


# Aproximação e Interpolação

MCEF

2011/12



## Interpolação


O Problema da interpolação consiste na obtenção de funções que descrevam de forma exacta um conjunto de dados. Concretamente, dada uma tabela de valores (Observações) de uma determinada função  $f$ , da forma

$x$	$x_0$	$x_1$	$\cdots$	$x_n$
$f(x)$	$f_1$	$f_2$	$\cdots$	$f_n$

o Problema consiste em determinar uma função, de determinada família escolhida *a priori* ( $p$ . ex. *Polinómios, funções trigonométricas, funções racionais, etc*), de tal modo que

$$g(x_i) = f_i, \quad i = 0, \cdots, n$$

## Graficamente






## Em que situações se deve interpolar ?

- Quando temos os valores numéricos de uma função desconhecida para um conjunto de pontos e queremos o valor desta num ponto que não consta da tabela
- Quando apesar de conhecermos a expressão de uma função, esta tem uma forma que operações como diferenciação e integração difíceis ou mesmo impossíveis.

## Interpolação polinomial

No caso da interpolação polinomial, a família de funções escolhida para descrever os dados é constituída apenas por polinómios. Podemos saber a priori qual deve ser o grau do polinómio a escolher ?



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

2 pontos =>

2 coeficientes no polinómio =>

Polinómio de grau 1

## Interpolação Polinomial

Em geral, podemos provar que, dado um conjunto de dados da forma  $(x_i, f_i), i = 0, \dots, n$ , existe um e um só polinómio de grau menor ou igual que  $n$  que os interpola.

$$p_n(x) = a_0 + a_1x + a_2x^2 + a_3x^3 + \dots + a_nx^n$$

$$p_n(x_i) = f_i, \quad i = 0, \dots, n \Leftrightarrow \begin{cases} a_0 + a_1x_0 + a_2x_0^2 + \dots + a_nx_0^n = f_0 \\ a_0 + a_1x_1 + a_2x_1^2 + \dots + a_nx_1^n = f_1 \\ \vdots \\ a_0 + a_1x_n + a_2x_n^2 + \dots + a_nx_n^n = f_n \end{cases}$$

$$\begin{pmatrix} 1 & x_0 & x_0^2 & \cdots & x_0^n \\ 1 & x_1 & x_1^2 & \cdots & x_1^n \\ 1 & x_2 & x_2^2 & \cdots & x_2^n \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_n & x_n^2 & \cdots & x_n^n \end{pmatrix} \begin{pmatrix} a_0 \\ a_1 \\ a_2 \\ \vdots \\ a_n \end{pmatrix} = \begin{pmatrix} f_0 \\ f_1 \\ f_2 \\ \vdots \\ f_n \end{pmatrix}$$

Matriz de Vandermonde

Podemos mostrar que o determinante desta matriz é não nulo se e só se os pontos forem distintos. Nesse caso os coeficientes a determinar existem e são únicos, o que é equivalente a dizer que o polinómio interpolador existe e é único.


## Exemplo

Determinar o polinómio interpolador do seguinte conjunto de dados:

X	F(x)
0	1
1	1.5
2	0

$$\begin{cases} a_0 + a_1 \cdot 0 + a_2 \cdot 0^2 = 1 \\ a_0 + a_1 \cdot 1 + a_2 \cdot 1^2 = 1.5 \\ a_0 + a_1 \cdot 2 + a_2 \cdot 2^2 = 0 \end{cases} \Leftrightarrow \begin{cases} a_0 = 1 \\ a_1 = 1.5 \\ a_2 = -1 \end{cases}$$

$$p_2(x) = 1 + 1.5x - x^2 \quad \rightarrow \text{Polinómio Interpolador}$$






## Exemplo

Determinar o polinómio interpolador do seguinte conjunto de dados:

$x_i$	$f_i$
1	3
2	5
3	3
4	3
5	2
6	1
7	1
8	4
9	5
10	4

$$p_9(x) = \frac{79t^9}{362880} - \frac{431t^8}{40320} + \frac{13663t^7}{60480} - \frac{861t^6}{320} + \frac{342739t^5}{17280} - \frac{59753t^4}{640} + \frac{12631939t^3}{45360} - \frac{5059501t^2}{10080} + \frac{1228393t}{2520} - 185$$



