 * f(t_values[i], y_values[i]) -
        59 * f(t_values[i - 1], y_values[i - 1]) +
        37 * f(t_values[i - 2], y_values[i - 2]) -
        9 * f(t_values[i - 3], y_values[i - 3]))
)

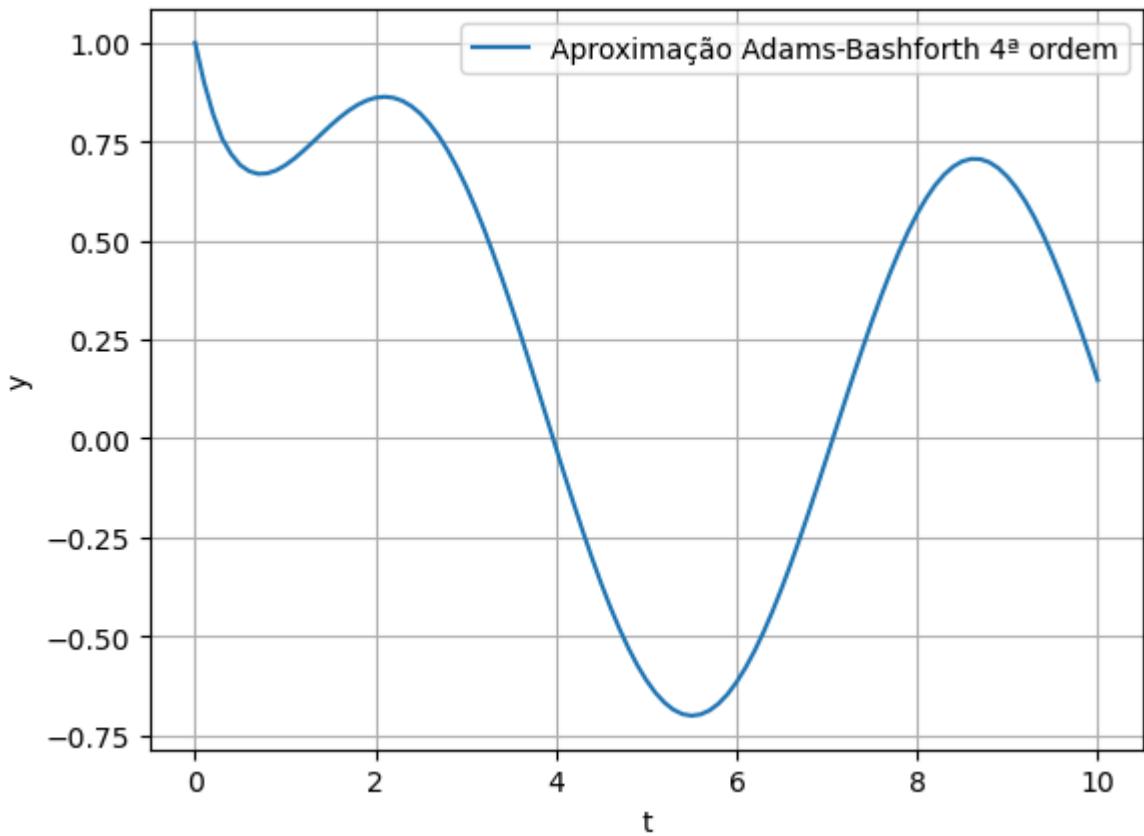
return t_values, y_values

# Parâmetros de exemplo
t0 = 0
y0 = 1
t_final = 10
h = 0.1

# Resolvendo a EDO
t_values, y_values = adams_bashforth_4(f, t0, y0, t_final, h)

# Plotando o resultado
plt.plot(t_values, y_values, label='Aproximação Adams-Bashforth 4a ordem')
plt.xlabel('t')
plt.ylabel('y')
plt.legend()
plt.grid()
plt.show()

```



5. Método de Adams-Moulton

O método de Adams-Moulton de 4a.order, e passo 3, é um método implícito dado por

$$y_{i+1} = y_i + \frac{h}{24}[9f(x_{i+1}, y_{i+1}) + 19f(x_i, y_i) - 5f(x_{i-1}, y_{i-1}) + f(x_{i-2}, y_{i-2})]$$

Para aplicar um método implícito diretamente devemos resolver a equação. Isto não é óbvio que possa ser feito, portanto, temos que alguns cuidados.cito}.

```
In [14]: #adams-moulton
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt

def adams_moulton_4th_order(f, exact_solution, x0, y0, h, n):
    """
    Método de Adams-Moulton de 4ª ordem para resolver EDOs.

    Parâmetros:
        f - Função f(x, y) que define a EDO dy/dx = f(x, y)
        exact_solution - Função exata y(x) para cálculo do erro
        x0 - Valor inicial de x
        y0 - Valor inicial de y
        h - Passo do método
        n - Número de passos

    Retorna:
        DataFrame contendo x, y_aproximado e erro absoluto.
    """
    # Validação dos parâmetros
```

```

if h <= 0:
    raise ValueError("O passo h deve ser positivo.")
if n <= 0:
    raise ValueError("O número de passos n deve ser positivo.")

# Inicialização dos vetores
xs = [x0]
ys = [y0]
errors = [0.0] # Erro inicial é zero

# Usando Runge-Kutta de 4ª ordem para obter os primeiros 4 pontos
for i in range(3):
    x = xs[-1]
    y = ys[-1]

    k1 = f(x, y)
    k2 = f(x + h/2, y + (h/2) * k1)
    k3 = f(x + h/2, y + (h/2) * k2)
    k4 = f(x + h, y + h * k3)

    y_next = y + (h/6) * (k1 + 2*k2 + 2*k3 + k4)
    x_next = x + h

    xs.append(x_next)
    ys.append(y_next)
    errors.append(abs(y_next - exact_solution(x_next)))

# Método de Adams-Moulton de 4ª ordem
for i in range(3, n):
    x = xs[-1]
    y = ys[-1]

    # Predição usando Adams-Bashforth de 4ª ordem
    y_pred = ys[-1] + (h/24) * (
        55 * f(xs[-1], ys[-1]) -
        59 * f(xs[-2], ys[-2]) +
        37 * f(xs[-3], ys[-3]) -
        9 * f(xs[-4], ys[-4])
    )

    # Correção usando Adams-Moulton de 4ª ordem
    y_next = ys[-1] + (h/24) * (
        9 * f(x + h, y_pred) +
        19 * f(xs[-1], ys[-1]) -
        5 * f(xs[-2], ys[-2]) +
        f(xs[-3], ys[-3])
    )

    x_next = x + h

    xs.append(x_next)
    ys.append(y_next)
    errors.append(abs(y_next - exact_solution(x_next)))

# Criar DataFrame para exibição
df = pd.DataFrame({
    'x': xs,
    'y_aprox': ys,
    'Erro Absoluto': errors
})

```

```

        return df

def plot_results(df, exact_solution):
    """
        Plota os resultados aproximados e a solução exata.

