

Regressão, Interpolação e Extrapolação Numéricas

Alexandre Rosas

Departamento de Física
Universidade Federal da Paraíba

29 de Maio de 2009

O problema

Quem é quem

- Um problema muito comum na física é o de conhecermos os valores de uma **função** em uma série de **pontos** e desejamos fazer **previsões ou estimativas fora** deles
- **Conhecimento** da **forma analítica** subjacente ao problema
→ estimar parâmetros da função
Regressão
- **Estimar** valor da função **entre os valores conhecidos** →
interpolação
- **Estimar** valor da função **fora do intervalo de valores conhecidos** →
extrapolação

O problema

Quem é quem

- Um problema muito comum na física é o de conhecermos os valores de uma **função** em uma série de **pontos** e desejamos fazer **previsões ou estimativas fora** deles
- **Conhecimento da forma analítica** subjacente ao problema
→ **estimar parâmetros da função**

Regressão

- **Estimar** valor da função **entre os valores conhecidos** →
interpolação
- **Estimar** valor da função **fora do intervalo de valores conhecidos** →
extrapolação

O problema

Quem é quem

- Um problema muito comum na física é o de conhecermos os valores de uma **função** em uma série de **pontos** e desejamos fazer **previsões ou estimativas fora** deles
- **Conhecimento** da **forma analítica** subjacente ao problema
→ **estimar parâmetros da função**

Regressão

- **Estimar** valor da função **entre os valores conhecidos** →
interpolação
- **Estimar** valor da função **fora do intervalo de valores conhecidos** →
extrapolação

O problema

Quem é quem

- Um problema muito comum na física é o de conhecermos os valores de uma **função** em uma série de **pontos** e desejamos fazer **previsões ou estimativas fora** deles
- **Conhecimento** da **forma analítica** subjacente ao problema
→ estimar parâmetros da função

Regressão

- **Estimar** valor da função **entre os valores conhecidos** → interpolação
- **Estimar** valor da função **fora do intervalo de valores conhecidos** → extrapolação

O problema

Quem é quem

- Um problema muito comum na física é o de conhecermos os valores de uma **função** em uma série de **pontos** e desejamos fazer **previsões ou estimativas fora** deles
- **Conhecimento** da **forma analítica** subjacente ao problema
→ estimar parâmetros da função

Regressão

- **Estimar** valor da função **entre os valores conhecidos** → interpolação
- **Estimar** valor da função **fora do intervalo de valores conhecidos** → extrapolação

O que usar?

- **Ajuste de dados** é mais confiável que **interpolação** é mais confiável que **extrapolação**
- Os algoritmos para **interpolação** "servem" para **extrapolação**
- Contudo, são muito menos confiáveis

O que usar?

- **Ajuste de dados** é mais confiável que **interpolação** é mais confiável que **extrapolação**
- Os algoritmos para **interpolação** "servem" para **extrapolação**
- Contudo, são muito menos confiáveis

O que usar?

- **Ajuste de dados** é mais confiável que **interpolação** é mais confiável que **extrapolação**
- Os algoritmos para **interpolação** "servem" para **extrapolação**
- Contudo, são muito menos confiáveis

Interpolação polinomial

Polinômios

- Suponha que conheçamos $y_i = f(x_i)$ em $N + 1$ pontos $x_0 < x_1 < \dots < x_N$
- Existe um **único** polinômio $P_N(x)$ de grau N que **passa por todos** eles $P_N(x_i) = y_i$

$$P_N(x) = a_0 + a_1(x-x_0) + a_2(x-x_0)(x-x_1) + \dots + a_N(x-x_0)(x-x_1)\dots(x-x_{N-1})$$

$$a_0 = y_0$$

$$a_0 + a_1(x_1 - x_0) = y_1$$

$$a_0 + a_1(x_2 - x_0) + a_2(x_2 - x_0)(x_2 - x_1) = y_2$$

...

...

...

...

Interpolação polinomial

Polinômios

- Suponha que conheçamos $y_i = f(x_i)$ em $N + 1$ pontos $x_0 < x_1 < \dots < x_N$
- Existe um **único** polinômio $P_N(x)$ de grau N que **passa por todos** eles $P_N(x_i) = y_i$

$$P_N(x) = a_0 + a_1(x-x_0) + a_2(x-x_0)(x-x_1) + \dots + a_N(x-x_0)(x-x_1)\dots(x-x_{N-1})$$

$$a_0 = y_0$$

$$a_0 + a_1(x_1 - x_0) = y_1$$

$$a_0 + a_1(x_2 - x_0) + a_2(x_2 - x_0)(x_2 - x_1) = y_2$$

...

...

...

...

Interpolação polinomial

Polinômios

- Suponha que conheçamos $y_i = f(x_i)$ em $N + 1$ pontos $x_0 < x_1 < \dots < x_N$
- Existe um **único** polinômio $P_N(x)$ de grau N que **passa por todos** eles $P_N(x_i) = y_i$

$$P_N(x) = a_0 + a_1(x-x_0) + a_2(x-x_0)(x-x_1) + \dots + a_N(x-x_0)(x-x_1) \dots (x-x_{N-1})$$

$$a_0 = y_0$$

$$a_0 + a_1(x_1 - x_0) = y_1$$

$$a_0 + a_1(x_2 - x_0) + a_2(x_2 - x_0)(x_2 - x_1) = y_2$$

...

...

...

...

Interpolação polinomial

Polinômios

- Suponha que conheçamos $y_i = f(x_i)$ em $N + 1$ pontos $x_0 < x_1 < \dots < x_N$
- Existe um **único** polinômio $P_N(x)$ de grau N que **passa por todos** eles $P_N(x_i) = y_i$

$$P_N(x) = a_0 + a_1(x - x_0) + a_2(x - x_0)(x - x_1) + \dots + a_N(x - x_0)(x - x_1) \dots (x - x_{N-1})$$

$$a_0 = y_0$$

$$a_0 + a_1(x_1 - x_0) = y_1$$

$$a_0 + a_1(x_2 - x_0) + a_2(x_2 - x_0)(x_2 - x_1) = y_2$$

$$\dots \quad \dots \quad \dots \quad \dots$$

Interpolação polinomial

Polinômios

- Suponha que conheçamos $y_i = f(x_i)$ em $N + 1$ pontos $x_0 < x_1 < \dots < x_N$
- Existe um **único** polinômio $P_N(x)$ de grau N que **passa por todos** eles $P_N(x_i) = y_i$

$$P_N(x) = a_0 + a_1(x - x_0) + a_2(x - x_0)(x - x_1) + \dots + a_N(x - x_0)(x - x_1) \dots (x - x_{N-1})$$

$$a_0 = y_0$$

$$a_0 + a_1(x_1 - x_0) = y_1$$

$$a_0 + a_1(x_2 - x_0) + a_2(x_2 - x_0)(x_2 - x_1) = y_2$$

...

...

...

...

Interpolação polinomial

Polinômios

- Suponha que conheçamos $y_i = f(x_i)$ em $N + 1$ pontos $x_0 < x_1 < \dots < x_N$
- Existe um **único** polinômio $P_N(x)$ de grau N que **passa por todos** eles $P_N(x_i) = y_i$

$$P_N(x) = a_0 + a_1(x - x_0) + a_2(x - x_0)(x - x_1) + \dots + a_N(x - x_0)(x - x_1) \dots (x - x_{N-1})$$

$$a_0 = y_0$$

$$a_0 + a_1(x_1 - x_0) = y_1$$

$$a_0 + a_1(x_2 - x_0) + a_2(x_2 - x_0)(x_2 - x_1) = y_2$$

...

...

...

...

Cálculo dos coeficientes

1 $a_0 = f(x_0)$

2 $f_0(x) = \frac{f(x) - f(x_0)}{x - x_0} = a_1 + a_2(x - x_1) + \dots + a_N(x - x_1) \cdots (x - x_{N-1}) \Rightarrow a_1 = f'_0(x_1)$

3 $f_1(x) = \frac{f_0(x) - f_0(x_1)}{x - x_1} = a_2 + a_3(x - x_2) + \dots + a_N(x - x_2) \cdots (x - x_{N-1}) \Rightarrow a_2 = f'_1(x_2)$

4 Em geral, temos

$$f_{k-1}(x) = \frac{f_{k-2}(x) - f_{k-2}(x_{k-1})}{x - x_{k-1}} =$$
$$a_k + a_{k+1}(x - x_k) + \dots + a_N(x - x_k) \cdots (x - x_{N-1})$$
$$\Rightarrow a_k = f'_{k-1}(x_k)$$

Cálculo dos coeficientes

1 $a_0 = f(x_0)$

2 $f_0(x) = \frac{f(x) - f(x_0)}{x - x_0} = a_1 + a_2(x - x_1) + \dots + a_N(x - x_1) \cdots (x - x_{N-1}) \Rightarrow a_1 = f'_0(x_1)$

3 $f_1(x) = \frac{f_0(x) - f_0(x_1)}{x - x_1} = a_2 + a_3(x - x_2) + \dots + a_N(x - x_2) \cdots (x - x_{N-1}) \Rightarrow a_2 = f'_1(x_2)$

4 Em geral, temos

$$f_{k-1}(x) = \frac{f_{k-2}(x) - f_{k-2}(x_{k-1})}{x - x_{k-1}} = a_k + a_{k+1}(x - x_k) + \dots + a_N(x - x_k) \cdots (x - x_{N-1})$$
$$\Rightarrow a_k = f'_{k-1}(x_k)$$

Cálculo dos coeficientes

1 $a_0 = f(x_0)$

2 $f_0(x) = \frac{f(x) - f(x_0)}{x - x_0} = a_1 + a_2(x - x_1) + \dots + a_N(x - x_1) \cdots (x - x_{N-1}) \Rightarrow a_1 = f'_0(x_1)$

3 $f_1(x) = \frac{f_0(x) - f_0(x_1)}{x - x_1} = a_2 + a_3(x - x_2) + \dots + a_N(x - x_2) \cdots (x - x_{N-1}) \Rightarrow a_2 = f'_1(x_2)$

4 Em geral, temos

$$f_{k-1}(x) = \frac{f_{k-2}(x) - f_{k-2}(x_{k-1})}{x - x_{k-1}} = a_k + a_{k+1}(x - x_k) + \dots + a_N(x - x_k) \cdots (x - x_{N-1})$$
$$\Rightarrow a_k = f'_{k-1}(x_k)$$

Cálculo dos coeficientes

1 $a_0 = f(x_0)$

2 $f_0(x) = \frac{f(x) - f(x_0)}{x - x_0} = a_1 + a_2(x - x_1) + \dots + a_N(x - x_1) \cdots (x - x_{N-1}) \Rightarrow a_1 = f'_0(x_1)$

3 $f_1(x) = \frac{f_0(x) - f_0(x_1)}{x - x_1} = a_2 + a_3(x - x_2) + \dots + a_N(x - x_2) \cdots (x - x_{N-1}) \Rightarrow a_2 = f'_1(x_2)$

4 Em geral, temos

$$f_{k-1}(x) = \frac{f_{k-2}(x) - f_{k-2}(x_{k-1})}{x - x_{k-1}} = a_k + a_{k+1}(x - x_k) + \dots + a_N(x - x_k) \cdots (x - x_{N-1}) \Rightarrow a_k = f'_{k-1}(x_k)$$

Cálculo dos coeficientes

1 $a_0 = f(x_0)$

2 $f_0(x) = \frac{f(x) - f(x_0)}{x - x_0} = a_1 + a_2(x - x_1) + \dots + a_N(x - x_1) \cdots (x - x_{N-1}) \Rightarrow a_1 = f'_0(x_1)$

3 $f_1(x) = \frac{f_0(x) - f_0(x_1)}{x - x_1} = a_2 + a_3(x - x_2) + \dots + a_N(x - x_2) \cdots (x - x_{N-1}) \Rightarrow a_2 = f'_1(x_2)$

4 Em geral, temos

$$f_{k-1}(x) = \frac{f_{k-2}(x) - f_{k-2}(x_{k-1})}{x - x_{k-1}} = a_k + a_{k+1}(x - x_k) + \dots + a_N(x - x_k) \cdots (x - x_{N-1}) \Rightarrow a_k = f'_{k-1}(x_k)$$

Cálculo dos coeficientes

1 $a_0 = f(x_0)$

2 $f_0(x) = \frac{f(x) - f(x_0)}{x - x_0} = a_1 + a_2(x - x_1) + \dots + a_N(x - x_1) \cdots (x - x_{N-1}) \Rightarrow a_1 = f'_0(x_1)$

3 $f_1(x) = \frac{f_0(x) - f_0(x_1)}{x - x_1} = a_2 + a_3(x - x_2) + \dots + a_N(x - x_2) \cdots (x - x_{N-1}) \Rightarrow a_2 = f'_1(x_2)$

4 Em geral, temos

$$f_{k-1}(x) = \frac{f_{k-2}(x) - f_{k-2}(x_{k-1})}{x - x_{k-1}} = a_k + a_{k+1}(x - x_k) + \dots + a_N(x - x_k) \cdots (x - x_{N-1})$$
$$\Rightarrow a_k = f'_{k-1}(x_k)$$