## Interpolação Polinomial no Mathematica

1. Introdução dos dados: Devem ser fornecidos na forma de uma LISTA contendo os pontos, Exemplo anterior teríamos:

```
dados = {{1, 3}, {2, 5}, {3, 3}, {4, 3}, {5, 2}, {6, 1}, {7, 1}, {8, 4}, {9, 5}, {10, 4}} ;
```

2. Determinação do polinómio interpolador, usando a função *InterpolatingPolynomial*:

```
InterpolatingPolynomial[dados , t ]
```

3. O resultado dos dois comandos anteriores é um polinómio na variável  $t$ , correspondente ao polinómio interpolador dos dados.

## Polinómios de Lagrange

$$L_i(x) = \frac{\prod_{j \neq i} (x - x_j)}{\prod_{j \neq i} (x_i - x_j)}$$

Deste modo temos que

$$L_i(x_j) = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases}$$

e portanto podemos escrever o polinómio interpolador na forma

$$p_n(x) = \sum_{i=0}^n f_i L_i(x)$$

## Polinómio Interpolador de Lagrange (no Mathematica)

```
InterpL[dados_, t_] := Sum[
  dados[[i, 2]] * Product[t - dados[[j, 1]], {j, 1, i - 1}] *
  Product[t - dados[[j, 1]], {j, i + 1, Length[dados]}] /
  (Product[dados[[i, 1]] - dados[[j, 1]], {j, 1, i - 1}] *
  Product[dados[[i, 1]] - dados[[j, 1]],
    {j, i + 1, Length[dados]}]), {i, 1, Length[dados]}
```

Exemplo:

```
dados = {{0, 1}, {1, 1.5}, {2, 0}}
InterpL[dados, x] // Expand
```

```
{{0, 1}, {1, 1.5}, {2, 0}}
```

```
1 + 1.5 x - 1. x2
```

## Polinómio Interpolador de Newton

Aparece como resposta a uma dificuldade presente no modo de cálculo dos polinómios interpoladores de Lagrange: Se acrescentarmos mais um ponto ao nosso conjunto de dados, temos que voltar a calcular tudo desde o início !!

$x$	$x_0$	$x_1$	$\cdots$	$x_n$
$f(x)$	$f_1$	$f_2$	$\cdots$	$f_n$

↓

$$p_n(x)$$

$x$	$x_0$	$x_1$	$\cdots$	$x_n$	$x_{n+1}$
$f(x)$	$f_1$	$f_2$	$\cdots$	$f_n$	$f_{n+1}$

↓

$$p_{n+1}(x) = p_n(x) + c(x - x_0)(x - x_1) \cdots (x - x_n)$$

Como calcular  $c$  ???

## Diferenças divididas

Uma diferença dividida de uma função num conjunto de pontos  $x_0, \dots, x_n$  é designada por

$$f[x_0, x_1, \dots, x_n]$$

- Uma diferença de ordem zero corresponde à própria função:  
 $f[x_0] = f(x_0)$ .
- Uma diferença de ordem um corresponde a uma razão incremental

$$f[x_0, x_1] = \frac{f[x_0] - f[x_1]}{x_0 - x_1}$$

- Uma diferença de ordem  $n$  calcula-se recursivamente através da fórmula

$$f[x_0, x_1, \dots, x_{n-1}, x_n] = \frac{f[x_0, \dots, x_{n-1}] - f[x_1, \dots, x_n]}{x_0 - x_n}$$

## Fórmula Interpoladora de Newton

$$p_n(x) = f[x_0] + f[x_0, x_1](x - x_0) + f[x_0, x_1, x_2](x - x_0)(x - x_1) + \cdots + f[x_0, x_1, \cdots, x_n](x - x_0)(x - x_1) \cdots (x - x_{n-1})$$

Basta então determinar:

$$f[x_0]$$

$$f[x_0, x_1]$$

$$f[x_0, x_1, x_2]$$


$$f[x_0, x_1, x_2, x_3]$$

⋮

$$f[x_0, x_1, x_2, x_3, \cdots, x_n]$$



## Esquema de cálculo (Tabela de diferenças divididas)





## Exemplo

X	F(x)
0	1
1	1.5
2	0

$x_i$	$f[\cdot]$	$f[\cdot, \cdot]$	$f[\cdot, \cdot, \cdot]$
0	1		
		0.5	
1	1.5		0.5
		- 1.5	
2	0		

$$p_2(x) = 1 + 0.5(x - 0) + 0.5(x - 0)(x - 1)$$






O que pode correr mal ?