    Parâmetros:
        df - DataFrame contendo os resultados do método de Adams-Moulton
        exact_solution - Função exata y(x) para comparação
    """
    plt.figure(figsize=(10, 6))
    plt.plot(df['x'], df['y_aprox'], 'bo-', label='Aproximação (Adams-Moulton 4ª')
    x_exact = np.linspace(min(df['x']), max(df['x']), 400)
    y_exact = exact_solution(x_exact)
    plt.plot(x_exact, y_exact, 'r-', label='Solução Exata')
    plt.xlabel('x')
    plt.ylabel('y')
    plt.title('Comparação entre a Aproximação e a Solução Exata')
    plt.legend()
    plt.grid(True)
    plt.show()

# Definição da EDO: dy/dx = f(x, y)
def f(x, y):
    return x + y # Exemplo: dy/dx = x + y

# Solução exata para comparação: y(x) = 2e^x - x - 1 (obtida via método analítico)
def exact_solution(x):
    return 2 * np.exp(x) - x - 1

# Parâmetros
x0 = 0
y0 = 1 # y(0) = 1
h = 0.1 # Tamanho do passo
n = 10 # Número de passos

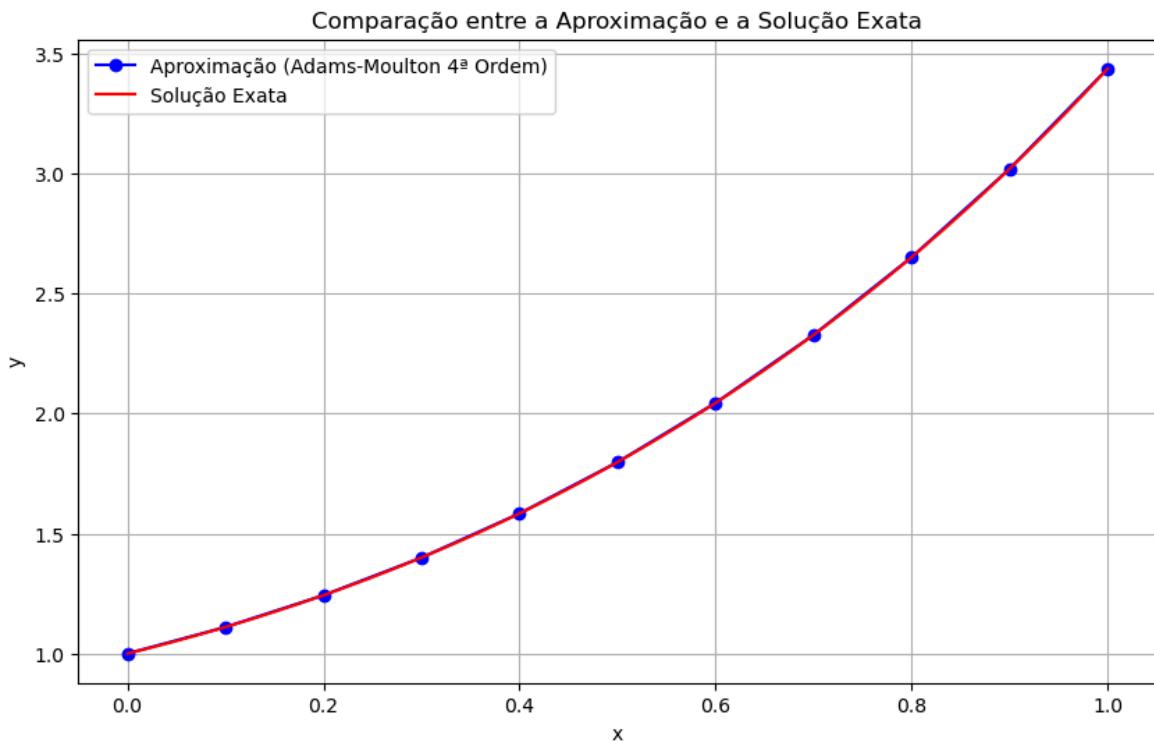
# Gerar a tabela atualizada
df_am4 = adams_moulton_4th_order(f, exact_solution, x0, y0, h, n)

# Exibir a tabela
print(df_am4)

# Plotar os resultados
plot_results(df_am4, exact_solution)

```

	x	y_aprox	Erro Absoluto
0	0.0	1.000000	0.000000e+00
1	0.1	1.110342	1.694846e-07
2	0.2	1.242805	3.746190e-07
3	0.3	1.399717	6.210269e-07
4	0.4	1.583649	3.145719e-07
5	0.5	1.797443	7.527723e-08
6	0.6	2.044238	5.461356e-07
7	0.7	2.327507	1.115782e-06
8	0.8	2.651084	1.799271e-06
9	0.9	3.019209	2.614175e-06
10	1.0	3.436567	3.580586e-06



6. Exemplos

```
In [15]: #crescimento populacional
# Definição da EDO: dP/dt = kP
def f(t, P):
    k = 0.02 # Taxa de crescimento
    return k * P

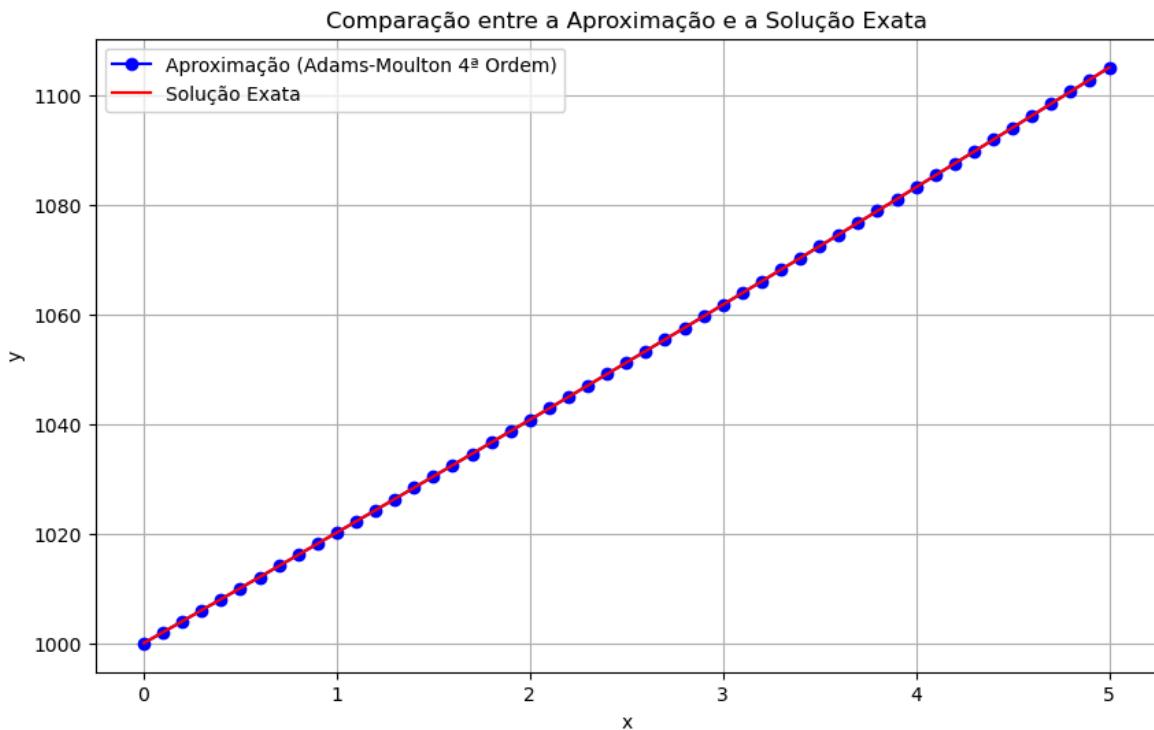
# Solução exata: P(t) = P0 * e^(kt)
def exact_solution(t):
    P0 = 1000 # População inicial
    k = 0.02
    return P0 * np.exp(k * t)