Cálculo dos coeficientes

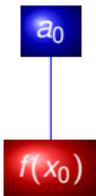
1 $a_0 = f(x_0)$

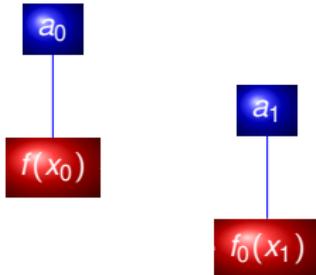
2 $f_0(x) = \frac{f(x) - f(x_0)}{x - x_0} = a_1 + a_2(x - x_1) + \dots + a_N(x - x_1) \cdots (x - x_{N-1}) \Rightarrow a_1 = f'_0(x_1)$

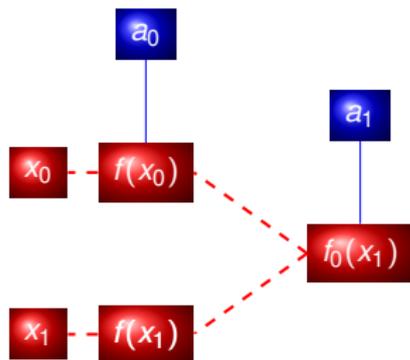
3 $f_1(x) = \frac{f_0(x) - f_0(x_1)}{x - x_1} = a_2 + a_3(x - x_2) + \dots + a_N(x - x_2) \cdots (x - x_{N-1}) \Rightarrow a_2 = f'_1(x_2)$

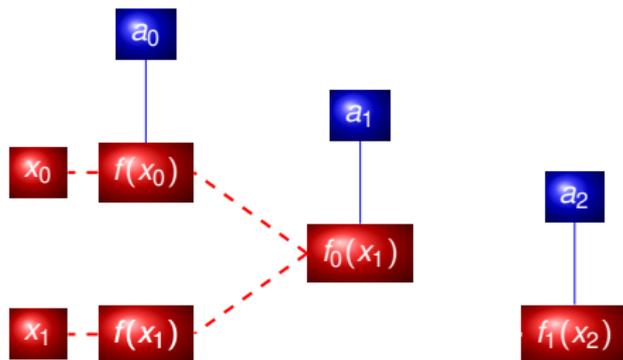
4 Em geral, temos

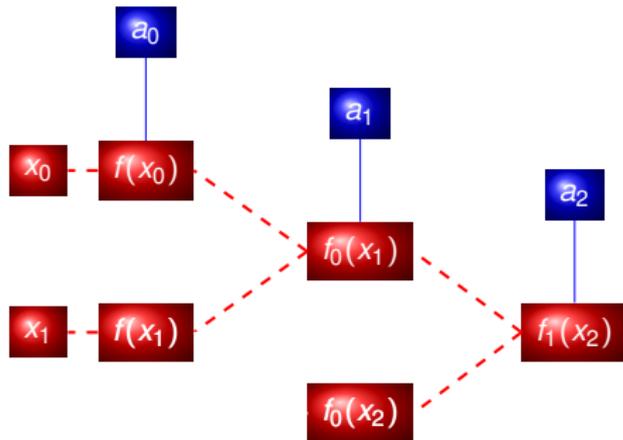
$$f_{k-1}(x) = \frac{f_{k-2}(x) - f_{k-2}(x_{k-1})}{x - x_{k-1}} = a_k + a_{k+1}(x - x_k) + \dots + a_N(x - x_k) \cdots (x - x_{N-1})$$
$$\Rightarrow a_k = f'_{k-1}(x_k)$$

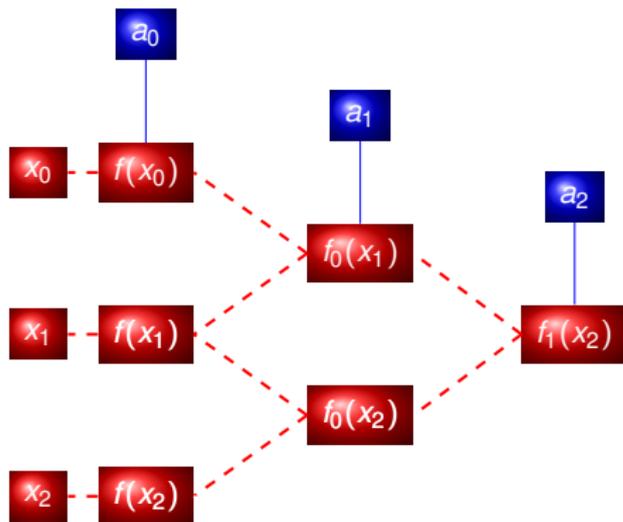


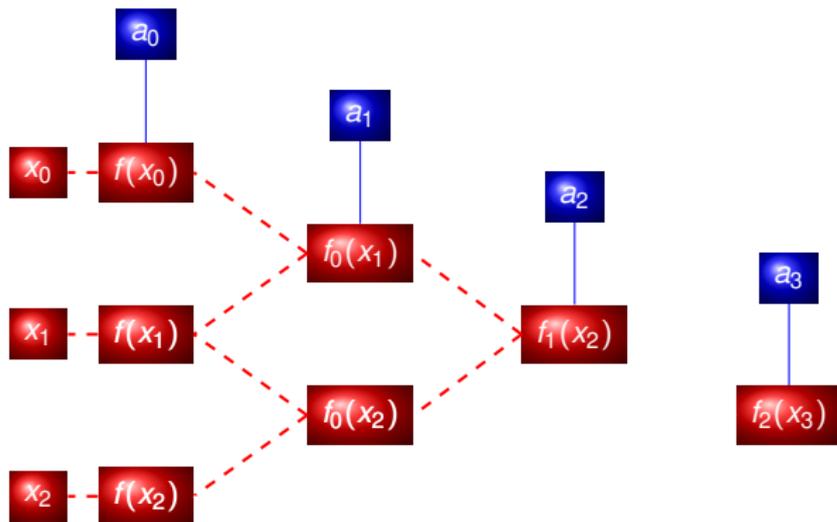


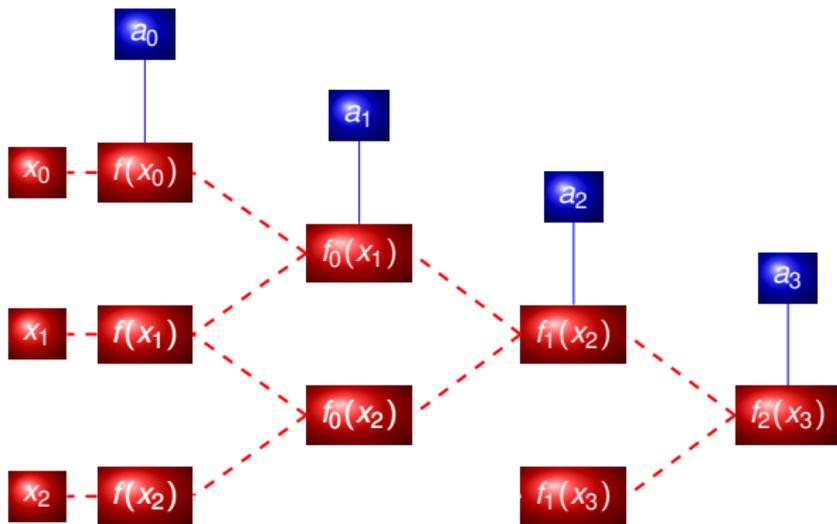


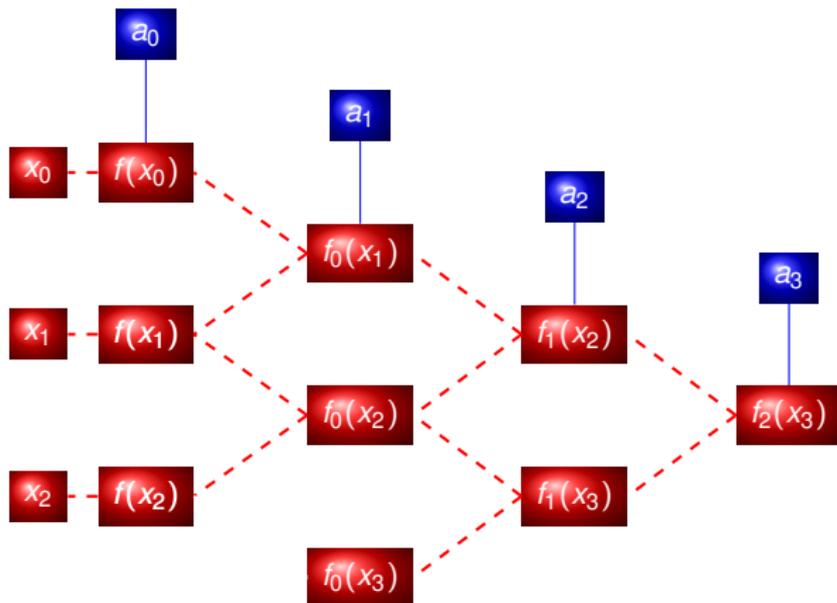


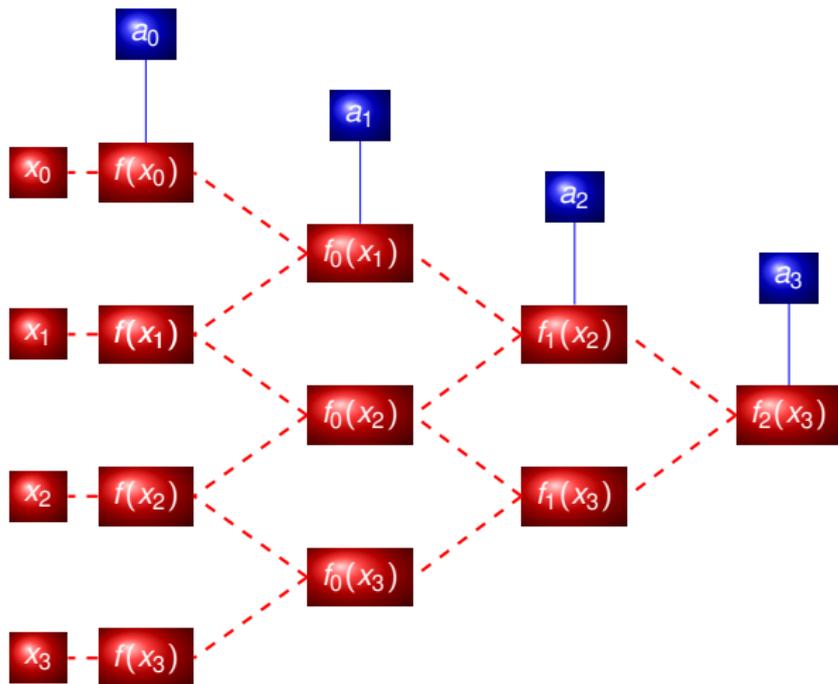




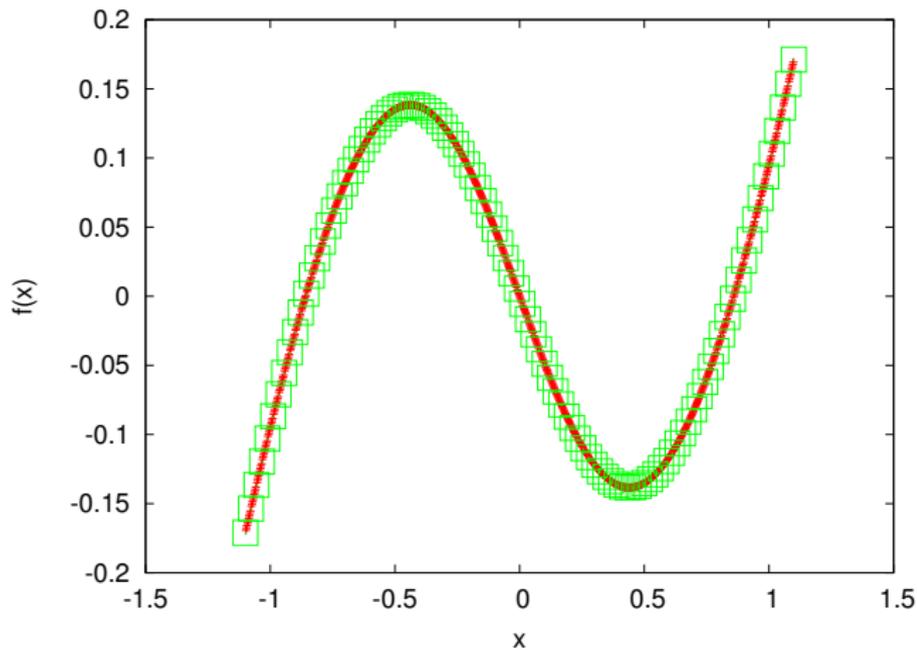








Interpolação polinomial



Observações finais

- A interpolação polinomial deve ser feita em **cada ponto**
- Em **pontos diferentes**, obtemos **polinômios diferentes**
- Erro pode ser grande próximo aos limites do intervalo.

Observações finais

- A interpolação polinomial deve ser feita em **cada ponto**
- Em **pontos diferentes**, obtemos **polinômios diferentes**
- Erro pode ser grande próximo aos limites do intervalo.

Observações finais

- A interpolação polinomial deve ser feita em **cada ponto**
- Em **pontos diferentes**, obtemos **polinômios diferentes**
- Erro pode ser grande próximo aos limites do intervalo.