**Exemplo de Runge:**

$$f(x) = \frac{1}{1 + 25x^2}, \quad x \in [-1, 1]$$

$$x_i = -1 + ih, \quad i = 0, \dots, n$$

$$h = \frac{2}{n - 1}$$



Qual a origem destas perturbações?

Podem ser evitadas ?

## Erro de Interpolação

$$x_0 < x_1 < x_2 < \cdots < x_n$$

Para cada  $x \in [x_0, x_n]$  temos :

$$f(x) - p_n(x) = \frac{f^{(n+1)}(\xi)}{(n+1)!} \prod_{i=0}^n (x - x_i)$$

Em que  $\xi \in [x_0, x_n]$  é um ponto desconhecido. Se a função tiver derivadas contínuas até á ordem  $n + 1$  podemos dizer que:

$$|f(x) - p_n(x)| \leq \frac{1}{(n+1)!} \max_{x_0 \leq x \leq x_n} |f^{(n+1)}(x)| \cdot \max_{x_0 \leq x \leq x_n} |(x - x_0)(x - x_1) \cdots (x - x_n)|$$

Erro relacionado com a  
Função desconhecida f.

Erro relacionada com os nós de interpolação

## Interpolação de Chebychev

- Os pontos (nós) de interpolação são escolhidos de modo a minimizar essa componente do erro. No entanto, **nem sempre temos a liberdade de fazer a escolha dos nós.**




Pretendemos então escolher  $x_0, \dots, x_n$  de modo a **minimizar** a quantidade

$$\max_{x_0 \leq x \leq x_n} |(x - x_0)(x - x_1) \cdots (x - x_n)|$$

no case particular do interval  $[-1, 1]$  a escolha dos nós deve ser a seguinte:

$$x_i = \text{Cos} \left( \frac{(2i + 1)\pi}{2n} \right), \quad i = 0, \dots, n - 1$$

## Exemplo de Runge, com nós de Chebyshev



Com os “novos” nós de interpolação  
Desaparecem as instabilidades

## Exercício

Suponha que pretende construir uma tabela de valores da função exponencial no intervalo  $[-2, 2]$ , de tal modo que ao aproximar linearmente os pontos não tabelados o erro cometido seja seguramente inferior a 0.01. Qual deve ser o espaçamento entre os pontos da tabela ?

$x_i$	$exp(x_i)$
-2.	0.135335
-1.5	0.22313
-1.	0.367879
-0.5	0.606531
0.	1.
0.5	1.64872
1.	2.71828
1.5	4.48169
2.	7.38906

$$exp(0.75) \approx ?$$

No intervalo  $[0.5, 1]$  o polinómio interpolador de grau 1 é

$$p_1(x) = 1.64872 + \frac{2.71828 - 1.64872}{1 - 0.5}(x - 0.5)$$

$$exp(0.75) \approx p_1(0.75) = 2.1835$$

Na verdade  $p_1(0.75) - exp(0.75) \approx 0.665$ , pelo que esta tabela não verifica a restrição proposta.

## Aproximação de funções: Caso discreto



- Ao contrário da interpolação, em que a função  $g(x)$  escolhida para descrever os dados os devia reproduzir de forma exacta, no caso da aproximação apenas estamos interessados numa descrição aproximada.
- Essa descrição aproximada deve ser optimal, num sentido a descrever mais adiante.
- O número de parâmetros a determinar deve ser substancialmente inferior à quantidade de dados envolvidos.

$$(x_0, f_0), (x_1, f_1), (x_2, f_2), \dots, (x_n, f_n)$$

$$f(x) \approx g(x) = a_0 g_0(x) + a_1 g_1(x) + \dots + a_m g_m(x), \quad m \ll n$$