# Parâmetros
t0 = 0
P0 = 1000
h = 0.1
n = 50

# Resolver usando Adams-Moulton
df_am4 = adams_moulton_4th_order(f, exact_solution, t0, P0, h, n)

# Exibir resultados
print(df_am4)
plot_results(df_am4, exact_solution)
```

	x	y_aprox	Erro Absoluto
0	0.0	1000.000000	0.000000e+00
1	0.1	1002.002001	2.273737e-13
2	0.2	1004.008011	4.547474e-13
3	0.3	1006.018036	7.958079e-13
4	0.4	1008.032086	1.136868e-13
5	0.5	1010.050167	1.136868e-12
6	0.6	1012.072289	1.818989e-12
7	0.7	1014.098459	2.728484e-12
8	0.8	1016.128685	3.524292e-12
9	0.9	1018.162976	4.433787e-12
10	1.0	1020.201340	5.229595e-12
11	1.1	1022.243784	6.139089e-12
12	1.2	1024.290318	7.048584e-12
13	1.3	1026.340948	7.958079e-12
14	1.4	1028.395684	8.640200e-12
15	1.5	1030.454534	9.549694e-12
16	1.6	1032.517505	1.068656e-11
17	1.7	1034.584607	1.136868e-11
18	1.8	1036.655846	1.227818e-11
19	1.9	1038.731233	1.341505e-11
20	2.0	1040.810774	1.432454e-11
21	2.1	1042.894479	1.523404e-11
22	2.2	1044.982355	1.614353e-11
23	2.3	1047.074411	1.682565e-11
24	2.4	1049.170655	1.773515e-11
25	2.5	1051.271096	1.864464e-11
26	2.6	1053.375743	1.978151e-11
27	2.7	1055.484602	2.046363e-11
28	2.8	1057.597684	2.160050e-11
29	2.9	1059.714996	2.250999e-11
30	3.0	1061.836547	2.364686e-11
31	3.1	1063.962345	2.455636e-11
32	3.2	1066.092399	2.569323e-11
33	3.3	1068.226717	2.637535e-11
34	3.4	1070.365308	2.751221e-11
35	3.5	1072.508181	2.819434e-11
36	3.6	1074.655344	2.933120e-11
37	3.7	1076.806805	3.024070e-11
38	3.8	1078.962574	3.115019e-11
39	3.9	1081.122659	3.205969e-11
40	4.0	1083.287068	3.296918e-11
41	4.1	1085.455810	3.410605e-11
42	4.2	1087.628894	3.501555e-11
43	4.3	1089.806328	3.592504e-11
44	4.4	1091.988122	3.706191e-11
45	4.5	1094.174284	3.797140e-11
46	4.6	1096.364822	3.910827e-11
47	4.7	1098.559746	4.001777e-11
48	4.8	1100.759064	4.092726e-11
49	4.9	1102.962785	4.183676e-11
50	5.0	1105.170918	4.297362e-11



In [13]:

```
#cicuito rc
# Definição da EDO: dV/dt = -V/(RC)
def f(t, V):
    R = 1000 # Resistência (Ohms)
    C = 1e-6 # Capacitância (Farads)
    return -V / (R * C)

# Solução exata: V(t) = V0 * e^(-t/(RC))
def exact_solution(t):
    V0 = 10 # Tensão inicial
    R = 1000
    C = 1e-6
    return V0 * np.exp(-t / (R * C))

# Parâmetros
t0 = 0
V0 = 10
h = 0.0001 # Passo pequeno devido à rápida descarga
n = 100

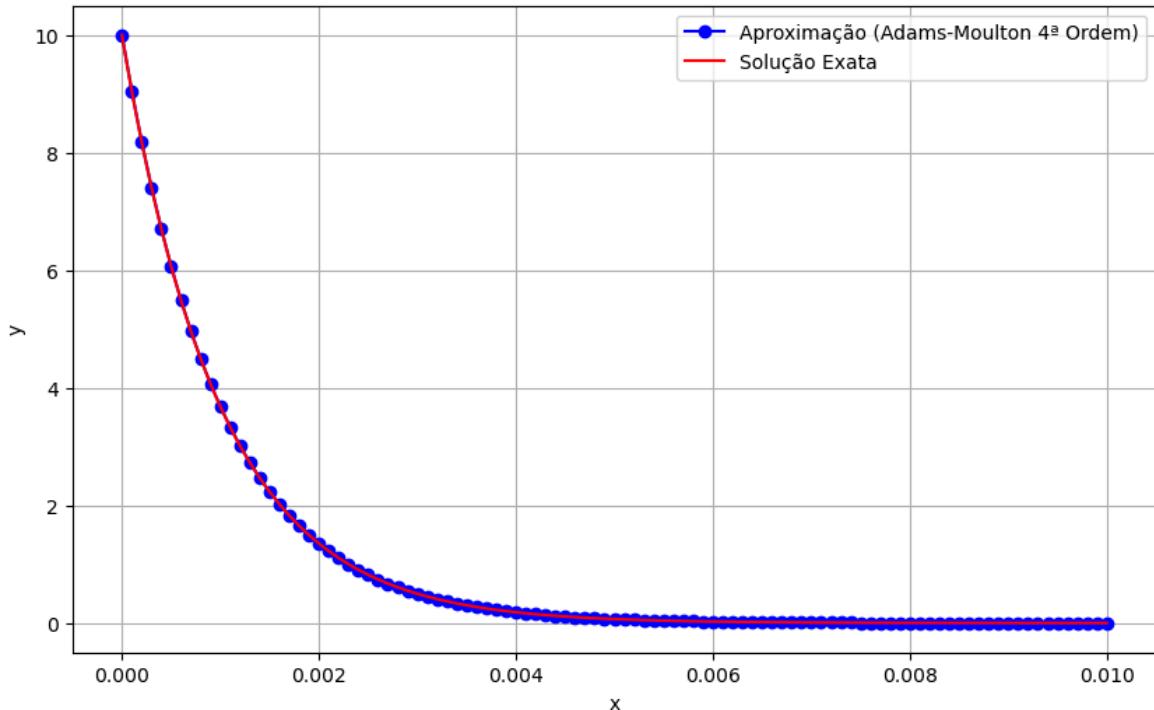
# Resolver usando Adams-Moulton
df_am4 = adams_moulton_4th_order(f, exact_solution, t0, V0, h, n)