Spline cúbico – objetivo

- Interpolar um conjunto de $n + 1$ pontos $\{x_i, y_i\}$ com uma função

$$s(x) = s_i(x) \quad \text{para} \quad x_i < x \leq x_{i+1} \quad n \text{ equações}$$

- $s_i(x)$ é um polinômio de grau 3 $4n$ coeficiente

- Condições de contorno

- 1 Interpolação $\Rightarrow s(x_i) = y_i$ n equações
- 2 Continuidade de $s(x) \Rightarrow s_i(x_i) = s_{i-1}(x_i) = y_i$ n equações
- 3 Continuidade de $s'(x) \Rightarrow s'_i(x_i) = s'_{i-1}(x_i)$ $(n - 1)$ equações
- 4 Continuidade de $s''(x) \Rightarrow s''_i(x_i) = s''_{i-1}(x_i)$ $(n - 1)$ equações
- 5 Condições de contorno livres nos extremos
 $s''(x_0) = s''(x_n) = 0$ 2 equações

Spline cúbico – objetivo

- Interpolar um conjunto de $n + 1$ pontos $\{x_i, y_i\}$ com uma função

$$s(x) = s_i(x) \quad \text{para} \quad x_i < x \leq x_{i+1} \quad n \text{ equações}$$

- $s_i(x)$ é um polinômio de grau 3 $4n$ coeficiente

- Condições de contorno

- 1 Interpolação $\Rightarrow s(x_i) = y_i$ n equações
- 2 Continuidade de $s(x) \Rightarrow s_i(x_i) = s_{i-1}(x_i) = y_i$ n equações
- 3 Continuidade de $s'(x) \Rightarrow s'_i(x_i) = s'_{i-1}(x_i)$ $(n - 1)$ equações
- 4 Continuidade de $s''(x) \Rightarrow s''_i(x_i) = s''_{i-1}(x_i)$ $(n - 1)$ equações
- 5 Condições de contorno livres nos extremos
 $s''(x_0) = s''(x_n) = 0$ 2 equações

Spline cúbico – objetivo

- Interpolar um conjunto de $n + 1$ pontos $\{x_i, y_i\}$ com uma função

$$s(x) = s_i(x) \quad \text{para} \quad x_i < x \leq x_{i+1} \quad n \text{ equações}$$

- $s_i(x)$ é um polinômio de grau 3 $4n$ coeficiente

- Condições de contorno

- 1 Interpolação $\Rightarrow s(x_i) = y_i$ n equações
- 2 Continuidade de $s(x) \Rightarrow s_i(x_i) = s_{i-1}(x_i) = y_i$ n equações
- 3 Continuidade de $s'(x) \Rightarrow s'_i(x_i) = s'_{i-1}(x_i)$ $(n - 1)$ equações
- 4 Continuidade de $s''(x) \Rightarrow s''_i(x_i) = s''_{i-1}(x_i)$ $(n - 1)$ equações
- 5 Condições de contorno livres nos extremos
 $s''(x_0) = s''(x_n) = 0$ 2 equações

Spline cúbico – objetivo

- Interpolar um conjunto de $n + 1$ pontos $\{x_i, y_i\}$ com uma função

$$s(x) = s_i(x) \quad \text{para} \quad x_i < x \leq x_{i+1} \quad n \text{ equações}$$

- $s_i(x)$ é um polinômio de grau 3 $4n$ coeficiente
- Condições de contorno

- 1 Interpolação $\Rightarrow s(x_i) = y_i$ n equações
- 2 Continuidade de $s(x) \Rightarrow s_i(x_i) = s_{i-1}(x_i) = y_i$ n equações
- 3 Continuidade de $s'(x) \Rightarrow s'_i(x_i) = s'_{i-1}(x_i)$ $(n - 1)$ equações
- 4 Continuidade de $s''(x) \Rightarrow s''_i(x_i) = s''_{i-1}(x_i)$ $(n - 1)$ equações
- 5 Condições de contorno livres nos extremos
 $s''(x_0) = s''(x_n) = 0$ 2 equações

Spline cúbico – objetivo

- Interpolar um conjunto de $n + 1$ pontos $\{x_i, y_i\}$ com uma função

$$s(x) = s_i(x) \quad \text{para} \quad x_i < x \leq x_{i+1} \quad n \text{ equações}$$

- $s_i(x)$ é um polinômio de grau 3 $4n$ coeficiente
- Condições de contorno

- 1 Interpolação $\Rightarrow s(x_i) = y_i$ n equações
- 2 Continuidade de $s(x) \Rightarrow s_i(x_i) = s_{i-1}(x_i) = y_i$ n equações
- 3 Continuidade de $s'(x) \Rightarrow s'_i(x_i) = s'_{i-1}(x_i)$ $(n - 1)$ equações
- 4 Continuidade de $s''(x) \Rightarrow s''_i(x_i) = s''_{i-1}(x_i)$ $(n - 1)$ equações
- 5 Condições de contorno livres nos extremos
 $s''(x_0) = s''(x_n) = 0$ 2 equações

Spline cúbico – objetivo

- Interpolar um conjunto de $n + 1$ pontos $\{x_i, y_i\}$ com uma função

$$s(x) = s_i(x) \quad \text{para} \quad x_i < x \leq x_{i+1} \quad n \text{ equações}$$

- $s_i(x)$ é um polinômio de grau 3 $4n$ coeficiente
- Condições de contorno

- 1 Interpolação $\Rightarrow s(x_i) = y_i$ n equações
- 2 Continuidade de $s(x) \Rightarrow s_i(x_i) = s_{i-1}(x_i) = y_i$ n equações
- 3 Continuidade de $s'(x) \Rightarrow s'_i(x_i) = s'_{i-1}(x_i)$ $(n - 1)$ equações
- 4 Continuidade de $s''(x) \Rightarrow s''_i(x_i) = s''_{i-1}(x_i)$ $(n - 1)$ equações
- 5 Condições de contorno livres nos extremos
 $s''(x_0) = s''(x_n) = 0$ 2 equações

Spline cúbico – objetivo

- Interpolar um conjunto de $n + 1$ pontos $\{x_i, y_i\}$ com uma função

$$s(x) = s_i(x) \quad \text{para} \quad x_i < x \leq x_{i+1} \quad n \text{ equações}$$

- $s_i(x)$ é um polinômio de grau 3 $4n$ coeficiente
- Condições de contorno

- 1 Interpolação $\Rightarrow s(x_i) = y_i$ n equações
- 2 Continuidade de $s(x) \Rightarrow s_i(x_i) = s_{i-1}(x_i) = y_i$ n equações
- 3 Continuidade de $s'(x) \Rightarrow s'_i(x_i) = s'_{i-1}(x_i)$ $(n - 1)$ equações
- 4 Continuidade de $s''(x) \Rightarrow s''_i(x_i) = s''_{i-1}(x_i)$ $(n - 1)$ equações
- 5 Condições de contorno livres nos extremos
 $s''(x_0) = s''(x_n) = 0$ 2 equações

Spline cúbico – objetivo

- Interpolar um conjunto de $n + 1$ pontos $\{x_i, y_i\}$ com uma função

$$s(x) = s_i(x) \quad \text{para} \quad x_i < x \leq x_{i+1} \quad n \text{ equações}$$

- $s_i(x)$ é um polinômio de grau 3 $4n$ coeficiente
- Condições de contorno

- 1 Interpolação $\Rightarrow s(x_i) = y_i$ n equações
- 2 Continuidade de $s(x) \Rightarrow s_i(x_i) = s_{i-1}(x_i) = y_i$ n equações
- 3 Continuidade de $s'(x) \Rightarrow s'_i(x_i) = s'_{i-1}(x_i)$ $(n - 1)$ equações
- 4 Continuidade de $s''(x) \Rightarrow s''_i(x_i) = s''_{i-1}(x_i)$ $(n - 1)$ equações
- 5 Condições de contorno livres nos extremos
 $s''(x_0) = s''(x_n) = 0$ 2 equações

Spline cúbico – objetivo

- Interpolar um conjunto de $n + 1$ pontos $\{x_i, y_i\}$ com uma função

$$s(x) = s_i(x) \quad \text{para} \quad x_i < x \leq x_{i+1} \quad n \text{ equações}$$

- $s_i(x)$ é um polinômio de grau 3 $4n$ coeficiente

- Condições de contorno

- 1 Interpolação $\Rightarrow s(x_i) = y_i$ n equações
- 2 Continuidade de $s(x) \Rightarrow s_i(x_i) = s_{i-1}(x_i) = y_i$ n equações
- 3 Continuidade de $s'(x) \Rightarrow s'_i(x_i) = s'_{i-1}(x_i)$ $(n - 1)$ equações
- 4 Continuidade de $s''(x) \Rightarrow s''_i(x_i) = s''_{i-1}(x_i)$ $(n - 1)$ equações
- 5 Condições de contorno livres nos extremos
 $s''(x_0) = s''(x_n) = 0$ 2 equações

Spline cúbico – objetivo

- Interpolar um conjunto de $n + 1$ pontos $\{x_i, y_i\}$ com uma função

$$s(x) = s_i(x) \quad \text{para} \quad x_i < x \leq x_{i+1} \quad n \text{ equações}$$

- $s_i(x)$ é um polinômio de grau 3 $4n$ coeficiente

- Condições de contorno

- 1 Interpolação $\Rightarrow s(x_i) = y_i$ n equações
- 2 Continuidade de $s(x) \Rightarrow s_i(x_i) = s_{i-1}(x_i) = y_i$ n equações
- 3 Continuidade de $s'(x) \Rightarrow s'_i(x_i) = s'_{i-1}(x_i)$ $(n - 1)$ equações
- 4 Continuidade de $s''(x) \Rightarrow s''_i(x_i) = s''_{i-1}(x_i)$ $(n - 1)$ equações
- 5 Condições de contorno livres nos extremos
 $s''(x_0) = s''(x_n) = 0$ 2 equações

Spline cúbico – objetivo

- Interpolar um conjunto de $n + 1$ pontos $\{x_i, y_i\}$ com uma função

$$s(x) = s_i(x) \quad \text{para} \quad x_i < x \leq x_{i+1} \quad n \text{ equações}$$

- $s_i(x)$ é um polinômio de grau 3 $4n$ coeficiente

- Condições de contorno

- 1 Interpolação $\Rightarrow s(x_i) = y_i$ n equações
- 2 Continuidade de $s(x) \Rightarrow s_i(x_i) = s_{i-1}(x_i) = y_i$ n equações
- 3 Continuidade de $s'(x) \Rightarrow s'_i(x_i) = s'_{i-1}(x_i)$ $(n - 1)$ equações
- 4 Continuidade de $s''(x) \Rightarrow s''_i(x_i) = s''_{i-1}(x_i)$ $(n - 1)$ equações
- 5 Condições de contorno livres nos extremos
 $s''(x_0) = s''(x_n) = 0$ 2 equações

Determinação de $s_j(x)$

$$s_j(x) = a_j(x - x_j)^3 + b_j(x - x_{j+1})^3 + c_j(x - x_j) + d_j(x - x_{j+1})$$

Precisamos, portanto, calcular $\{a_j, b_j, c_j, d_j\}$

$$s_j''(x_j) = y_j'' = 6b_j(x_j - x_{j+1})$$

$$\Rightarrow b_j = -\frac{y_j''}{6(x_{j+1} - x_j)}$$

$$s_j''(x_{j+1}) = s_{j+1}(x_{j+1}) = y_{j+1}'' = 6a_j(x_{j+1} - x_j)$$

$$\Rightarrow a_j = \frac{y_{j+1}''}{6(x_{j+1} - x_j)}$$

$$s_j(x) = \frac{y_{j+1}''}{6h_j}(x - x_j)^3 - \frac{y_j''}{6h_j}(x - x_{j+1})^3 + c_j(x - x_j) + d_j(x - x_{j+1})$$

Determinação de $s_j(x)$

$$s_j(x) = a_j(x - x_j)^3 + b_j(x - x_{j+1})^3 + c_j(x - x_j) + d_j(x - x_{j+1})$$

Definindo y_j'' como a segunda derivada em x_j (a determinar), temos

$$s_j''(x_j) = y_j'' = 6b_j(x_j - x_{j+1})$$

$$\Rightarrow b_j = -\frac{y_j''}{6(x_{j+1} - x_j)}$$

$$s_j''(x_{j+1}) = s_{j+1}(x_{j+1}) = y_{j+1}'' = 6a_j(x_{j+1} - x_j)$$

$$\Rightarrow a_j = \frac{y_{j+1}''}{6(x_{j+1} - x_j)}$$

$$s_j(x) = \frac{y_{j+1}''}{6h_j}(x - x_j)^3 - \frac{y_j''}{6h_j}(x - x_{j+1})^3 + c_j(x - x_j) + d_j(x - x_{j+1})$$

Determinação de $s_j(x)$

$$s_j(x) = a_j(x - x_j)^3 + b_j(x - x_{j+1})^3 + c_j(x - x_j) + d_j(x - x_{j+1})$$