## Interpolação Vs. Aproximação



$$\begin{aligned}
 f(x) \approx & 1.12452 * 10^{13} - 4.35647 * 10^{13}x + 7.6921 * 10^{13}x^2 \\
 & - 8.35663 * 10^{13}x^3 + 6.3328 * 10^{13}x^4 + \dots \\
 & \dots + 4.20384 * 10^{-27}x^{36} - 1.65171 * 10^{-29}x^{37} + \\
 & 4.17772 * 10^{-32}x^{38} - 5.10641 * 10^{-35}x^{39}
 \end{aligned}$$

Parâmetros a determinar: 40

$$f(x) \approx -4.66217 + 5.11154x - 0.108315x^2$$

Parâmetros a determinar: 3

## Qualidade da Aproximação

Se pretendemos medir a qualidade da aproximação, devemos ser capazes de medir a Distância entre os dados a a função aproximadora, devemos para isso dispor de uma Norma, tal como aconteceu no estudo dos sistemas de equações.

Consideremos fixo o conjunto de pontos  $x_i$ ,  $i = 0, \dots, n$  e sejam  $f, g$  duas funções reais de variável real. Definimos:

**Produto interno:**  $\langle f, g \rangle = \sum_{i=0}^n f(x_i)g(x_i)$

**Norma:**  $\|f\| = \sqrt{\langle f, f \rangle} = \sqrt{\sum_{i=0}^n f(x_i)^2}$


**distância:**  $d(f, g) = \|f - g\| = \sqrt{\sum_{i=0}^n (f(x_i) - g(x_i))^2}$

## Melhor aproximação no sentido dos mínimos quadrados

Fixemos funções  $g_0(x), \dots, g_m(x)$ , linearmente independentes, e consideremos o espaço linear gerado por estas, isto é, o espaço  $S$  das funções da forma

$$g(x) = a_0g_0(x) + \dots + a_mg_m(x), \quad a_0, \dots, a_m \in \mathbb{R}$$

A melhor aproximação dos mínimos quadrados para um conjunto de dados  $(x_i, f(x_i))$  é a função  $g \in S$  mais próxima de  $f$ , no sentido da distância anteriormente definida. Devemos então calcular  $a_0, \dots, a_m$  de modo a minimizar



$$\begin{aligned} Q(a_0, \dots, a_m) &= \|g - f\|^2 = \sum_{i=0}^n (g(x_i) - f(x_i))^2 \\ &= \sum_{i=0}^n [a_0g_0(x_i) + \dots + a_mg_m(x_i) - f(x_i)]^2 \end{aligned}$$

A função  $Q$  é uma função quadrática dos seus argumentos  $(a_0, \dots, a_m)$  e, sendo diferenciável em  $\mathbb{R}^n$ , os seus extremantes ocorrem necessariamente em pontos estacionários. Calculemos então os pontos estacionários de  $Q$ , isto é, os pontos onde se anulam em simultâneo todas as derivadas parciais.

$$\frac{\partial Q}{\partial a_j} = 0 \Leftrightarrow \sum_{i=0}^n 2g_j(x_i)(a_0g_0(x_i) + \dots + a_mg_m(x_i) - f(x_i)) = 0$$

$$\Leftrightarrow a_0 \langle g_j, g_0 \rangle + \dots + a_m \langle g_j, g_m \rangle = \langle f, g_j \rangle$$

Assim os coeficientes a determinar podem ser calculados resolvendo um **sistema linear**.

## Sistema Normal

$$\begin{pmatrix} \langle g_0, g_0 \rangle & \langle g_0, g_1 \rangle & \cdots & \langle g_0, g_m \rangle \\ \langle g_1, g_0 \rangle & \langle g_1, g_1 \rangle & \cdots & \langle g_1, g_m \rangle \\ \vdots & \vdots & \ddots & \vdots \\ \langle g_m, g_0 \rangle & \langle g_m, g_1 \rangle & \cdots & \langle g_m, g_m \rangle \end{pmatrix} \begin{pmatrix} a_0 \\ a_1 \\ \vdots \\ a_m \end{pmatrix} = \begin{pmatrix} \langle f, g_0 \rangle \\ \langle f, g_1 \rangle \\ \vdots \\ \langle f, g_m \rangle \end{pmatrix}$$

Se as funções  $g_i$  escolhidas forem linearmente independentes o **sistema normal tem uma e uma só solução**. Além disso podemos ver que a matriz Hessiana (que é constante) é definida positiva, pelo que a função  $Q$  **atinge um mínimo** no ponto definido pela solução do sistema anterior, que é **global** em virtude de a função  $Q$  ser convexa.