# Exibir resultados
print(df_am4)
plot_results(df_am4, exact_solution)
```

	x	y_aprox	Erro Absoluto
0	0.0000	10.000000	0.000000e+00
1	0.0001	9.048375	8.196404e-07
2	0.0002	8.187309	1.483283e-06
3	0.0003	7.408184	2.013195e-06
4	0.0004	6.703199	1.277917e-06
..
96	0.0096	0.000677	2.852201e-08
97	0.0097	0.000613	2.608704e-08
98	0.0098	0.000554	2.385721e-08
99	0.0099	0.000502	2.181553e-08
100	0.0100	0.000454	1.994639e-08

[101 rows x 3 columns]

Comparação entre a Aproximação e a Solução Exata



7. Pendulo simples Amortecido

Introdução

Um pêndulo simples consiste em uma massa m presa a uma haste rígida de comprimento L , que oscila sob a ação da gravidade. Quando há amortecimento (por exemplo, devido à resistência do ar), a amplitude das oscilações diminui ao longo do tempo.

Equação Diferencial

A equação diferencial que descreve o movimento do pêndulo amortecido é:

$$\frac{d^2\theta}{dt^2} + \frac{b}{m} \frac{d\theta}{dt} + \frac{g}{L} \sin(\theta) = 0$$

onde:

- $\theta(t)$ é o ângulo do pêndulo em relação à posição de equilíbrio no tempo t ;
- b é o coeficiente de amortecimento;
- m é a massa do pêndulo;
- g é a aceleração devida à gravidade ($\approx 9.81 \text{ m/s}^2$);
- L é o comprimento da haste.

Transformação em um Sistema de EDOs

Para resolver numericamente, transformamos a equação diferencial de segunda ordem em um sistema de duas equações diferenciais de primeira ordem. Definimos:

$$\omega = \frac{d\theta}{dt}$$

onde $\omega(t)$ representa a velocidade angular.

O sistema de equações diferenciais resultante é:

$$\begin{aligned}\frac{d\theta}{dt} &= \omega \\ \frac{d\omega}{dt} &= -\frac{b}{m}\omega - \frac{g}{L}\sin(\theta)\end{aligned}$$

Solução Analítica para Pequenos Ângulos

Para pequenos ângulos ($\theta \approx 0$), podemos aproximar $\sin(\theta) \approx \theta$, e a equação diferencial se torna linear. Neste caso, a solução analítica descreve uma oscilação amortecida:

$$\theta(t) = \theta_0 e^{-\frac{b}{2m}t} \cos\left(\sqrt{\frac{g}{L} - \left(\frac{b}{2m}\right)^2} t\right)$$

No entanto, para ângulos grandes, a solução exata não pode ser obtida diretamente e geralmente requer métodos numéricos.

Aplicação

Para um exemplo prático, consideremos os seguintes valores:

- $m = 1 \text{ kg}$;
- $L = 1 \text{ m}$;
- $b = 0.5 \text{ kg/s}$;
- $g = 9.81 \text{ m/s}^2$;
- $\theta(0) = \frac{\pi}{4} \text{ rad}$ (ângulo inicial);
- $\omega(0) = 0 \text{ rad/s}$ (velocidade angular inicial).

Com esses valores, podemos resolver numericamente as equações diferenciais para analisar o comportamento do pêndulo amortecido ao longo do tempo. Vamos analisar o comportamento do pêndulo amortecido ao longo do tempo.

\end{document}

EDO:

```
In [14]: #pendulo simples amortecido
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt

def runge_kutta4_system(f, t0, y0, h, n):
    """
    Método de Runge-Kutta de 4ª ordem para sistemas de EDOs.

    Parâmetros:
        f - Função que define o sistema de EDOs (deve retornar um array)
        t0 - Valor inicial de t
        y0 - Valores iniciais de y (array)
        h - Passo do método
        n - Número de passos

    Retorna:
        ts - Valores de t
        ys - Valores de y (array de arrays)
    """
    ts = [t0]
    ys = [y0]

    for i in range(n):
        t = ts[-1]
        y = ys[-1]

        k1 = f(t, y)
        k2 = f(t + h/2, y + (h/2) * k1)
        k3 = f(t + h/2, y + (h/2) * k2)
        k4 = f(t + h, y + h * k3)

        y_next = y + (h/6) * (k1 + 2*k2 + 2*k3 + k4)
        t_next = t + h

        ts.append(t_next)
        ys.append(y_next)

    return np.array(ts), np.array(ys)

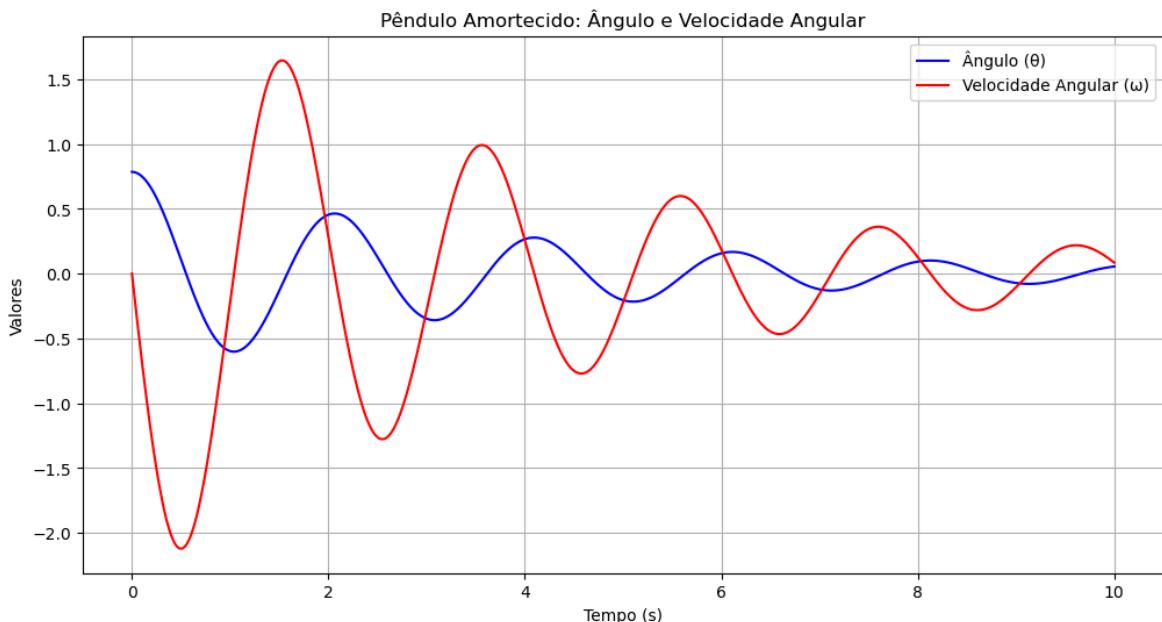
# Definição do sistema de EDOs para o pêndulo amortecido
def f(t, y):
    theta, omega = y
    b = 0.5 # Coeficiente de amortecimento
    m = 1 # Massa
    g = 9.81 # Aceleração da gravidade
    L = 1 # Comprimento da haste
    dtheta_dt = omega
    domega_dt = -(b/m) * omega - (g/L) * np.sin(theta)
    return np.array([dtheta_dt, domega_dt])
```

```
# Parâmetros
t0 = 0
y0 = np.array([np.pi/4, 0]) # Ângulo inicial e velocidade angular inicial
h = 0.01 # Passo
n = 1000 # Número de passos

# Resolver o sistema
ts, ys = runge_kutta4_system(f, t0, y0, h, n)

# Extrair theta e omega
thetas = ys[:, 0]
omegas = ys[:, 1]

# Plotar os resultados
plt.figure(figsize=(12, 6))
plt.plot(ts, thetas, 'b-', label='Ângulo ( $\theta$ )')
plt.plot(ts, omegas, 'r-', label='Velocidade Angular ( $\omega$ )')
plt.xlabel('Tempo (s)')
plt.ylabel('Valores')
plt.title('Pêndulo Amortecido: Ângulo e Velocidade Angular')
plt.legend()
plt.grid(True)
plt.show()
```



8. Método de Runge-Kutta para sistemas de edos 2 por 2

```
In [15]: # runge-kutta de ordem 4 para sistemas 2 por 2
import numpy as np
import matplotlib.pyplot as plt

def runge_kutta_4_system(f1, f2, t0, y0, z0, t_final, h):
    """
    Método de Runge-Kutta de quarta ordem para um sistema de EDOs de primeira ordem.

    Parâmetros:
    f1, f2: Funções que representam o sistema de equações diferenciais.
    t0: Tempo inicial.
    """

    # Implementação do método de Runge-Kutta de quarta ordem
```

```

y0, z0: Condições iniciais para y e z.
t_final: Tempo final.
h: Passo de integração.