Definindo y_j'' como a segunda derivada em x_j (a determinar), temos

$$s_j''(x_j) = y_j'' = 6b_j(x_j - x_{j+1})$$

$$\Rightarrow b_j = -\frac{y_j''}{6(x_{j+1} - x_j)}$$

$$s_j''(x_{j+1}) = s_{j+1}(x_{j+1}) = y_{j+1}'' = 6a_j(x_{j+1} - x_j)$$

$$\Rightarrow a_j = \frac{y_{j+1}''}{6(x_{j+1} - x_j)}$$

$$s_j(x) = \frac{y_{j+1}''}{6h_j}(x - x_j)^3 - \frac{y_j''}{6h_j}(x - x_{j+1})^3 + c_j(x - x_j) + d_j(x - x_{j+1})$$

Determinação de $s_j(x)$

$$s_j(x) = a_j(x - x_j)^3 + b_j(x - x_{j+1})^3 + c_j(x - x_j) + d_j(x - x_{j+1})$$

Definindo y_j'' como a segunda derivada em x_j (a determinar), temos

$$s_j''(x_j) = y_j'' = 6b_j(x_j - x_{j+1})$$

$$\Rightarrow b_j = -\frac{y_j''}{6(x_{j+1} - x_j)}$$

$$s_j''(x_{j+1}) = s_{j+1}(x_{j+1}) = y_{j+1}'' = 6a_j(x_{j+1} - x_j)$$

$$\Rightarrow a_j = \frac{y_{j+1}''}{6(x_{j+1} - x_j)}$$

$$s_j(x) = \frac{y_{j+1}''}{6h_j}(x - x_j)^3 - \frac{y_j''}{6h_j}(x - x_{j+1})^3 + c_j(x - x_j) + d_j(x - x_{j+1})$$

Determinação de $s_i(x)$

$$s_i(x) = \frac{y''_{i+1}}{6h_i}(x - x_i)^3 - \frac{y''_i}{6h_i}(x - x_{i+1})^3 + c_i(x - x_i) + d_i(x - x_{i+1})$$

Mas, $s_i(x_i) = y_i$ e $s_i(x_{i+1}) = y_{i+1}$, logo

$$y_{i+1} = \frac{y''_{i+1}}{6}h_i^2 + c_i h_i \Rightarrow c_i = \frac{y_{i+1}}{h_i} - \frac{y''_{i+1}}{6}h_i$$

$$y_i = \frac{y''_i}{6}h_i^2 - d_i h_i \Rightarrow d_i = -\frac{y_i}{h_i} + \frac{y''_i}{6}h_i$$

$$s_i(x) = \frac{y''_{i+1}}{6h_i}(x - x_i)^3 - \frac{y''_i}{6h_i}(x - x_{i+1})^3 + \left(\frac{y_{i+1}}{h_i} - \frac{y''_{i+1}}{6}h_i\right)(x - x_i) + \left(-\frac{y_i}{h_i} + \frac{y''_i}{6}h_i\right)(x - x_{i+1})$$

Determinação de $s_i(x)$

$$s_i(x) = \frac{y''_{i+1}}{6h_i}(x - x_i)^3 - \frac{y''_i}{6h_i}(x - x_{i+1})^3 + c_i(x - x_i) + d_i(x - x_{i+1})$$

Mas, $s_i(x_i) = y_i$ e $s_i(x_{i+1}) = y_{i+1}$, logo

$$y_{i+1} = \frac{y''_{i+1}}{6}h_i^2 + c_i h_i \Rightarrow c_i = \frac{y_{i+1}}{h_i} - \frac{y''_{i+1}}{6}h_i$$

$$y_i = \frac{y''_i}{6}h_i^2 - d_i h_i \Rightarrow d_i = -\frac{y_i}{h_i} + \frac{y''_i}{6}h_i$$

$$s_i(x) = \frac{y''_{i+1}}{6h_i}(x - x_i)^3 - \frac{y''_i}{6h_i}(x - x_{i+1})^3 + \left(\frac{y_{i+1}}{h_i} - \frac{y''_{i+1}}{6}h_i\right)(x - x_i) + \left(-\frac{y_i}{h_i} + \frac{y''_i}{6}h_i\right)(x - x_{i+1})$$

Determinação de $s_i(x)$

$$s_i(x) = \frac{y''_{i+1}}{6h_i}(x - x_i)^3 - \frac{y''_i}{6h_i}(x - x_{i+1})^3 + c_i(x - x_i) + d_i(x - x_{i+1})$$

Mas, $s_i(x_i) = y_i$ e $s_i(x_{i+1}) = y_{i+1}$, logo

$$y_{i+1} = \frac{y''_{i+1}}{6}h_i^2 + c_i h_i \Rightarrow c_i = \frac{y_{i+1}}{h_i} - \frac{y''_{i+1}}{6}h_i$$

$$y_i = \frac{y''_i}{6}h_i^2 - d_i h_i \Rightarrow d_i = -\frac{y_i}{h_i} + \frac{y''_i}{6}h_i$$

$$s_i(x) = \frac{y''_{i+1}}{6h_i}(x - x_i)^3 - \frac{y''_i}{6h_i}(x - x_{i+1})^3 + \left(\frac{y_{i+1}}{h_i} - \frac{y''_{i+1}}{6}h_i\right)(x - x_i) + \left(-\frac{y_i}{h_i} + \frac{y''_i}{6}h_i\right)(x - x_{i+1})$$

Determinação de y_i''

Usando a continuidade de $s'(x)$ [$s'_i(x_i) = s'_{i-1}(x_i)$], temos

$$\begin{aligned} -\frac{y_i''}{2}h_i + \left[\frac{y_{i+1}}{h_i} - \frac{y_{i+1}''}{6}h_i \right] + \left[-\frac{y_i}{h_i} + \frac{y_i''}{6}h_i \right] \\ = \frac{y_i''}{2}h_{i-1} + \left[\frac{y_i}{h_{i-1}} - \frac{y_i''}{6}h_{i-1} \right] + \left[-\frac{y_{i-1}}{h_{i-1}} + \frac{y_{i-1}''}{6}h_{i-1} \right] \end{aligned}$$

Donde

$$\begin{aligned} h_{i-1}y_{i-1}'' + 2(h_{i-1} + h_i)y_i'' + h_iy_{i+1}'' \\ = 6 \left[\frac{y_{i+1} - y_i}{h_i} - \frac{y_i - y_{i-1}}{h_{i-1}} \right] \end{aligned}$$

Determinação de y_i''

Usando a continuidade de $s'(x)$ [$s'_i(x_i) = s'_{i-1}(x_i)$], temos

$$\begin{aligned} -\frac{y_i''}{2}h_i + \left[\frac{y_{i+1}}{h_i} - \frac{y_{i+1}''}{6}h_i \right] + \left[-\frac{y_i}{h_i} + \frac{y_i''}{6}h_i \right] \\ = \frac{y_i''}{2}h_{i-1} + \left[\frac{y_i}{h_{i-1}} - \frac{y_i''}{6}h_{i-1} \right] + \left[-\frac{y_{i-1}}{h_{i-1}} + \frac{y_{i-1}''}{6}h_{i-1} \right] \end{aligned}$$

Donde

$$\begin{aligned} h_{i-1}y_{i-1}'' + 2(h_{i-1} + h_i)y_i'' + h_iy_{i+1}'' \\ = 6 \left[\frac{y_{i+1} - y_i}{h_i} - \frac{y_i - y_{i-1}}{h_{i-1}} \right] \end{aligned}$$

Determinação de y_i''

Usando a continuidade de $s'(x)$ [$s_i'(x_i) = s_{i-1}'(x_i)$], temos

$$\begin{aligned} -\frac{y_i''}{2}h_i + \left[\frac{y_{i+1}}{h_i} - \frac{y_{i+1}''}{6}h_i \right] + \left[-\frac{y_i}{h_i} + \frac{y_i''}{6}h_i \right] \\ = \frac{y_i''}{2}h_{i-1} + \left[\frac{y_i}{h_{i-1}} - \frac{y_i''}{6}h_{i-1} \right] + \left[-\frac{y_{i-1}}{h_{i-1}} + \frac{y_{i-1}''}{6}h_{i-1} \right] \end{aligned}$$

Donde

$$\begin{aligned} h_{i-1}y_{i-1}'' + 2(h_{i-1} + h_i)y_i'' + h_iy_{i+1}'' \\ = 6 \left[\frac{y_{i+1} - y_i}{h_i} - \frac{y_i - y_{i-1}}{h_{i-1}} \right] \end{aligned}$$

Algoritmo

- 1 Dado o conjunto de pontos $\{x_i, y_i\}$, resolvemos o sistema de equações acima, obtendo y_i'' .
- 2 Para um ponto qualquer x_0 , encontramos i , tal que $x_i \leq x_0 < x_{i+1}$.
- 3 Calculamos a interpolação em x_0

$$s_i(x_0) = \frac{y_{i+1}''}{6h_i}(x_0 - x_i)^3 - \frac{y_i''}{6h_i}(x_0 - x_{i+1})^3 \\ + \left(\frac{y_{i+1}}{h_i} - \frac{y_{i+1}''}{6}h_i \right) (x_0 - x_i) + \left(-\frac{y_i}{h_i} + \frac{y_i''}{6}h_i \right) (x_0 - x_{i+1})$$

Algoritmo

- 1 Dado o conjunto de pontos $\{x_i, y_i\}$, resolvemos o sistema de equações acima, obtendo y_i'' .
- 2 Para um ponto qualquer x_0 , encontramos i , tal que $x_i \leq x_0 < x_{i+1}$.
- 3 Calculamos a interpolação em x_0

$$s_i(x_0) = \frac{y_{i+1}''}{6h_i}(x_0 - x_i)^3 - \frac{y_i''}{6h_i}(x_0 - x_{i+1})^3 \\ + \left(\frac{y_{i+1}}{h_i} - \frac{y_{i+1}''}{6}h_i \right) (x_0 - x_i) + \left(-\frac{y_i}{h_i} + \frac{y_i''}{6}h_i \right) (x_0 - x_{i+1})$$

Algoritmo

- 1 Dado o conjunto de pontos $\{x_i, y_i\}$, resolvemos o sistema de equações acima, obtendo y_i'' .
- 2 Para um ponto qualquer x_0 , encontramos i , tal que $x_i \leq x_0 < x_{i+1}$.
- 3 Calculamos a interpolação em x_0

$$s_i(x_0) = \frac{y_{i+1}''}{6h_i}(x_0 - x_i)^3 - \frac{y_i''}{6h_i}(x_0 - x_{i+1})^3 \\ + \left(\frac{y_{i+1}}{h_i} - \frac{y_{i+1}''}{6} h_i \right) (x_0 - x_i) + \left(-\frac{y_i}{h_i} + \frac{y_i''}{6} h_i \right) (x_0 - x_{i+1})$$

Observações finais

- O método Spline gera uma função que pode ser avaliada para **qualquer ponto**
- Chamadas sucessivas para diferentes pontos não requerem novas interpolações
- **Suavidade** da curva é garantida

Observações finais

- O método Spline gera uma função que pode ser avaliada para **qualquer ponto**
- Chamadas sucessivas para diferentes pontos não requerem novas interpolações
- **Suavidade** da curva é garantida

Observações finais

- O método Spline gera uma função que pode ser avaliada para **qualquer ponto**
- Chamadas sucessivas para diferentes pontos não requerem novas interpolações
- **Suavidade** da curva é garantida

Objetivo e Tipos

Objetivo

- Modelar a relação entre uma ou mais variáveis dependentes e as variáveis de controle
- Conhecendo a **dependência funcional** entre as variáveis dependentes e de controle, encontrar os **parâmetros** que **melhor ajustam** a função aos dados
- A função não passa necessariamente por todos os pontos, mas deve minimizar o erro (**mínimos quadrados**)

Objetivo e Tipos

Objetivo

- Modelar a relação entre uma ou mais variáveis dependentes e as variáveis de controle
- Conhecendo a **dependência funcional** entre as variáveis dependentes e de controle, encontrar os **parâmetros** que **melhor ajustam** a função aos dados
- A função não passa necessariamente por todos os pontos, mas deve minimizar o erro (mínimos quadrados)

Objetivo e Tipos

Objetivo

- Modelar a relação entre uma ou mais variáveis dependentes e as variáveis de controle
- Conhecendo a **dependência funcional** entre as variáveis dependentes e de controle, encontrar os **parâmetros** que **melhor ajustam** a função aos dados
- A função **não** passa necessariamente por **todos os pontos**, mas deve **minimizar o erro** (**mínimos quadrados**)