## Exemplo: Regressão Linear

$$\begin{pmatrix} (n+1) & \sum x_i \\ \sum x_i & \sum x_i^2 \end{pmatrix} \begin{pmatrix} a_0 \\ a_1 \end{pmatrix} = \begin{pmatrix} \sum f_i \\ \sum f_i x_i \end{pmatrix}$$

$$\Leftrightarrow \begin{pmatrix} 1 & \bar{x} \\ \bar{x} & \overline{x^2} \end{pmatrix} \begin{pmatrix} a_0 \\ a_1 \end{pmatrix} = \begin{pmatrix} \bar{f} \\ \overline{fx} \end{pmatrix}$$

$$a_0 = \frac{\bar{f} \cdot \overline{x^2} - \overline{fx} \cdot \bar{x}}{\overline{x^2} - \bar{x}^2}$$

$$a_1 = \frac{\overline{fx} - \bar{x} \cdot \bar{f}}{\overline{x^2} - \bar{x}^2}$$

$$g_0(x) = 1, \quad g_1(x) = x$$

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

$$\langle g_0, g_0 \rangle = \sum_{i=0}^n g_0(x_i) \cdot g_0(x_i) = \sum_{i=0}^n 1 \cdot 1 = n + 1$$

$$\langle g_0, g_1 \rangle = \sum_{i=0}^n g_0(x_i) \cdot g_1(x_i) = \sum_{i=0}^n 1 \cdot x_i = \sum x_i$$

$$\langle g_1, g_1 \rangle = \sum_{i=0}^n g_1(x_i) \cdot g_1(x_i) = \sum_{i=0}^n x_i \cdot x_i = \sum x_i^2$$

$$\langle f, g_0 \rangle = \sum_{i=0}^n f(x_i) g_0(x_i) = \sum f_i$$

$$\langle f, g_1 \rangle = \sum_{i=0}^n f(x_i) g_1(x_i) = \sum f_i x_i$$

## Aproximação dos mínimos quadrados no mathematica

**Fit**[*dados, funções de base, variáveis*]

**Exemplo 1:** Os comandos

Dados = {{0,1}, {1,2},{2,4},{3,0}};

Fit[dados, {1,x,x^2}, x]

Dão como resultado a melhor aproximação dos mínimos quadrados com polinómios de grau 2

**Exemplo 2:** Os comandos

Dados = {{0,1}, {1,2},{2,4},{3,0}};

Fit[dados, {1, x ,Sin[x]}, x]

Dão como resultado a melhor aproximação dos mínimos quadrados por funções do tipo:

$$g(x) = a + b x + c \sin(x)$$



## Actividade

Determinar diversas aproximações por mínimos quadrados para os dados propostos, procurando melhorar os resultados através de uma escolha criteriosa das funções de base  $g_0, g_1, \dots, g_m$ .



## Extensões: Mínimos quadrados não lineares

### Exemplo

Determinar os parâmetros  $a, b$  de modo que a função  $g(x) = \cos(ax + b)$  esteja o mais próxima possível dos dados  $(x_i, f_i)$ . Devemos minimizar a função

$$Q(a, b) = \sum_{i=0}^n (\cos(ax_i + b) - f(x_i))^2$$

$$\begin{cases} \frac{\partial Q}{\partial a} = 0 \\ \frac{\partial Q}{\partial b} = 0 \end{cases} \Leftrightarrow \begin{cases} \sum_{i=0}^n -2x_i \sin(ax_i + b)(\cos(ax_i + b) - f(x_i)) = 0 \\ \sum_{i=0}^n -2 \sin(ax_i + b)(\cos(ax_i + b) - f(x_i)) = 0 \end{cases}$$

Sistema não Linear