Retorna:
t_vals: Lista dos valores de t.
y_vals, z_vals: Listas dos valores das soluções y e z.
"""

t_vals = np.arange(t0, t_final + h, h)
y_vals = np.zeros_like(t_vals)
z_vals = np.zeros_like(t_vals)

y_vals[0] = y0
z_vals[0] = z0

for i in range(len(t_vals) - 1):
    t = t_vals[i]
    y = y_vals[i]
    z = z_vals[i]

    k1_y = h * f1(t, y, z)
    k1_z = h * f2(t, y, z)

    k2_y = h * f1(t + h/2, y + k1_y/2, z + k1_z/2)
    k2_z = h * f2(t + h/2, y + k1_y/2, z + k1_z/2)

    k3_y = h * f1(t + h/2, y + k2_y/2, z + k2_z/2)
    k3_z = h * f2(t + h/2, y + k2_y/2, z + k2_z/2)

    k4_y = h * f1(t + h, y + k3_y, z + k3_z)
    k4_z = h * f2(t + h, y + k3_y, z + k3_z)

    y_vals[i+1] = y + (k1_y + 2*k2_y + 2*k3_y + k4_y) / 6
    z_vals[i+1] = z + (k1_z + 2*k2_z + 2*k3_z + k4_z) / 6

return t_vals, y_vals, z_vals

# Definição do sistema de EDOs
def f1(t, y, z):
    return z # Exemplo: dy/dt = z

def f2(t, y, z):
    return -y # Exemplo: dz/dt = -y

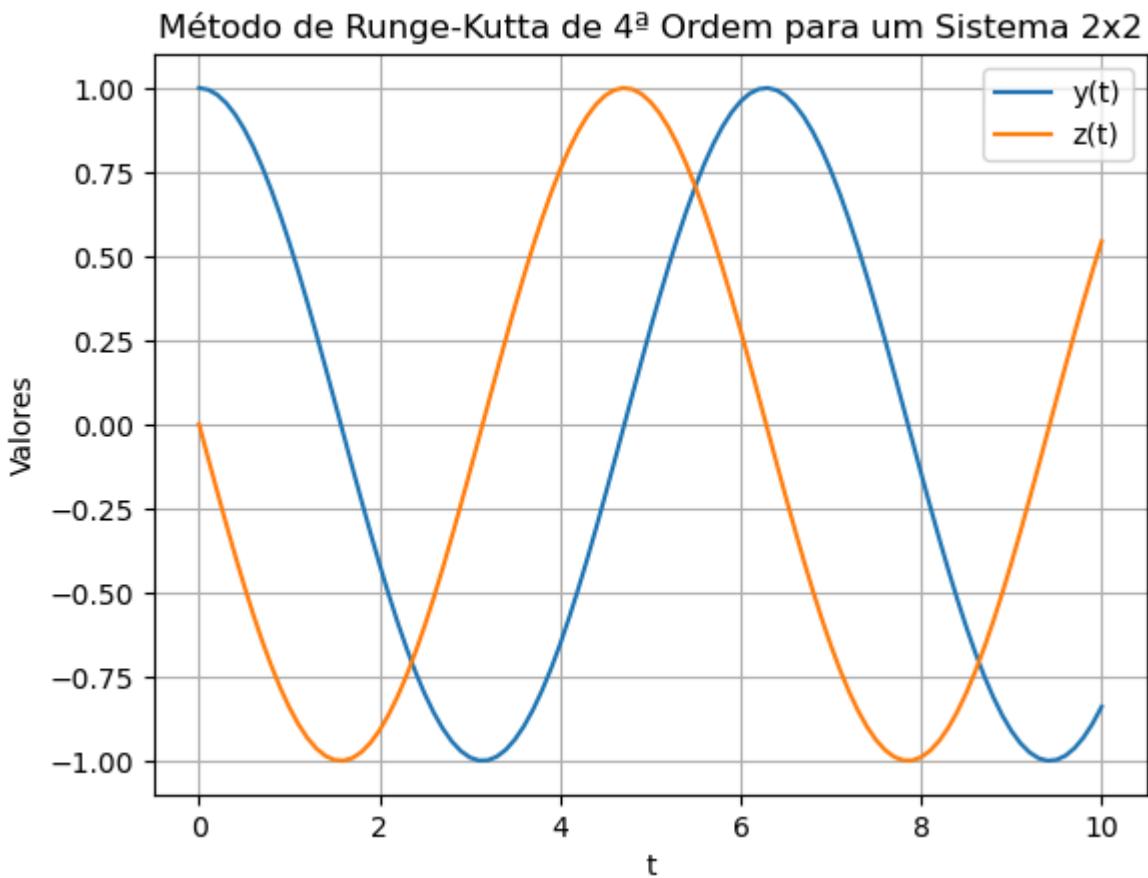
# Parâmetros
t0 = 0
y0 = 1
z0 = 0
t_final = 10
h = 0.1

# Resolvendo o sistema
t_vals, y_vals, z_vals = runge_kutta_4_system(f1, f2, t0, y0, z0, t_final, h)

# Plotando os resultados
plt.plot(t_vals, y_vals, label='y(t)')
plt.plot(t_vals, z_vals, label='z(t)')
plt.xlabel('t')
plt.ylabel('Valores')

```

```
plt.legend()
plt.grid()
plt.title('Método de Runge-Kutta de 4ª Ordem para um Sistema 2x2')
plt.show()
```



9. Modelo presa-predador

```
In [16]: #predador presa
import numpy as np
import matplotlib.pyplot as plt

def runge_kutta_4_system(f1, f2, t0, y0, z0, t_final, h):
    """
    Método de Runge-Kutta de quarta ordem para um sistema de EDOs de primeira ordem.

    Parâmetros:
    f1, f2: Funções que representam o sistema de equações diferenciais.
    t0: Tempo inicial.
    y0, z0: Condições iniciais para y e z.
    t_final: Tempo final.
    h: Passo de integração.

    Retorna:
    t_vals: Lista dos valores de t.
    y_vals, z_vals: Listas dos valores das soluções y e z.
    """
    t_vals = np.arange(t0, t_final + h, h)
    y_vals = np.zeros_like(t_vals)
    z_vals = np.zeros_like(t_vals)

    y_vals[0] = y0
    z_vals[0] = z0

    for i in range(1, len(t_vals)):
        k1_y = f1(t_vals[i-1], y_vals[i-1], z_vals[i-1])
        k1_z = f2(t_vals[i-1], y_vals[i-1], z_vals[i-1])

        k2_y = f1(t_vals[i-1] + h/2, y_vals[i-1] + k1_y * h/2, z_vals[i-1] + k1_z * h/2)
        k2_z = f2(t_vals[i-1] + h/2, y_vals[i-1] + k1_y * h/2, z_vals[i-1] + k1_z * h/2)

        k3_y = f1(t_vals[i-1] + h/2, y_vals[i-1] + k2_y * h/2, z_vals[i-1] + k2_z * h/2)
        k3_z = f2(t_vals[i-1] + h/2, y_vals[i-1] + k2_y * h/2, z_vals[i-1] + k2_z * h/2)

        k4_y = f1(t_vals[i-1] + h, y_vals[i-1] + k3_y * h, z_vals[i-1] + k3_z * h)
        k4_z = f2(t_vals[i-1] + h, y_vals[i-1] + k3_y * h, z_vals[i-1] + k3_z * h)

        y_vals[i] = y_vals[i-1] + (k1_y + 2*k2_y + 2*k3_y + k4_y) * h/6
        z_vals[i] = z_vals[i-1] + (k1_z + 2*k2_z + 2*k3_z + k4_z) * h/6
```