Mínimos quadrados

Definições

- Assim como no caso da interpolação, conhecemos N pontos $\{x_i, y_i\}$
- Temos também uma função $f(x; a_1, a_2, \dots, a_k)$, onde $\{a_j\}$ são os parâmetros a ajustar a função
- Por exemplo, $f(x) = a_1x + a_2$
- Podemos "medir" a distância entre a função e os pontos (erro) pela soma dos quadrados das diferenças

$$\chi^2 = \sum_{i=1}^N [f(x_i) - y_i]^2$$

Mínimos quadrados \Rightarrow minimizar χ^2

Mínimos quadrados

Definições

- Assim como no caso da interpolação, conhecemos N pontos $\{x_i, y_i\}$
- Temos também uma função $f(x; a_1, a_2, \dots, a_k)$, onde $\{a_j\}$ são os parâmetros a ajustar à função
- Por exemplo, $f(x) = a_1x + a_2$
- Podemos "medir" a distância entre a função e os pontos (erro) pela soma dos quadrados das diferenças

$$\chi^2 = \sum_{i=1}^N [f(x_i) - y_i]^2$$

Mínimos quadrados \Rightarrow minimizar χ^2

Mínimos quadrados

Definições

- Assim como no caso da interpolação, conhecemos N pontos $\{x_i, y_i\}$
- Temos também uma função $f(x; a_1, a_2, \dots, a_k)$, onde $\{a_j\}$ são os parâmetros ajustarão a função
- Por exemplo, $f(x) = a_1x + a_2$
- Podemos "medir" a distância entre a função e os pontos (erro) pela soma dos quadrados das diferenças

$$\chi^2 = \sum_{i=1}^N [f(x_i) - y_i]^2$$

Mínimos quadrados \Rightarrow minimizar χ^2

Mínimos quadrados

Definições

- Assim como no caso da interpolação, conhecemos N pontos $\{x_i, y_i\}$
- Temos também uma função $f(x; a_1, a_2, \dots, a_k)$, onde $\{a_j\}$ são os parâmetros a ajustar à função
- Por exemplo, $f(x) = a_1x + a_2$
- Podemos "medir" a distância entre a função e os pontos (**erro**) pela soma dos quadrados das diferenças

$$\chi^2 = \sum_{i=1}^N [f(x_i) - y_i]^2$$

Mínimos quadrados \Rightarrow minimizar χ^2

Mínimos quadrados

Definições

- Assim como no caso da interpolação, conhecemos N pontos $\{x_i, y_i\}$
- Temos também uma função $f(x; a_1, a_2, \dots, a_k)$, onde $\{a_j\}$ são os parâmetros ajustarão a função
- Por exemplo, $f(x) = a_1x + a_2$
- Podemos "medir" a distância entre a função e os pontos (erro) pela soma dos quadrados das diferenças

$$\chi^2 = \sum_{i=1}^N [f(x_i) - y_i]^2$$

Mínimos quadrados \Rightarrow minimizar χ^2

Regressão linear: um exemplo

$$f(x) = a_0 + a_1 x$$

$$\text{Minimizar } \chi^2 = \sum_{i=1}^N [a_1 x_i + a_0 - y_i]^2$$

$$\frac{\partial \chi^2}{\partial a_1} = 2 \left[a_1 \left(\sum_{i=1}^N x_i^2 \right) + a_0 \left(\sum_{i=1}^N x_i \right) - \left(\sum_{i=1}^N x_i y_i \right) \right] = 0$$

$$\frac{\partial \chi^2}{\partial a_0} = 2 \left[a_1 \left(\sum_{i=1}^N x_i \right) + N a_0 - \left(\sum_{i=1}^N y_i \right) \right] = 0$$

Regressão linear

Resolvendo o sistema para a_1 e a_0 temos

$$a_1 = \frac{N \left(\sum_{i=1}^N x_i y_i \right) - \left(\sum_{i=1}^N x_i \right) \left(\sum_{i=1}^N y_i \right)}{N \left(\sum_{i=1}^N x_i^2 \right) - \left(\sum_{i=1}^N x_i \right)^2}$$
$$a_0 = \frac{\left(\sum_{i=1}^N x_i^2 \right) \left(\sum_{i=1}^N y_i \right) - \left(\sum_{i=1}^N x_i \right) \left(\sum_{i=1}^N x_i y_i \right)}{N \left(\sum_{i=1}^N x_i^2 \right) - \left(\sum_{i=1}^N x_i \right)^2}$$

Regressão linear

Interpretação física

$$a_1 = \frac{\langle xy \rangle - \langle x \rangle \langle y \rangle}{\langle x^2 \rangle - \langle x \rangle^2}$$
$$a_0 = \frac{\langle x^2 \rangle \langle y \rangle - \langle x \rangle \langle xy \rangle}{\langle x^2 \rangle - \langle x \rangle^2}$$

Qualidade da regressão

Coeficiente de correlação

$$r = \frac{\langle xy \rangle - \langle x \rangle \langle y \rangle}{\sqrt{(\langle x^2 \rangle - \langle x \rangle^2) (\langle y^2 \rangle - \langle y \rangle^2)}}$$

- Dados correlacionados:

$$y = f(x) = a_0 + a_1 x \Rightarrow r = \text{sinal}(a_1)$$

- $r > 0 \rightarrow$ dados correlacionados
- $r < 0 \rightarrow$ dados anti-correlacionados
- $r = 0 \Rightarrow y$ não depende de x

Quanto mais próximo de 1 for o valor de r^2 ,
melhor a regressão

Qualidade da regressão

Coeficiente de correlação

$$r = \frac{\langle xy \rangle - \langle x \rangle \langle y \rangle}{\sqrt{(\langle x^2 \rangle - \langle x \rangle^2) (\langle y^2 \rangle - \langle y \rangle^2)}}$$

- Dados correlacionados:

$$y = f(x) = a_0 + a_1 x \Rightarrow r = \text{sinal}(a_1)$$

- $r > 0 \rightarrow$ dados correlacionados
- $r < 0 \rightarrow$ dados anti-correlacionados
- $r = 0 \Rightarrow y$ não depende de x

Quanto mais próximo de 1 for o valor de r^2 ,
melhor a regressão

Qualidade da regressão

Coeficiente de correlação

$$r = \frac{\langle xy \rangle - \langle x \rangle \langle y \rangle}{\sqrt{(\langle x^2 \rangle - \langle x \rangle^2) (\langle y^2 \rangle - \langle y \rangle^2)}}$$

- Dados correlacionados:

$$y = f(x) = a_0 + a_1 x \Rightarrow r = \text{sinal}(a_1)$$

- $r > 0 \rightarrow$ dados correlacionados
- $r < 0 \rightarrow$ dados anti-correlacionados
- $r = 0 \Rightarrow y$ não depende de x

Quanto mais próximo de 1 for o valor de r^2 ,
melhor a regressão

Qualidade da regressão

Coeficiente de correlação

$$r = \frac{\langle xy \rangle - \langle x \rangle \langle y \rangle}{\sqrt{(\langle x^2 \rangle - \langle x \rangle^2) (\langle y^2 \rangle - \langle y \rangle^2)}}$$

- Dados correlacionados:

$$y = f(x) = a_0 + a_1 x \Rightarrow r = \text{sinal}(a_1)$$

- $r > 0 \rightarrow$ dados correlacionados
- $r < 0 \rightarrow$ dados anti-correlacionados
- $r = 0 \Rightarrow y$ não depende de x

Quanto mais próximo de 1 for o valor de r^2 ,
melhor a regressão

Qualidade da regressão

Coeficiente de correlação

$$r = \frac{\langle xy \rangle - \langle x \rangle \langle y \rangle}{\sqrt{(\langle x^2 \rangle - \langle x \rangle^2) (\langle y^2 \rangle - \langle y \rangle^2)}}$$

- Dados correlacionados:

$$y = f(x) = a_0 + a_1 x \Rightarrow r = \text{sinal}(a_1)$$

- $r > 0 \rightarrow$ dados correlacionados
- $r < 0 \rightarrow$ dados anti-correlacionados
- $r = 0 \Rightarrow y$ não depende de x

Quanto mais próximo de 1 for o valor de r^2 ,
melhor a regressão

Qualidade da regressão

Coeficiente de correlação

$$r = \frac{\langle xy \rangle - \langle x \rangle \langle y \rangle}{\sqrt{(\langle x^2 \rangle - \langle x \rangle^2) (\langle y^2 \rangle - \langle y \rangle^2)}}$$

- Dados correlacionados:

$$y = f(x) = a_0 + a_1 x \Rightarrow r = \text{sinal}(a_1)$$

- $r > 0 \rightarrow$ dados correlacionados
- $r < 0 \rightarrow$ dados anti-correlacionados
- $r = 0 \Rightarrow y$ não depende de x

**Quanto mais próximo de 1 for o valor de r^2 ,
melhor a regressão**

Regressão linear: teoria geral

- No exemplo anterior, consideramos a função

$$f(x) = a_0 + a_1x$$

- O termo **linear NÃO** se refere à variável x
- Para a regressão linear o importante é a linearidade de a_0 e a_1
- Em geral, podemos fazer uma regressão linear da função

$$f(x) = \sum_k a_k g_k(x)$$

onde $g_k(x)$ pode ser qualquer.

Regressão linear: teoria geral

- No exemplo anterior, consideramos a função

$$f(x) = a_0 + a_1x$$

- O termo **linear NÃO** se refere à variável x
- Para a **regressão linear** o importante é a linearidade de a_0 e a_1
- Em geral, podemos fazer uma **regressão linear** da função

$$f(x) = \sum_k a_k g_k(x)$$

onde $g_k(x)$ pode ser qualquer.

Regressão linear: teoria geral

- No exemplo anterior, consideramos a função

$$f(x) = a_0 + a_1x$$

- O termo **linear NÃO** se refere à variável x
- Para a **regressão linear** o importante é a linearidade de a_0 e a_1
- Em geral, podemos fazer uma **regressão linear** da função

$$f(x) = \sum_k a_k g_k(x)$$

onde $g_k(x)$ pode ser qualquer.

Regressão linear: teoria geral

$$f(x) = \sum_k a_k g_k(x)$$

$$\text{Minimizar } \chi^2 = \sum_{i=1}^N [(\sum_k a_k g_k(x_i)) - y_i]^2$$

$$\frac{\partial \chi^2}{\partial a_j} = 2 \left[\sum_k a_k \left(\sum_{i=1}^N g_k(x_i) g_j(x_i) \right) - \left(\sum_{i=1}^N g_j(x_i) y_i \right) \right] = 0$$

Definindo $G_{kj} = \sum_{i=1}^N g_k(x_i) g_j(x_i)$ e $Y_j = \sum_{i=1}^N g_j(x_i) y_i$ temos:

$$\sum_k a_k G_{kj} = Y_j$$

Sistema linear \Rightarrow solução analítica

Linearização

Algumas funções não-lineares podem ser linearizadas

- 1 Exponencial – $f(x) = A \exp(Bx)$

Transformação: $g(x) = \ln f(x) = Bx + \ln A = a_1 x + a_0$
Regressão linear de $\{x_i, \ln(y_i)\}$

- 2 Lei de potência – $f(x) = Ax^B$

Transformação:
 $g(x) = \ln f(x) = B \ln(x) + \ln A = a_1 \ln(x) + a_0$
Regressão linear de $\{\ln(x_i), \ln(y_i)\}$

- 3 Logaritmo – $f(x) = A \ln(Bx)$

Notando que $f(x) = A \ln(x) + A \ln B = a_1 \ln(x) + a_0$
Regressão linear de $\{\ln(x_i), y_i\}$

Linearização

Algumas funções não-lineares podem ser linearizadas

- 1 Exponencial – $f(x) = A \exp(Bx)$

Transformação: $g(x) = \ln f(x) = Bx + \ln A = a_1 x + a_0$

Regressão linear de $\{x_i, \ln(y_i)\}$

- 2 Lei de potência – $f(x) = Ax^B$

Transformação:

$g(x) = \ln f(x) = B \ln(x) + \ln A = a_1 \ln(x) + a_0$

Regressão linear de $\{\ln(x_i), \ln(y_i)\}$

- 3 Logaritmo – $f(x) = A \ln(Bx)$

Notando que $f(x) = A \ln(x) + A \ln B = a_1 \ln(x) + a_0$

Regressão linear de $\{\ln(x_i), y_i\}$

Linearização

Algumas funções não-lineares podem ser linearizadas

- 1 Exponencial – $f(x) = A \exp(Bx)$
Transformação: $g(x) = \ln f(x) = Bx + \ln A = a_1 x + a_0$
Regressão linear de $\{x_i, \ln(y_i)\}$
- 2 Lei de potência – $f(x) = Ax^B$
Transformação:
 $g(x) = \ln f(x) = B \ln(x) + \ln A = a_1 \ln(x) + a_0$
Regressão linear de $\{\ln(x_i), \ln(y_i)\}$
- 3 Logaritmo – $f(x) = A \ln(Bx)$
Notando que $f(x) = A \ln(x) + A \ln B = a_1 \ln(x) + a_0$
Regressão linear de $\{\ln(x_i), y_i\}$

Linearização

Algumas funções não-lineares podem ser linearizadas

- 1 Exponencial – $f(x) = A \exp(Bx)$

Transformação: $g(x) = \ln f(x) = Bx + \ln A = a_1 x + a_0$

Regressão linear de $\{x_i, \ln(y_i)\}$

- 2 Lei de potência – $f(x) = Ax^B$

Transformação:

$g(x) = \ln f(x) = B \ln(x) + \ln A = a_1 \ln(x) + a_0$

Regressão linear de $\{\ln(x_i), \ln(y_i)\}$

- 3 Logaritmo – $f(x) = A \ln(Bx)$

Notando que $f(x) = A \ln(x) + A \ln B = a_1 \ln(x) + a_0$

Regressão linear de $\{\ln(x_i), y_i\}$

Linearização

Algumas funções não-lineares podem ser linearizadas

- 1 Exponencial – $f(x) = A \exp(Bx)$

Transformação: $g(x) = \ln f(x) = Bx + \ln A = a_1 x + a_0$

Regressão linear de $\{x_i, \ln(y_i)\}$

- 2 Lei de potência – $f(x) = Ax^B$

Transformação:

$g(x) = \ln f(x) = B \ln(x) + \ln A = a_1 \ln(x) + a_0$

Regressão linear de $\{\ln(x_i), \ln(y_i)\}$

- 3 Logaritmo – $f(x) = A \ln(Bx)$

Notando que $f(x) = A \ln(x) + A \ln B = a_1 \ln(x) + a_0$

Regressão linear de $\{\ln(x_i), y_i\}$

Linearização

Algumas funções não-lineares podem ser linearizadas

- 1 Exponencial – $f(x) = A \exp(Bx)$
Transformação: $g(x) = \ln f(x) = Bx + \ln A = a_1 x + a_0$
Regressão linear de $\{x_i, \ln(y_i)\}$
- 2 Lei de potência – $f(x) = Ax^B$
Transformação:
 $g(x) = \ln f(x) = B \ln(x) + \ln A = a_1 \ln(x) + a_0$
Regressão linear de $\{\ln(x_i), \ln(y_i)\}$
- 3 Logaritmo – $f(x) = A \ln(Bx)$
Notando que $f(x) = A \ln(x) + A \ln B = a_1 \ln(x) + a_0$
Regressão linear de $\{\ln(x_i), y_i\}$

Linearização

Algumas funções não-lineares podem ser linearizadas

- 1 Exponencial – $f(x) = A \exp(Bx)$

Transformação: $g(x) = \ln f(x) = Bx + \ln A = a_1 x + a_0$

Regressão linear de $\{x_i, \ln(y_i)\}$

- 2 Lei de potência – $f(x) = Ax^B$

Transformação:

$g(x) = \ln f(x) = B \ln(x) + \ln A = a_1 \ln(x) + a_0$

Regressão linear de $\{\ln(x_i), \ln(y_i)\}$

- 3 Logaritmo – $f(x) = A \ln(Bx)$

Notando que $f(x) = A \ln(x) + A \ln B = a_1 \ln(x) + a_0$

Regressão linear de $\{\ln(x_i), y_i\}$

Linearização

Algumas funções não-lineares podem ser linearizadas

- 1 Exponencial – $f(x) = A \exp(Bx)$
Transformação: $g(x) = \ln f(x) = Bx + \ln A = a_1 x + a_0$
Regressão linear de $\{x_i, \ln(y_i)\}$
- 2 Lei de potência – $f(x) = Ax^B$
Transformação:
 $g(x) = \ln f(x) = B \ln(x) + \ln A = a_1 \ln(x) + a_0$
Regressão linear de $\{\ln(x_i), \ln(y_i)\}$
- 3 Logaritmo – $f(x) = A \ln(Bx)$
Notando que $f(x) = A \ln(x) + A \ln B = a_1 \ln(x) + a_0$
Regressão linear de $\{\ln(x_i), y_i\}$

Linearização

Algumas funções não-lineares podem ser linearizadas

- 1 Exponencial – $f(x) = A \exp(Bx)$
Transformação: $g(x) = \ln f(x) = Bx + \ln A = a_1 x + a_0$
Regressão linear de $\{x_i, \ln(y_i)\}$
- 2 Lei de potência – $f(x) = Ax^B$
Transformação:
 $g(x) = \ln f(x) = B \ln(x) + \ln A = a_1 \ln(x) + a_0$
Regressão linear de $\{\ln(x_i), \ln(y_i)\}$
- 3 Logaritmo – $f(x) = A \ln(Bx)$
Notando que $f(x) = A \ln(x) + A \ln B = a_1 \ln(x) + a_0$
Regressão linear de $\{\ln(x_i), y_i\}$

Regressão não-linear

- Para regressões lineares, a minimização de χ^2 levou a um sistema de equações lineares
- Portanto, uma solução analítica foi possível
- No caso da regressão não-linear, isto não é possível
- Contudo, se olharmos para χ^2 no espaço de parâmetros $\{a_k\}$, o problema se resume a encontrar o mínimo → solução iterativa

Regressão não-linear

- Para regressões lineares, a minimização de χ^2 levou a um sistema de equações lineares
- Portanto, uma solução analítica foi possível
- No caso da regressão não-linear, isto não é possível
- Contudo, se olharmos para χ^2 no espaço de parâmetros $\{a_k\}$, o problema se resume a encontrar o mínimo → solução iterativa

Regressão não-linear

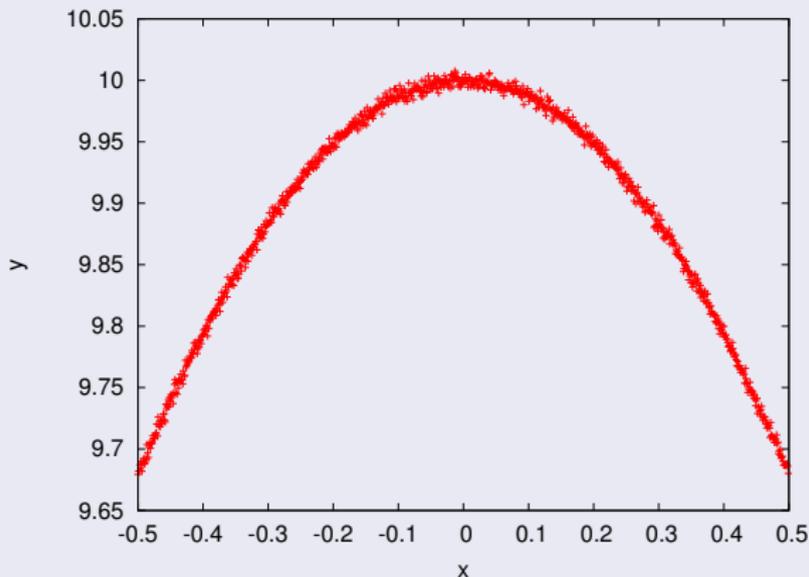
- Para regressões lineares, a minimização de χ^2 levou a um sistema de equações lineares
- Portanto, uma solução analítica foi possível
- No caso da regressão não-linear, isto não é possível
- Contudo, se olharmos para χ^2 no espaço de parâmetros $\{a_k\}$, o problema se resume a encontrar o mínimo \rightarrow solução iterativa

Regressão não-linear

- Para regressões lineares, a minimização de χ^2 levou a um sistema de equações lineares
- Portanto, uma solução analítica foi possível
- No caso da regressão não-linear, isto não é possível
- Contudo, se olharmos para χ^2 no espaço de parâmetros $\{a_k\}$, o problema se resume a encontrar o mínimo → solução iterativa

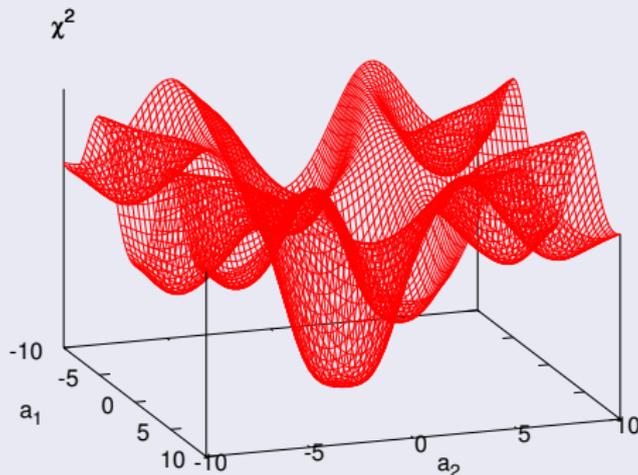
Múltiplos mínimos

Exemplo: $f(x) = 10 \cos^2(a_1 x) \cos^2(a_2 x)$



Múltiplos mínimos

Exemplo: $f(x) = 10 \cos^2(a_1 x) \cos^2(a_2 x)$



Como encontrar o mínimo?

O problema

Encontrar o mínimo de

$$\chi^2(a_1, a_2, \dots, a_s) = \sum_{k=1}^N [F_k(a_1, a_2, \dots, a_s)]$$

Métodos

Todos os métodos são **iterativos**

- 1 Steepest descent
- 2 Algoritmo de Gauss-Newton
- 3 Algoritmo de Levenberg-Marquardt

Como encontrar o mínimo?

O problema

Encontrar o mínimo de

$$\chi^2(a_1, a_2, \dots, a_s) = \sum_{k=1}^N [F_k(a_1, a_2, \dots, a_s)]$$

Métodos

Todos os métodos são **iterativos**

- 1 Steepest descent
- 2 Algoritmo de Gauss-Newton
- 3 Algoritmo de Levenberg-Marquardt

Como encontrar o mínimo?

O problema

Encontrar o mínimo de

$$\chi^2(a_1, a_2, \dots, a_s) = \sum_{k=1}^N [F_k(a_1, a_2, \dots, a_s)]$$

Métodos

Todos os métodos são **iterativos**

- 1 Steepest descent
- 2 Algoritmo de Gauss-Newton
- 3 Algoritmo de Levenberg-Marquardt

Como encontrar o mínimo?

O problema

Encontrar o mínimo de

$$\chi^2(a_1, a_2, \dots, a_s) = \sum_{k=1}^N [F_k(a_1, a_2, \dots, a_s)]$$

Métodos

Todos os métodos são **iterativos**

- 1 Steepest descent
- 2 Algoritmo de Gauss-Newton
- 3 Algoritmo de Levenberg-Marquardt

Como encontrar o mínimo?

O problema

Encontrar o mínimo de

$$\chi^2(a_1, a_2, \dots, a_s) = \sum_{k=1}^N [F_k(a_1, a_2, \dots, a_s)]$$

Métodos

Todos os métodos são **iterativos**

- 1 Steepest descent
- 2 Algoritmo de Gauss-Newton
- 3 Algoritmo de Levenberg-Marquardt

Steepest descent

- Intuitivamente é o método mais simples
- A partir de um ponto inicial (no espaço de parâmetros), se aproxima do **mínimo local** tomando passos proporcionais ao **negativo do gradiente**
-
- Portanto, $\vec{a}_{n+1} = \vec{a}_n - \lambda \nabla F$, com $\lambda > 0$ suficientemente pequeno, se aproxima sucessivamente do **mínimo local**

Steepest descent

- Intuitivamente é o método mais simples
- A partir de um ponto inicial (no espaço de parâmetros), se aproxima do **mínimo local** tomando passos proporcionais ao **negativo do gradiente**
-
- Portanto, $\vec{a}_{n+1} = \vec{a}_n - \lambda \nabla F$, com $\lambda > 0$ suficientemente pequeno, se aproxima sucessivamente do **mínimo local**

Steepest descent

- Intuitivamente é o método mais simples
- A partir de um ponto inicial (no espaço de parâmetros), se aproxima do **mínimo local** tomando passos proporcionais ao **negativo do gradiente**
- O **gradiente** diz a direção em que a função cresce **mais rápido**
- Portanto, $\vec{a}_{n+1} = \vec{a}_n - \lambda \nabla F$, com $\lambda > 0$ suficientemente pequeno, se aproxima sucessivamente do **mínimo local**

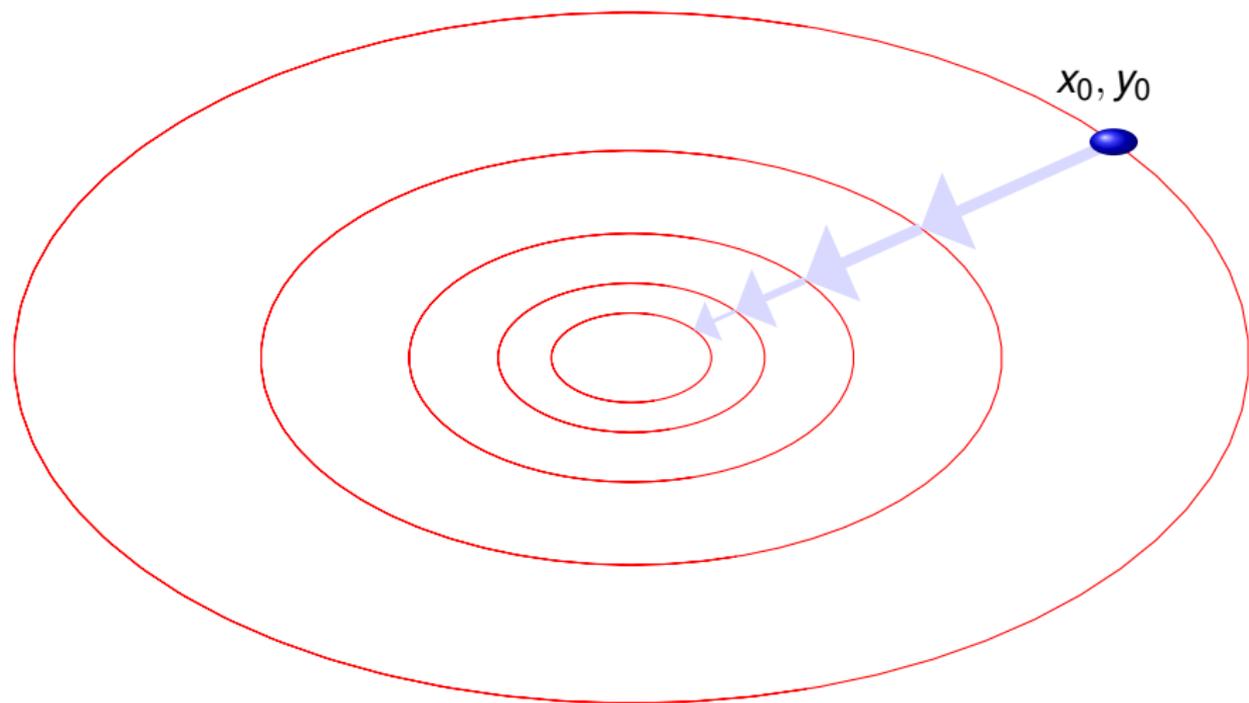
Steepest descent

- Intuitivamente é o método mais simples
- A partir de um ponto inicial (no espaço de parâmetros), se aproxima do **mínimo local** tomando passos proporcionais ao **negativo do gradiente**
- O **negativo do gradiente** diz a direção em que a função **decrece mais rápido**
- Portanto, $\vec{a}_{n+1} = \vec{a}_n - \lambda \nabla F$, com $\lambda > 0$ suficientemente pequeno, se aproxima sucessivamente do **mínimo local**