```

y_vals[0] = y0
z_vals[0] = z0

for i in range(len(t_vals) - 1):
    t = t_vals[i]
    y = y_vals[i]
    z = z_vals[i]

    k1_y = h * f1(t, y, z)
    k1_z = h * f2(t, y, z)

    k2_y = h * f1(t + h/2, y + k1_y/2, z + k1_z/2)
    k2_z = h * f2(t + h/2, y + k1_y/2, z + k1_z/2)

    k3_y = h * f1(t + h/2, y + k2_y/2, z + k2_z/2)
    k3_z = h * f2(t + h/2, y + k2_y/2, z + k2_z/2)

    k4_y = h * f1(t + h, y + k3_y, z + k3_z)
    k4_z = h * f2(t + h, y + k3_y, z + k3_z)

    y_vals[i+1] = y + (k1_y + 2*k2_y + 2*k3_y + k4_y) / 6
    z_vals[i+1] = z + (k1_z + 2*k2_z + 2*k3_z + k4_z) / 6

return t_vals, y_vals, z_vals

# Modelo Predador-Presa
def f1(t, y, z):
    alpha = 0.1 # Taxa de crescimento da presa
    beta = 0.02 # Taxa de predação
    return alpha * y - beta * y * z

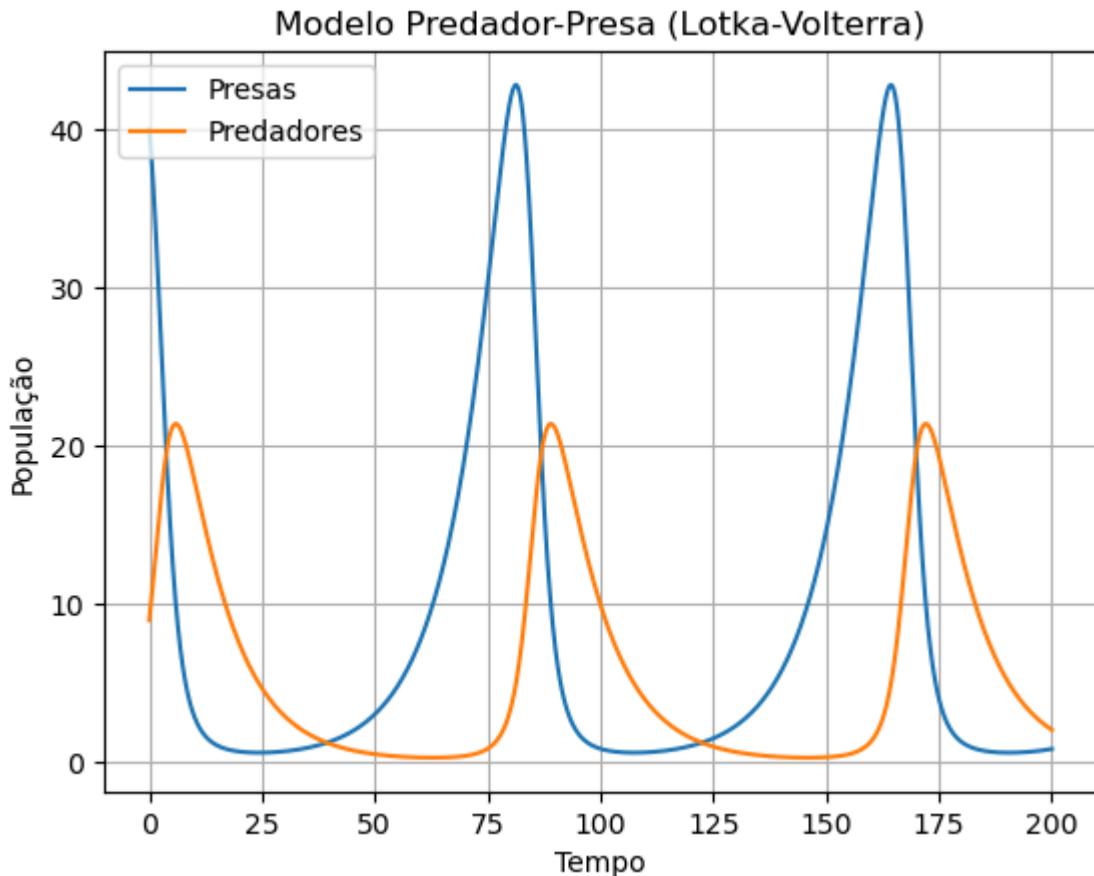
def f2(t, y, z):
    delta = 0.01 # Taxa de reprodução do predador
    gamma = 0.1 # Taxa de mortalidade do predador
    return delta * y * z - gamma * z

# Parâmetros
t0 = 0
y0 = 40 # População inicial de presas
z0 = 9 # População inicial de predadores
t_final = 200
h = 0.1

# Resolvendo o sistema
t_vals, y_vals, z_vals = runge_kutta_4_system(f1, f2, t0, y0, z0, t_final, h)

# Plotando os resultados
plt.plot(t_vals, y_vals, label='Presas')
plt.plot(t_vals, z_vals, label='Predadores')
plt.xlabel('Tempo')
plt.ylabel('População')
plt.legend()
plt.grid()
plt.title('Modelo Predador-Presa (Lotka-Volterra)')
plt.show()

```



10. edo diretamente do Python

Veja os exemplos em que usamos `sp.dsolve`, `solve_ivp`,

```
In [18]: import sympy as sp
import numpy as np
import matplotlib.pyplot as plt
from scipy.integrate import solve_ivp

# Resolvendo simbolicamente uma EDO com SymPy
t = sp.Symbol('t')
y = sp.Function('y')(t)
deq = sp.Eq(y.diff(t), -y + sp.sin(t)) # y' = -y + sin(t)
sol = sp.dsolve(deq, y)
print("Solução simbólica:", sol)