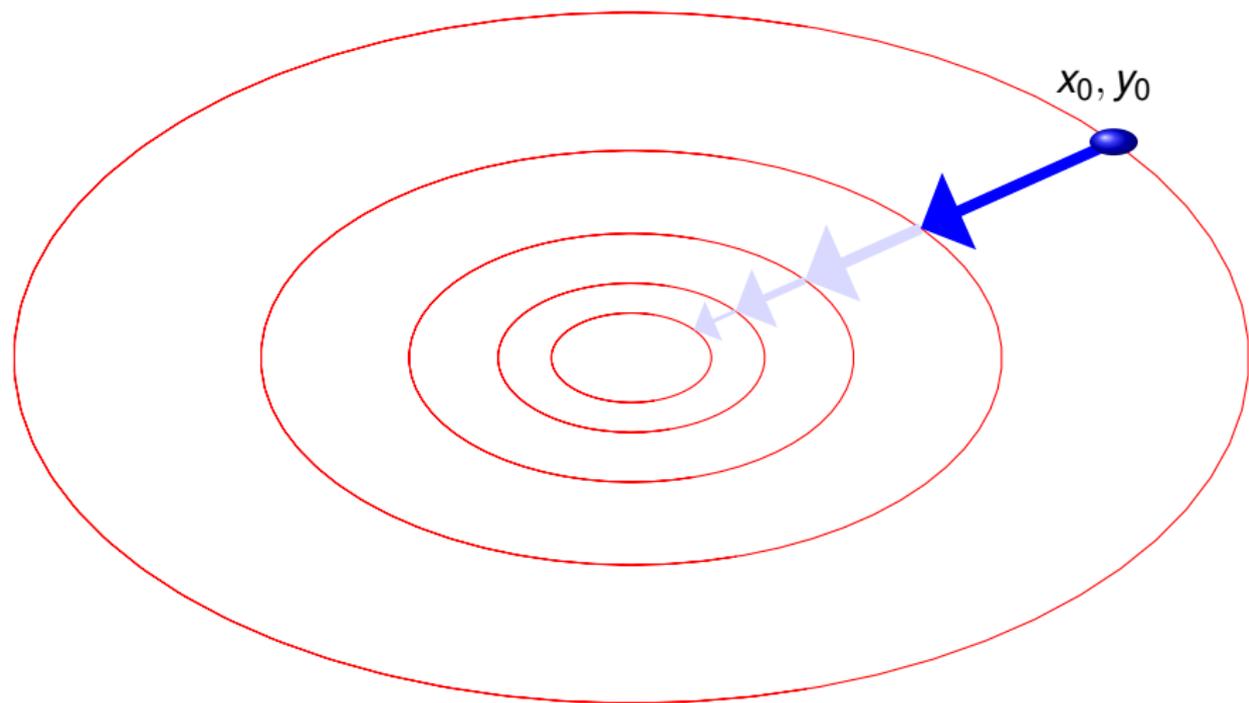
Steepest descent

- Intuitivamente é o método mais simples
- A partir de um ponto inicial (no espaço de parâmetros), se aproxima do **mínimo local** tomando passos proporcionais ao **negativo do gradiente**
- O **negativo do gradiente** diz a direção em que a função **decrece mais rápido**
- Portanto, $\vec{a}_{n+1} = \vec{a}_n - \lambda \nabla F$, com $\lambda > 0$ suficientemente pequeno, se aproxima sucessivamente do **mínimo local**

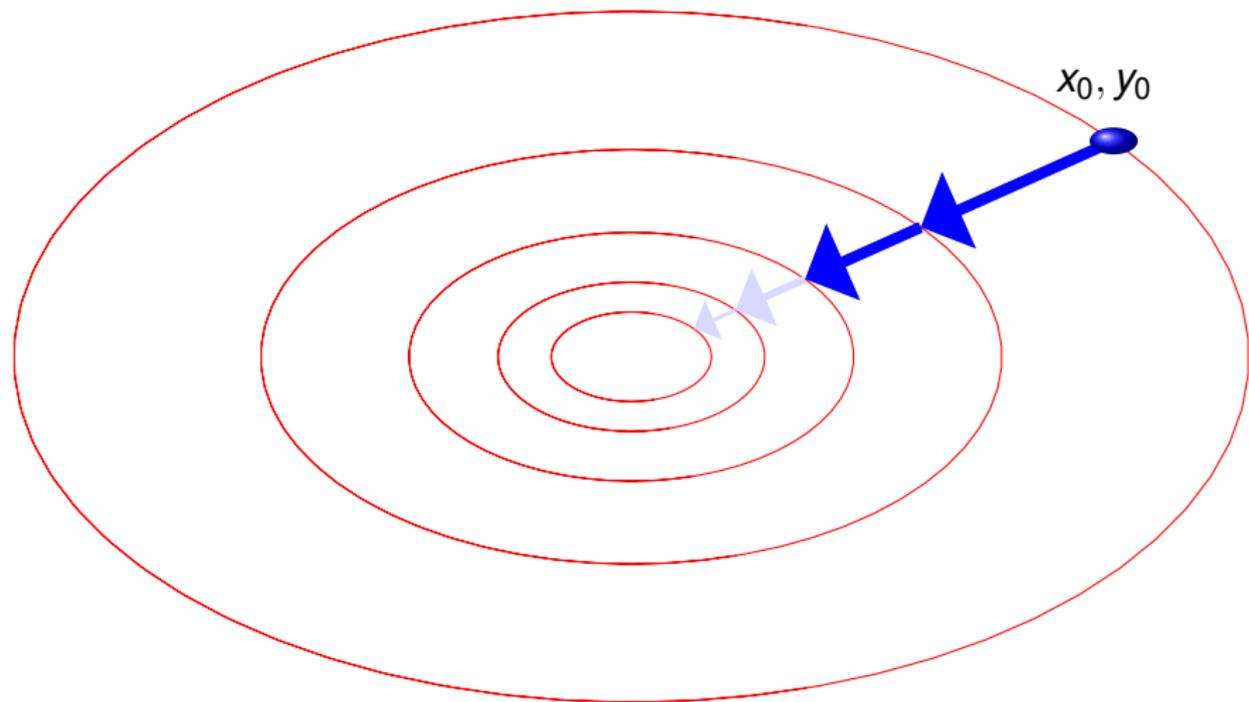
Steepest descent



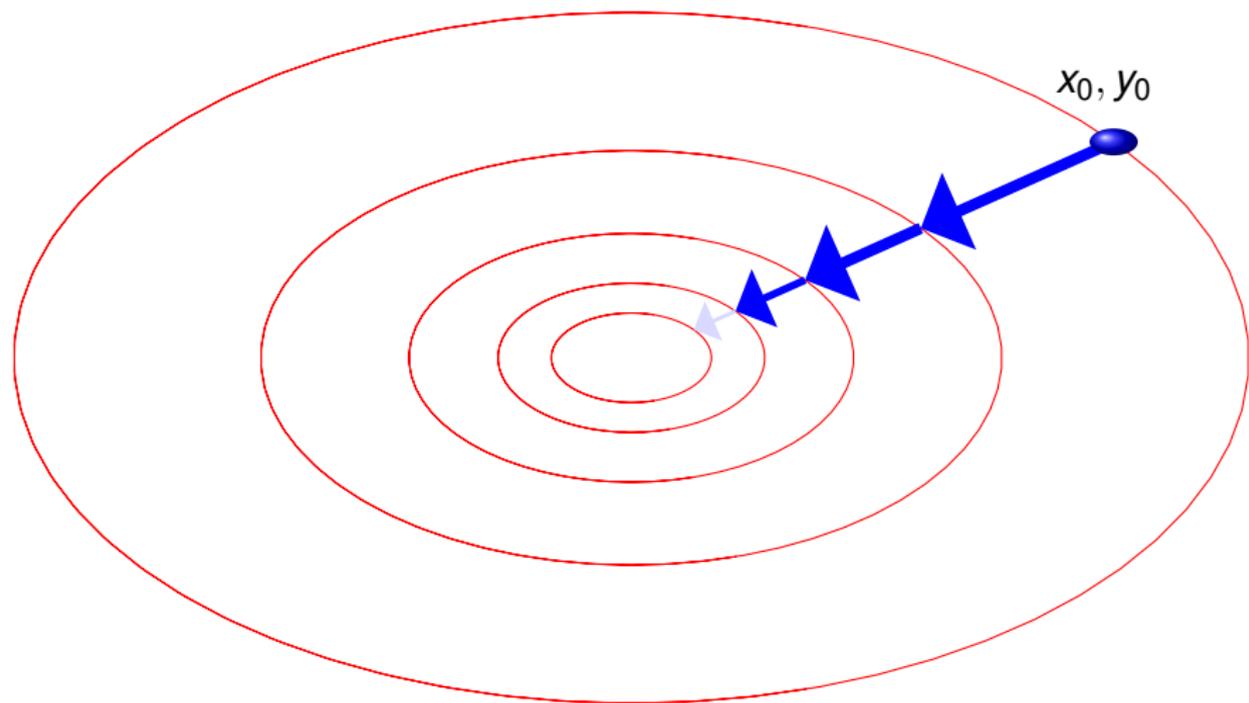
Steepest descent



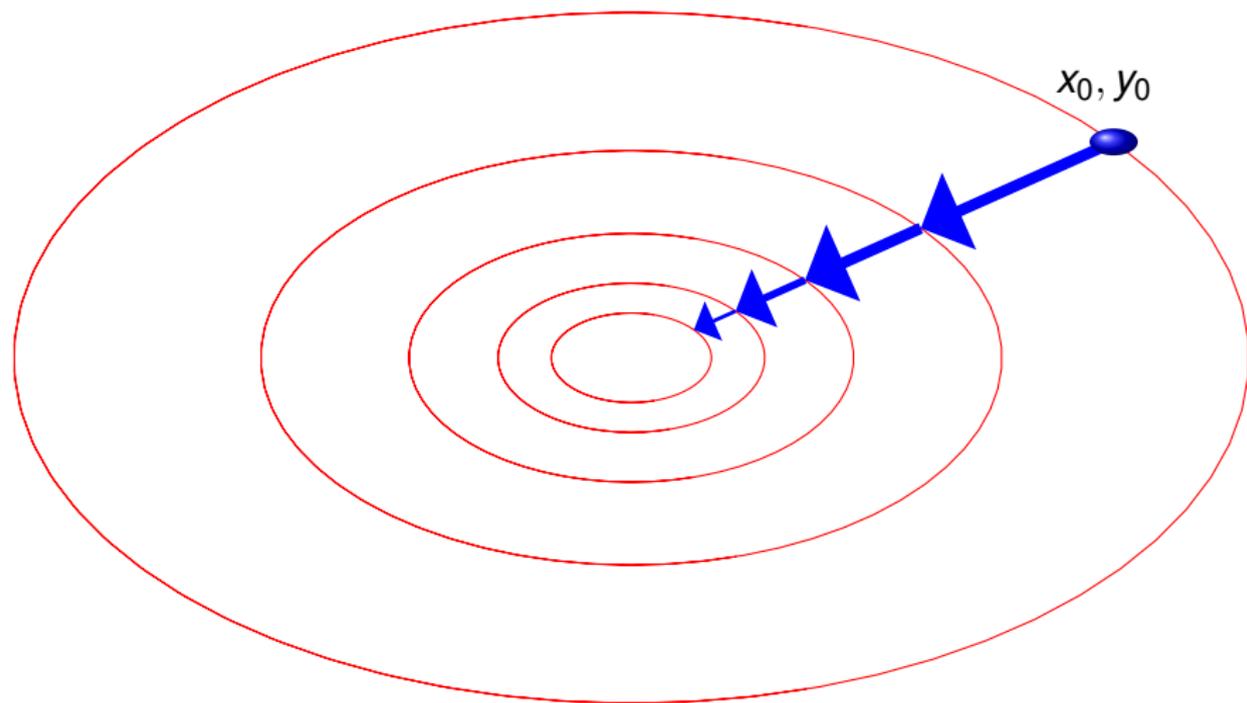
Steepest descent



Steepest descent



Steepest descent



Problemas do steepest descent

- O algoritmo pode levar **muitas iterações** para convergir para o mínimo local se as curvaturas forem diferentes nas diferentes direções
- Só funciona se começarmos **próximo ao mínimo**

Problemas do steepest descent

- O algoritmo pode levar **muitas iterações** para convergir para o mínimo local se as curvaturas forem diferentes nas diferentes direções
- Só funciona se começarmos **próximo ao mínimo**

Algoritmo de Gauss-Newton

- Para achar o mínimo, seria conveniente dar **passos grandes** quando o **gradiente é pequeno** e **passos pequenos** quando o **gradiente é grande**
- O método do steepest descent faz o oposto
- Uma possível solução é usar também a **curvatura** (segunda derivada) para determinar o **passo**
- Para tanto, notamos que no ponto de mínimo $\nabla f(\vec{a}) = 0$. Logo, podemos escrever

$$\nabla f(\vec{a}) = \nabla f(\vec{a}_0) + (\vec{a} - \vec{a}_0) \nabla^2 f(\vec{a}_0) \Rightarrow \vec{a} = \vec{a}_0 - [\nabla^2 f(\vec{a}_0)]^{-1} \nabla f(\vec{a}_0)$$

- Que, iterativamente, se torna

$$\vec{a}_{n+1} = \vec{a}_n - [\nabla^2 f(\vec{a}_n)]^{-1} \nabla f(\vec{a}_n)$$

Algoritmo de Gauss-Newton

- Para achar o mínimo, seria conveniente dar **passos grandes** quando o **gradiente é pequeno** e **passos pequenos** quando o **gradiente é grande**
- O método do steepest descent faz o oposto
- Uma possível solução é usar também a **curvatura** (segunda derivada) para determinar o **passo**
- Para tanto, notamos que no ponto de mínimo $\nabla f(\vec{a}) = 0$. Logo, podemos escrever

$$\nabla f(\vec{a}) = \nabla f(\vec{a}_0) + (\vec{a} - \vec{a}_0) \nabla^2 f(\vec{a}_0) \Rightarrow \vec{a} = \vec{a}_0 - [\nabla^2 f(\vec{a}_0)]^{-1} \nabla f(\vec{a}_0)$$

- Que, iterativamente, se torna

$$\vec{a}_{n+1} = \vec{a}_n - [\nabla^2 f(\vec{a}_n)]^{-1} \nabla f(\vec{a}_n)$$

Algoritmo de Gauss-Newton

- Para achar o mínimo, seria conveniente dar **passos grandes** quando o **gradiente é pequeno** e **passos pequenos** quando o **gradiente é grande**
- O método do steepest descent faz o oposto
- Uma possível solução é usar também a **curvatura** (segunda derivada) para determinar o **passo**
- Para tanto, notamos que no ponto de mínimo $\nabla f(\vec{a}) = 0$. Logo, podemos escrever

$$\nabla f(\vec{a}) = \nabla f(\vec{a}_0) + (\vec{a} - \vec{a}_0) \nabla^2 f(\vec{a}_0) \Rightarrow \vec{a} = \vec{a}_0 - [\nabla^2 f(\vec{a}_0)]^{-1} \nabla f(\vec{a}_0)$$

- Que, iterativamente, se torna

$$\vec{a}_{n+1} = \vec{a}_n - [\nabla^2 f(\vec{a}_n)]^{-1} \nabla f(\vec{a}_n)$$

Algoritmo de Gauss-Newton

- Para achar o mínimo, seria conveniente dar **passos grandes** quando o **gradiente é pequeno** e **passos pequenos** quando o **gradiente é grande**
- O método do steepest descent faz o oposto
- Uma possível solução é usar também a **curvatura** (segunda derivada) para determinar o **passo**
- Para tanto, notamos que no ponto de mínimo $\nabla f(\vec{a}) = 0$. Logo, podemos escrever

$$\nabla f(\vec{a}) = \nabla f(\vec{a}_0) + (\vec{a} - \vec{a}_0) \nabla^2 f(\vec{a}_0) \Rightarrow \vec{a} = \vec{a}_0 - [\nabla^2 f(\vec{a}_0)]^{-1} \nabla f(\vec{a}_0)$$

- Que, iterativamente, se torna

$$\vec{a}_{n+1} = \vec{a}_n - [\nabla^2 f(\vec{a}_n)]^{-1} \nabla f(\vec{a}_n)$$

Algoritmo de Gauss-Newton

- Para achar o mínimo, seria conveniente dar **passos grandes** quando o **gradiente é pequeno** e **passos pequenos** quando o **gradiente é grande**
- O método do steepest descent faz o oposto
- Uma possível solução é usar também a **curvatura** (segunda derivada) para determinar o **passo**
- Para tanto, notamos que no ponto de mínimo $\nabla f(\vec{a}) = 0$. Logo, podemos escrever

$$\nabla f(\vec{a}) = \nabla f(\vec{a}_0) + (\vec{a} - \vec{a}_0) \nabla^2 f(\vec{a}_0) \Rightarrow \vec{a} = \vec{a}_0 - [\nabla^2 f(\vec{a}_0)]^{-1} \nabla f(\vec{a}_0)$$

- Que, iterativamente, se torna

$$\vec{a}_{n+1} = \vec{a}_n - [\nabla^2 f(\vec{a}_n)]^{-1} \nabla f(\vec{a}_n)$$

Algoritmo de Gauss-Newton

- Para achar o mínimo, seria conveniente dar **passos grandes** quando o **gradiente é pequeno** e **passos pequenos** quando o **gradiente é grande**
- O método do steepest descent faz o oposto
- Uma possível solução é usar também a **curvatura** (segunda derivada) para determinar o **passo**
- Para tanto, notamos que no ponto de mínimo $\nabla f(\vec{a}) = 0$. Logo, podemos escrever

$$\nabla f(\vec{a}) = \nabla f(\vec{a}_0) + (\vec{a} - \vec{a}_0) \nabla^2 f(\vec{a}_0) \Rightarrow \vec{a} = \vec{a}_0 - [\nabla^2 f(\vec{a}_0)]^{-1} \nabla f(\vec{a}_0)$$

- Que, iterativamente, se torna

$$\vec{a}_{n+1} = \vec{a}_n - [\nabla^2 f(\vec{a}_n)]^{-1} \nabla f(\vec{a}_n)$$

Algoritmo de Gauss-Newton

- O método possui uma **convergência rápida**
- Contudo, a taxa de convergência depende sensivelmente do **ponto de partida**
- Torna-se particularmente **lento** se $\nabla^2 f$ for grande

Algoritmo de Gauss-Newton

- O método possui uma **convergência rápida**
- Contudo, a taxa de convergência depende sensivelmente do **ponto de partida**
- Torna-se particularmente **lento** se $\nabla^2 f$ for grande

Algoritmo de Gauss-Newton

- O método possui uma **convergência rápida**
- Contudo, a taxa de convergência depende sensivelmente do **ponto de partida**
- Torna-se particularmente **lento** se $\nabla^2 f$ for grande

Algoritmo de Levenberg-Marquardt

- Os algoritmos do **steepest descent** e de **Gauss-Newton** são, de certa forma, **complementares** em suas vantagens
- O algoritmo de **Levenberg-Marquadt** é uma **mistura** dos dois

Algoritmo de Levenberg-Marquardt

- Os algoritmos do **steepest descent** e de **Gauss-Newton** são, de certa forma, **complementares** em suas vantagens
- O algoritmo de **Levenberg-Marquadt** é uma **mistura** dos dois

Algoritmo de Levenberg

- 1 Faça uma iteração usando a seguinte regra

$$\vec{a}_{n+1} = \vec{a}_n - \left[\nabla^2 f(\vec{a}_n) + \lambda I \right]^{-1} \nabla f(\vec{a}_n)$$

- 2 Calcule o erro com o novo vetor de parâmetros
- 3 Se o erro aumentar, despreze o novo vetor de parâmetros e aumente λ por um certo fator (normalmente 10)
- 4 Se o erro diminuir, aceite o novo vetor e divida λ pelo mesmo fator
- 5 Repita o processo até obter convergência

Algoritmo de Levenberg

- 1 Faça uma iteração usando a seguinte regra

$$\vec{a}_{n+1} = \vec{a}_n - \left[\nabla^2 f(\vec{a}_n) + \lambda I \right]^{-1} \nabla f(\vec{a}_n)$$

- 2 Calcule o **erro** com o **novo vetor de parâmetros**
- 3 Se o **erro** aumentar, despreze o novo vetor de parâmetros e **auente** λ por um certo fator (normalmente 10)
- 4 Se o **erro** diminuir, **aceite** o novo vetor e **divida** λ pelo mesmo fator
- 5 **Repita** o processo até obter convergência

Algoritmo de Levenberg

- 1 Faça uma iteração usando a seguinte regra

$$\vec{a}_{n+1} = \vec{a}_n - \left[\nabla^2 f(\vec{a}_n) + \lambda I \right]^{-1} \nabla f(\vec{a}_n)$$

- 2 Calcule o erro com o novo vetor de parâmetros
- 3 Se o erro aumentar, despreze o novo vetor de parâmetros e aumente λ por um certo fator (normalmente 10)
- 4 Se o erro diminuir, aceite o novo vetor e divida λ pelo mesmo fator
- 5 Repita o processo até obter convergência

Algoritmo de Levenberg

- 1 Faça uma iteração usando a seguinte regra

$$\vec{a}_{n+1} = \vec{a}_n - \left[\nabla^2 f(\vec{a}_n) + \lambda I \right]^{-1} \nabla f(\vec{a}_n)$$

- 2 Calcule o erro com o novo vetor de parâmetros
- 3 Se o erro aumentar, despreze o novo vetor de parâmetros e aumente λ por um certo fator (normalmente 10)
- 4 Se o erro diminuir, aceite o novo vetor e divida λ pelo mesmo fator
- 5 Repita o processo até obter convergência

Algoritmo de Levenberg

- 1 Faça uma iteração usando a seguinte regra

$$\vec{a}_{n+1} = \vec{a}_n - \left[\nabla^2 f(\vec{a}_n) + \lambda I \right]^{-1} \nabla f(\vec{a}_n)$$

- 2 Calcule o erro com o novo vetor de parâmetros
- 3 Se o erro aumentar, despreze o novo vetor de parâmetros e aumente λ por um certo fator (normalmente 10)
- 4 Se o erro diminuir, aceite o novo vetor e divida λ pelo mesmo fator
- 5 Repita o processo até obter convergência

Algoritmo de Levenberg-Marquardt

- Para λ grande, o algoritmo anterior, despreza a curvatura
- É interessante, no entanto, dar passos maiores na direção em que a curvatura é menor
- Marquardt propôs, então, alterar a regra de iteração para

$$\vec{a}_{n+1} = \vec{a}_n - \left[\nabla^2 f(\vec{a}_n) + \lambda \text{diag}(\nabla^2 f(\vec{a}_n)) \right]^{-1} \nabla f(\vec{a}_n)$$

Algoritmo de Levenberg-Marquardt

- Para λ grande, o algoritmo anterior, despreza a curvatura
- É interessante, no entanto, dar passos maiores na direção em que a curvatura é menor
- Marquardt propôs, então, alterar a regra de iteração para

$$\vec{a}_{n+1} = \vec{a}_n - \left[\nabla^2 f(\vec{a}_n) + \lambda \text{diag}(\nabla^2 f(\vec{a}_n)) \right]^{-1} \nabla f(\vec{a}_n)$$

Algoritmo de Levenberg-Marquardt

- Para λ grande, o algoritmo anterior, despreza a curvatura
- É interessante, no entanto, dar passos maiores na direção em que a curvatura é menor
- Marquardt propôs, então, alterar a regra de iteração para

$$\vec{a}_{n+1} = \vec{a}_n - \left[\nabla^2 f(\vec{a}_n) + \lambda \text{diag}(\nabla^2 f(\vec{a}_n)) \right]^{-1} \nabla f(\vec{a}_n)$$

Algoritmo de Levenberg-Marquardt

- O algoritmo de Levenberg-Marquardt **não** é um **algoritmo ótimo**
- É **heurístico**
- Contudo, **funciona muito bem na prática**
- É o algoritmo mais usado
- Várias implementações estão disponíveis na internet

Algoritmo de Levenberg-Marquardt

- O algoritmo de Levenberg-Marquardt **não** é um **algoritmo ótimo**
- É **heurístico**
- Contudo, **funciona muito bem na prática**
- É o algoritmo mais usado
- Várias implementações estão disponíveis na internet

Algoritmo de Levenberg-Marquardt

- O algoritmo de Levenberg-Marquardt **não** é um **algoritmo ótimo**
- É **heurístico**
- Contudo, **funciona muito bem na prática**
- É o algoritmo mais usado
- Várias implementações estão disponíveis na internet

Algoritmo de Levenberg-Marquardt

- O algoritmo de Levenberg-Marquardt **não** é um **algoritmo ótimo**
- É **heurístico**
- Contudo, **funciona muito bem na prática**
- É o algoritmo mais usado
- Várias implementações estão disponíveis na internet

Algoritmo de Levenberg-Marquardt

- O algoritmo de Levenberg-Marquardt **não** é um **algoritmo ótimo**
- É **heurístico**
- Contudo, **funciona muito bem na prática**
- É o algoritmo mais usado
- Várias implementações estão disponíveis na internet