# Resolvendo numericamente com scipy.integrate.solve_ivp
def f(t, y):
    return -y + np.sin(t)

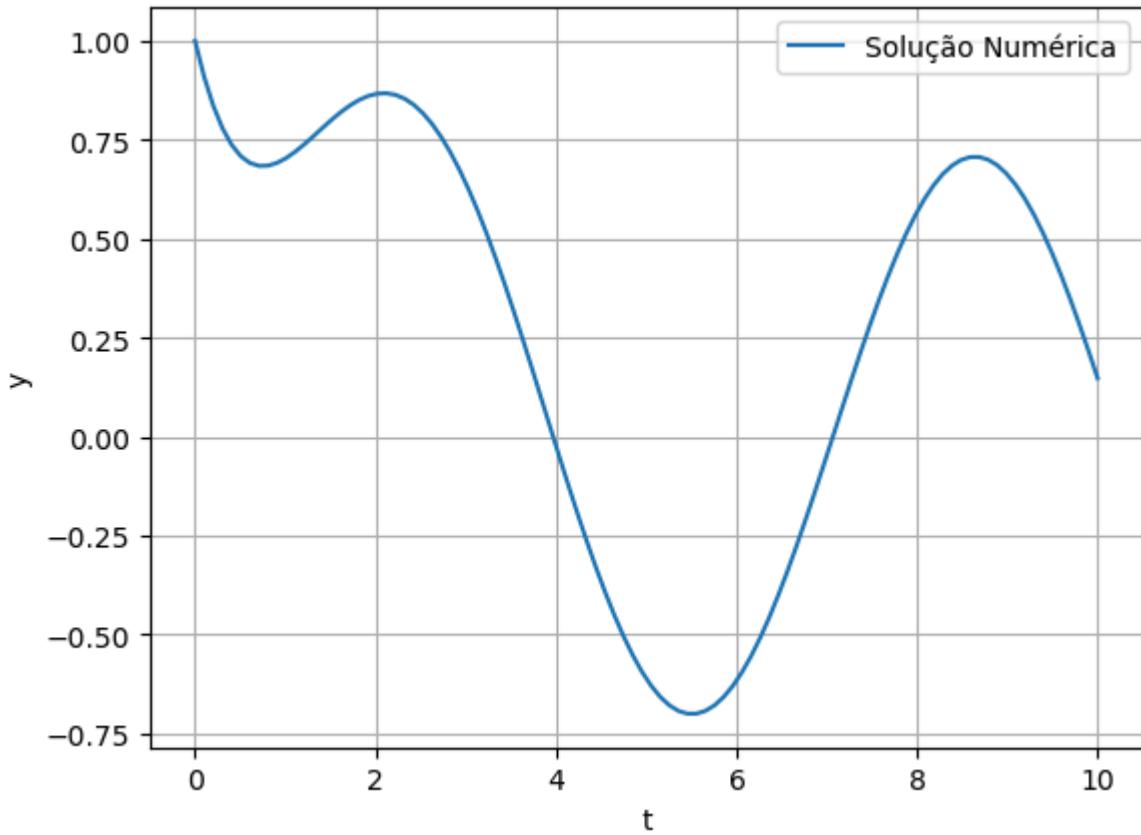
t_span = (0, 10) # Intervalo de tempo
y0 = [1] # Condição inicial
t_eval = np.linspace(0, 10, 100) # Pontos para avaliar a solução

sol_numeric = solve_ivp(f, t_span, y0, t_eval=t_eval, method='RK45')

# Plotando a solução numérica
plt.plot(sol_numeric.t, sol_numeric.y[0], label='Solução Numérica')
plt.xlabel('t')
plt.ylabel('y')
```

```
plt.legend()
plt.grid()
plt.show()
```

Solução simbólica: $\text{Eq}(y(t), C1\exp(-t) + \sin(t)/2 - \cos(t)/2)$



Mais um exemplo

```
In [20]: import sympy as sp
import numpy as np
import matplotlib.pyplot as plt
from scipy.integrate import solve_ivp

# Resolvendo simbolicamente uma EDO com SymPy
t = sp.Symbol('t')
y = sp.Function('y')(t)
deq = sp.Eq(y.diff(t), -y + sp.sin(t)) # y' = -y + sin(t)
sol = sp.dsolve(deq, y)
print("Solução simbólica:", sol)

# Resolvendo numericamente com scipy.integrate.solve_ivp
def f(t, y):
    return -y + np.sin(t)

t_span = (0, 10) # Intervalo de tempo
y0 = [1] # Condição inicial
t_eval = np.linspace(0, 10, 100) # Pontos para avaliar a solução

sol_numeric = solve_ivp(f, t_span, y0, t_eval=t_eval, method='RK45')

# Plotando a solução numérica
plt.plot(sol_numeric.t, sol_numeric.y[0], label='Solução Numérica')
plt.xlabel('t')
plt.ylabel('y')
```

```

plt.legend()
plt.grid()
plt.show()

# Novo exemplo: EDO de segunda ordem
x = sp.Symbol('x')
u = sp.Function('u')(x)
deq2 = sp.Eq(u.diff(x, x) - 2*u.diff(x) + u, sp.exp(x)) # u'' - 2u' + u = e^x
sol2 = sp.dsolve(deq2, u)
print("Solução simbólica da EDO de segunda ordem:", sol2)

# Resolvendo numericamente com solve_ivp
def f2(x, U):
    return [U[1], 2*U[1] - U[0] + np.exp(x)]

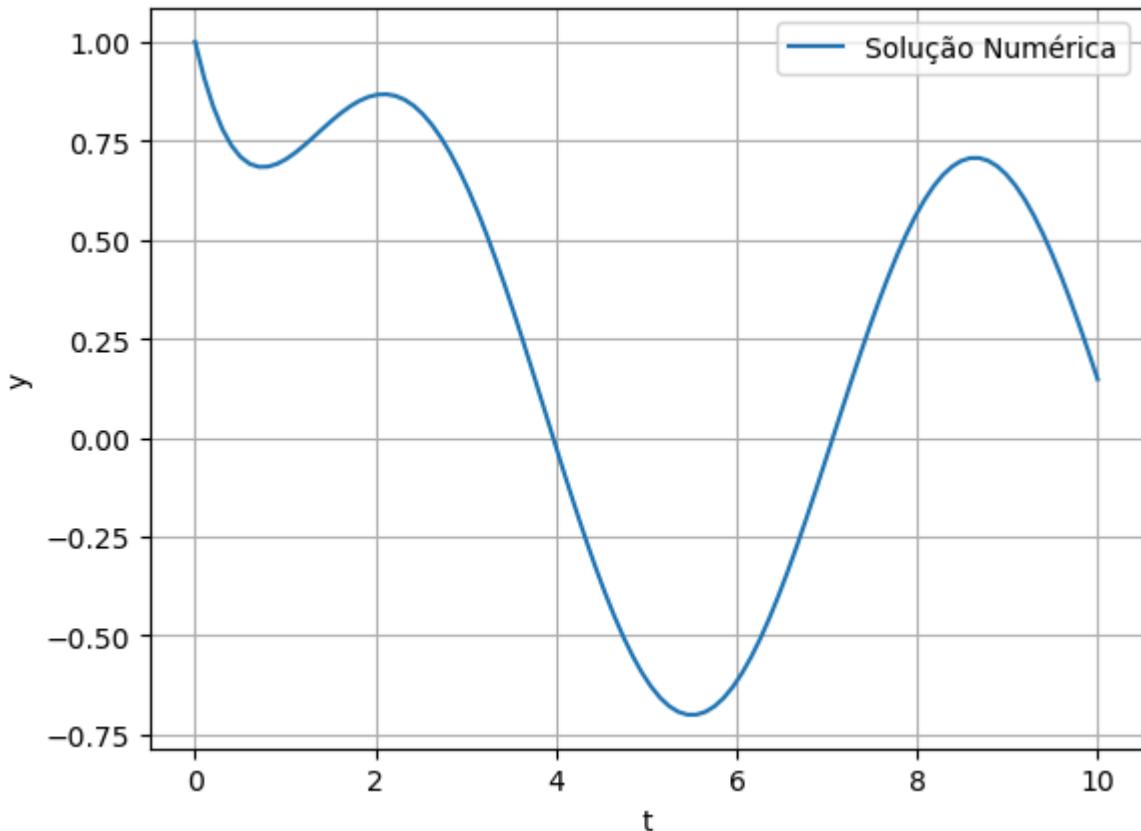
x_span = (0, 5) # Intervalo de solução
U0 = [0, 1] # Condições iniciais: u(0) = 0, u'(0) = 1
x_eval = np.linspace(0, 5, 100)

sol_numeric2 = solve_ivp(f2, x_span, U0, t_eval=x_eval, method='RK45')

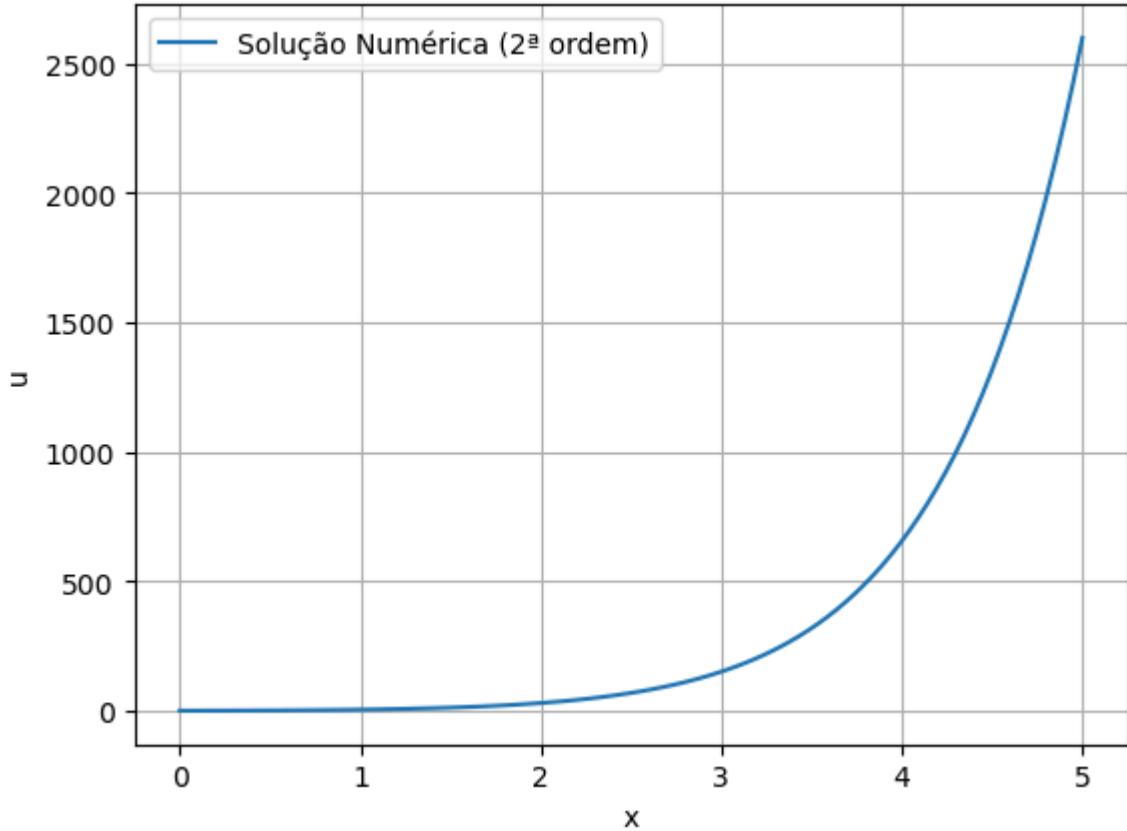
# Plotando a solução numérica
plt.plot(sol_numeric2.t, sol_numeric2.y[0], label='Solução Numérica (2ª ordem)')
plt.xlabel('x')
plt.ylabel('u')
plt.legend()
plt.grid()
plt.show()

```

Solução simbólica: Eq(y(t), C1*exp(-t) + sin(t)/2 - cos(t)/2)



Solução simbólica da EDO de segunda ordem: Eq(u(x), (C1 + x*(C2 + x/2))*exp(x))



```
In [21]: # pendulo
import numpy as np
import matplotlib.pyplot as plt
from scipy.integrate import solve_ivp

# Sistema de equações diferenciais
def pendulo(t, y):
    theta, omega = y
    dtheta_dt = omega
    domega_dt = -0.5 * omega - 9.81 * np.sin(theta)
    return [dtheta_dt, domega_dt]

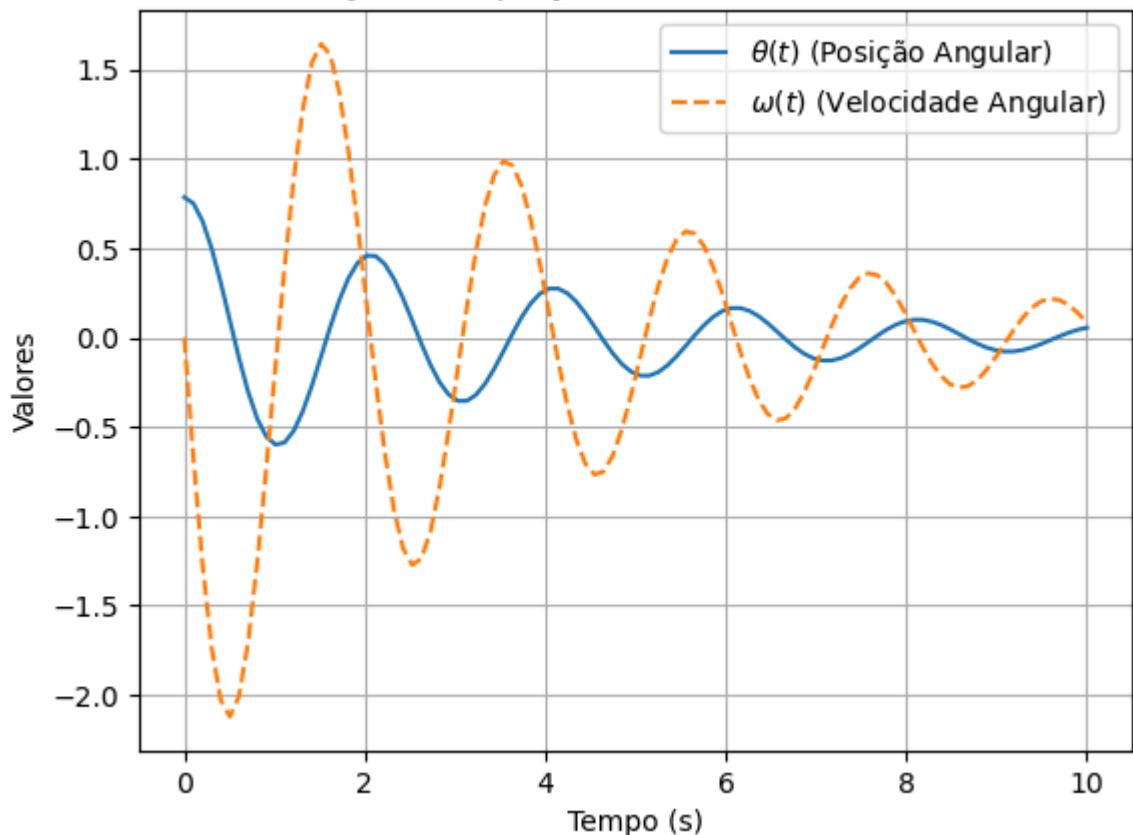
# Intervalo de tempo
t_span = (0, 10)
t_eval = np.linspace(0, 10, 100)

# Condições iniciais: theta(0) = pi/4, omega(0) = 0
y0 = [np.pi/4, 0]

# Resolver EDO usando solve_ivp
sol = solve_ivp(pendulo, t_span, y0, t_eval=t_eval, method='RK45')

# Plotar a solução
plt.plot(sol.t, sol.y[0], label=r"$\theta(t)$ (Posição Angular)")
plt.plot(sol.t, sol.y[1], label=r"$\omega(t)$ (Velocidade Angular)", linestyle=":")
plt.xlabel("Tempo (s)")
plt.ylabel("Valores")
plt.title("Solução da Equação do Pêndulo Amortecido")
plt.legend()
plt.grid()
plt.show()
```

Solução da Equação do Pêndulo Amortecido



In []: