

4. Ajuste de curvas

4.1 Relações entre variáveis.

4.2 Regressão linear simples.

4.3 Qualidade do ajuste.

4.4 Regressão linear múltipla.

4.5 Formas alternativas de estimar os parâmetros.

4.6 Diferença entre regressão e interpolação.

4.7 Estudos de caso:

- Tensão-deformação de aço.

- Produto iônico da água.

4.8 Exercícios.

Relações entre variáveis

- ❑ Relacionar, por meio de um modelo matemático, a variável resposta (ou dependente) com o conjunto de variáveis explicativas (ou independentes).
- ❑ Para ter controle, determinar algum parâmetro ou mesmo fazer previsão acerca do comportamento da variável resposta.
- ❑ Variação da leitura de uma variável:
 - erros de medida experimentais;
 - variáveis cujos valores se alteram durante o experimento.
- ❑ Tipos de relações entre as variáveis
 1. determinísticas,
 2. semideterminísticas e
 3. empíricas.

Relações determinísticas

- ❑ Variáveis relacionadas entre si por uma lei expressa por fórmula matemática precisa.
- ❑ Variação nas observações é atribuída a erros experimentais.
- ❑ Por exemplo, se r reais forem investidos durante m meses a uma taxa de juros j , ao final do prazo ter-se-á v reais.
- ❑ As variáveis r , m , j e v estão relacionadas pela expressão exata fornecida pela Matemática Financeira

$$v = r(1 + j)^m,$$

que é a lei dos juros compostos.

- ❑ Qualquer análise adicional é desnecessária para relacionar estas variáveis.

Relações semideterminísticas

- ❑ Teoria prescreve forma para a relação.
- ❑ Mas não os valores particulares dos parâmetros que aparecem na relação.
- ❑ É necessário realizar experimentos para obter informações acerca desses parâmetros.
- ❑ Precisão limitada dos instrumentos de medida.
- ❑ Perturbações incontrolláveis dos experimentos.
- ❑ Outros fatores introduzem erros nos dados.
- ❑ Causam perturbação na verdadeira relação.
- ❑ Por exemplo, a concentração c de uma substância após um tempo t em uma reação química de primeira ordem é

$$c = c_0 e^{-kt},$$

c_0 : concentração inicial e k : constante de velocidade *de uma reação específica*.

- ❑ A constante k é obtida experimentalmente.

Relações empíricas

- ❑ Relação entre as variáveis envolvidas não são conhecidas.
- ❑ Determinar uma fórmula matemática que relacione essas variáveis.
- ❑ Gráfico feito com valores observados dessas variáveis fornece uma idéia da relação entre elas com algumas variações aleatórias.
- ❑ Por exemplo, deseja-se conhecer em um experimento agrícola qual a relação entre a produção p de uma lavoura de feijão e a dosagem d de um certo fertilizante.
- ❑ Outros fatores influentes como acidez do solo, umidade e controle de pragas são mantidos constantes tanto quanto possível.

- ❑ Experimento consiste em aplicar dosagens diferentes do fertilizante em áreas distintas.
- ❑ Anotar a produção de feijão em cada uma delas.
- ❑ Dosagens diferentes do fertilizante induzirão à produção de quantidades diferentes.
- ❑ Não esperar que a relação obtida siga uma fórmula matemática precisa, dada a complexidade do problema.
- ❑ Ter suficiente conhecimento sobre uma relação empírica.
- ❑ Desenvolver a teoria que conduza a uma fórmula matemática.
- ❑ Caso semideterminístico.

Regressão linear simples

- ❑ Relações mais simples entre duas variáveis são as relações lineares.
- ❑ A variável independente ou explicativa x é relacionada com a variável dependente ou resposta y por meio de um modelo linear

$$y = b_0 + b_1x.$$


- ❑ Esboçar os dados em um gráfico de coordenadas cartesianas denominado diagrama de dispersão.
- ❑ Diagrama mostra a natureza da relação intrínseca entre as duas variáveis estudadas.

Diagrama de dispersão

- Variáveis explicativas x e as respostas y

x	0,3	2,7	4,5	5,9	7,8
y	1,8	1,9	3,1	3,9	3,3

- Diagrama de dispersão dos dados



Retas de regressão

- ❑ Modelo simples que relaciona as variáveis x e y

$$y = \beta_0 + \beta_1 x + \epsilon,$$

- ❑ β_0 e β_1 são os parâmetros a serem estimados.
- ❑ ϵ contém os componentes desconhecidos e aleatórios de erro que se sobrepõem à verdadeira relação linear.
- ❑ Como estimar os parâmetros β_0 e β_1 ?

Modelo 1

- ❑ Primeira tentativa obtida por meio de polinômio interpolador linear.
- ❑ Reta esboçada a partir de dois pontos quaisquer.
- ❑ Por exemplo, o primeiro e o último

x	0,3	7,8
y	1,8	3,3

- ❑ Equação da reta $u(x)$ que passa por estes dois pontos

$$u(x) = y_0 + \frac{y_1 - y_0}{x_1 - x_0}(x - x_0) = 1,8 + \frac{3,3 - 1,8}{7,8 - 0,3}(x - 0,3),$$


$$u(x) = 1,8 + 0,2(x - 0,3) \leadsto u(x) = 1,74 + 0,2x.$$

- ❑ Distância vertical d_i entre o i -ésimo ponto dado y_i e o ponto $u_i = 1,74 + 0,2x_i$ de mesma abscissa x_i

$$d_i = y_i - u_i.$$

Gráfico do modelo 1

□ modelo 1: $u = 1,74 + 0,2x$.



Qualidade do modelo 1

Qualidade do ajuste

$$D(b_0, b_1) = \sum_{i=1}^n (y_i - u_i)^2 = \sum_{i=1}^n (y_i - b_0 - b_1 x_i)^2 = \sum_{i=1}^n d_i^2,$$

$$D(1,74; 0,2) = \sum_{i=1}^5 (y_i - (1,74 + 0,2x_i))^2.$$

Resultados do ajuste pelo modelo 1

i	x_i	y_i	u_i	d_i
1	0,3	1,8	1,80	0,00
2	2,7	1,9	2,28	-0,38
3	4,5	3,1	2,64	0,46
4	5,9	3,9	2,92	0,98
5	7,8	3,3	3,30	0,00
$D(1,74; 0,2) = 1,3164$				

Modelo 2

- ❑ Segunda tentativa também obtida por polinômio interpolador linear.
- ❑ Reta traçada por dois pontos quaisquer.
- ❑ Pontos escolhidos não pertencentes ao diagrama de dispersão.
- ❑ Por exemplo, escolhendo os pontos

x	2	6
y	2	3


- ❑ Equação da reta $u(x)$

$$u(x) = y_0 + \frac{y_1 - y_0}{x_1 - x_0}(x - x_0) = 2 + \frac{3 - 2}{6 - 2}(x - 2),$$

$$2 + 0,25(x - 2) \leadsto u(x) = 1,5 + 0,25x.$$

Gráfico do modelo 2

□ modelo 2: $u = 1,5 + 0,25x$.



Qualidade do modelo 2

□ Resultados do ajuste pelo modelo 2

i	x_i	y_i	u_i	d_i
1	0,3	1,8	1,575	0,225
2	2,7	1,9	2,175	-0,275
3	4,5	3,1	2,625	0,475
4	5,9	3,9	2,975	0,925
5	7,8	3,3	3,450	-0,150
$D(1,5; 0,25) = 1,2300$				

□ Modelo 2 é mais adequado

$$D(1,5; 0,25) = 1,2300 < D(1,74; 0,2) = 1,3164.$$

Método dos quadrados mínimos

- ❑ Qualidade do ajuste depende da equação da reta escolhida.
- ❑ Reta que não passa por dois pontos dentre aqueles do diagrama de dispersão produziu resultado melhor.
- ❑ Por onde se deve traçar a reta de modo a obter o menor valor do desvio D ?
- ❑ Método dos quadrados mínimos consiste em encontrar uma estimativa da reta $u = \beta_0 + \beta_1 x$.
- ❑ Produzir o menor valor possível do desvio

$$D(\beta_0, \beta_1) = \sum_{i=1}^n (y_i - u_i)^2 = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2.$$

Dedução dos quadrados mínimos

□ Função desvio

$$D(\beta_0, \beta_1) = \sum_{i=1}^n (y_i - u_i)^2 = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2.$$

□ Derivadas parciais

$$\frac{\partial D(\beta_0, \beta_1)}{\partial \beta_0} = -2 \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i),$$

$$\frac{\partial D(\beta_0, \beta_1)}{\partial \beta_1} = -2 \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i) x_i.$$

□ Valores para os quais a função $D(\beta_0, \beta_1)$ possui um mínimo \longrightarrow derivadas parciais se anulam.

□ Se $D(b_0, b_1)$ for o ponto de mínimo de $D(\beta_0, \beta_1)$

$$-2 \sum_{i=1}^n (y_i - b_0 - b_1 x_i) = 0 \rightarrow \sum_{i=1}^n b_0 + \sum_{i=1}^n b_1 x_i = \sum_{i=1}^n y_i,$$

$$-2 \sum_{i=1}^n (y_i - b_0 - b_1 x_i) x_i = 0 \rightarrow \sum_{i=1}^n b_0 x_i + \sum_{i=1}^n b_1 x_i^2 = \sum_{i=1}^n x_i y_i.$$

Reta de quadrados mínimos

- Na forma matricial e simplificando a notação

$$\begin{bmatrix} n & \sum x_i \\ \sum x_i & \sum x_i^2 \end{bmatrix} \begin{bmatrix} b_0 \\ b_1 \end{bmatrix} = \begin{bmatrix} \sum y_i \\ \sum x_i y_i \end{bmatrix}.$$

- Valores em que $D(\beta_0, \beta_1)$ apresenta um mínimo são obtidos pela solução do sistema linear denominado equações normais.
- Utilizando as operações l-elementares

$$\begin{bmatrix} n & \sum x_i \\ 0 & -\frac{1}{n}(\sum x_i)^2 + \sum x_i^2 \end{bmatrix} \begin{bmatrix} b_0 \\ b_1 \end{bmatrix} = \begin{bmatrix} \sum y_i \\ -\frac{1}{n} \sum x_i \sum y_i + \sum x_i y_i \end{bmatrix}.$$

- Parâmetros da reta de quadrados mínimos

$$u(x) = b_0 + b_1 x,$$

$$b_1 = \frac{\sum x_i \sum y_i - n \sum x_i y_i}{(\sum x_i)^2 - n \sum x_i^2},$$

$$b_0 = \frac{\sum y_i - b_1 \sum x_i}{n}.$$

Exemplo de quadrados mínimos

- Calcular a reta de quadrados mínimos usando

x	0,3	2,7	4,5	5,9	7,8
y	1,8	1,9	3,1	3,9	3,3

- Valores dos somatórios

i	x_i	y_i	x_i^2	$x_i y_i$	y_i^2
1	0,3	1,8	0,09	0,54	3,24
2	2,7	1,9	7,29	5,13	3,61
3	4,5	3,1	20,25	13,95	9,61
4	5,9	3,9	34,81	23,01	15,21
5	7,8	3,3	60,84	25,74	10,89
Σ	21,2	14,0	123,28	68,37	42,56

- Solução de quadrados mínimos

$$b_1 = \frac{\sum x_i \sum y_i - n \sum x_i y_i}{(\sum x_i)^2 - n \sum x_i^2} = \frac{21,2 \cdot 14,0 - 5 \cdot 68,37}{(21,2)^2 - 5 \cdot 123,28}$$


$$\leadsto b_1 = 0,2698;$$

$$b_0 = \frac{\sum y_i - b_1 \sum x_i}{n} = \frac{14,0 - 0,2698 \cdot 21,2}{5}$$

$$\leadsto b_0 = 1,6560.$$

Reta de quadrados mínimos

□ Reta $u = 1,6560 + 0,2698x$



Qualidade do modelo

□ Ajuste de quadrados mínimos

i	x_i	y_i	u_i	d_i
1	0,3	1,8	1,7369	0,0631
2	2,7	1,9	2,3845	-0,4845
3	4,5	3,1	2,8701	0,2299
4	5,9	3,9	3,2478	0,6522
5	7,8	3,3	3,7604	-0,4604
$D(1,6560; 0,2698) = 0,9289$				

□ Melhor dos três modelos propostos

$$D(1,6560; 0,2698) = 0,9289 <$$

$$D(1,5; 0,25) = 1,2300 <$$

$$D(1,74; 0,2) = 1,3164.$$

Coeficiente de determinação

- Seja a expressão para o i -ésimo ponto

$$y_i - \bar{y} = (y_i - u_i) + (u_i - \bar{y}),$$

- sendo $u_i = b_0 + b_1 x_i$ e $\bar{y} = \frac{1}{n} \left(\sum_{i=1}^n y_i \right)$.

- Tomando o quadrado em ambos os termos

$$(y_i - \bar{y})^2 = (y_i - u_i)^2 + (u_i - \bar{y})^2 + 2(y_i - u_i)(u_i - \bar{y}).$$

- Calculando o somatório para $i = 1, 2, \dots, n$

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (y_i - u_i)^2 + \sum_{i=1}^n (u_i - \bar{y})^2 + 2 \sum_{i=1}^n (y_i - u_i)(u_i - \bar{y}).$$

- Pode-se mostrar que

$$\sum_{i=1}^n (y_i - u_i)(u_i - \bar{y}) = 0.$$

- Conseqüentemente

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (y_i - u_i)^2 + \sum_{i=1}^n (u_i - \bar{y})^2.$$

Cálculo de r^2

- Soma dos quadrados

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (y_i - u_i)^2 + \sum_{i=1}^n (u_i - \bar{y})^2.$$

- SQTot (soma de quadrados total)

$$\sum_{i=1}^n (y_i - \bar{y})^2.$$

- SQRes (soma de quadrados residual)

$$\sum_{i=1}^n (y_i - u_i)^2.$$

- SQReg (soma de quadrados devido à regressão)

$$\sum_{i=1}^n (u_i - \bar{y})^2.$$

- Qualidade do ajuste do modelo aos dados

$$r^2 = \frac{\text{SQReg}}{\text{SQTot}} = \frac{\text{SQTot} - \text{SQRes}}{\text{SQTot}} \rightsquigarrow r^2 = 1 - \frac{\text{SQRes}}{\text{SQTot}},$$

- r^2 : coeficiente de determinação, $0 \leq r^2 \leq 1$.

□ Considerando

$$D(b_0, b_1) = \sum_{i=1}^n (y_i - u_i)^2 = \sum_{i=1}^n d_i^2,$$

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n y_i^2 - 2\bar{y} \sum_{i=1}^n y_i + n\bar{y}^2 \leadsto$$

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n y_i^2 - \frac{1}{n} \left(\sum_{i=1}^n y_i \right)^2.$$

□ Coeficiente de determinação

$$r^2 = 1 - \frac{D(b_0, b_1)}{\sum y_i^2 - \frac{1}{n} (\sum y_i)^2}.$$

□ Proporção da variação total dos dados em torno da média \bar{y} que é explicada pelo modelo de regressão.

Variância residual

- Variância residual σ^2

$$\sigma^2 = \frac{D(b_0, b_1)}{n - p},$$

- $D(b_0, b_1)$: somatório dos desvios, n : número de pontos e p : número de parâmetros estimados.
- No caso de regressão linear simples $u = b_0 + b_1x$, $p = 2$.
- Tanto o numerador quanto o denominador irão diminuir se forem introduzidos mais parâmetros no modelo.
- Redução global de σ^2 define se mais parâmetros devem ou não ser incorporados ao modelo.

Exemplo

- Calcular a reta de quadrados mínimos

x	1,2	2,5	3,0	4,1	6,2	7,1	8,8	9,5
y	6,8	6,1	9,9	9,7	12,1	17,9	18,0	21,5

- Dispositivo para regressão linear simples

i	x_i	y_i	x_i^2	$x_i y_i$	y_i^2	u_i	d_i	d_i^2
1	1,2	6,8	1,44	8,16	46,24	5,4037	1,3963	1,9497
2	2,5	6,1	6,25	15,25	37,21	7,7330	-1,6330	2,6667
3	3,0	9,9	9,00	29,70	98,01	8,6289	1,2711	1,6157
4	4,1	9,7	16,81	39,77	94,09	10,5999	-0,8999	0,8098
5	6,2	12,1	38,44	75,02	146,41	14,3627	-2,2627	5,1198
6	7,1	17,9	50,41	127,09	320,41	15,9753	1,9247	3,7045
7	8,8	18,0	77,44	158,40	324,00	19,0213	-1,0213	1,0431
8	9,5	21,5	90,25	204,25	462,25	20,2756	1,2244	1,4992
\sum	42,4	102,0	290,04	657,64	1528,62	102,0003	-0,0004	18,4085

- Cálculo dos parâmetros

$$b_1 = \frac{\sum x_i \sum y_i - n \sum x_i y_i}{(\sum x_i)^2 - n \sum x_i^2} = \frac{42,4 \cdot 102,0 - 8 \cdot 657,64}{(42,4)^2 - 8 \cdot 290,04} \leadsto b_1 = 1,7918;$$

$$b_0 = \frac{\sum y_i - b_1 \sum x_i}{n} = \frac{102,0 - 1,7918 \cdot 42,4}{8} \leadsto b_0 = 3,2535;$$


$$r^2 = 1 - \frac{D(b_0, b_1)}{\sum y_i^2 - \frac{1}{n}(\sum y_i)^2} = 1 - \frac{18,4085}{1528,62 - (102,0)^2/8} \leadsto r^2 = 0,9193;$$

$$\sigma^2 = \frac{18,4085}{8 - 2} \leadsto \sigma^2 = 3,0681.$$

Reta de quadrados mínimos

□ Equação de quadrados mínimos

$$u = 3,2535 + 1,7918x.$$



Regressão linear múltipla

- Modelo mais completo que relaciona a variável resposta y com as p variáveis explicativas x_i

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p + \epsilon,$$

- $\beta_i, i = 0, 1, \dots, p$: parâmetros a serem estimados e ϵ : variável aleatória desconhecida que interfere na verdadeira relação linear.

- Método dos quadrados mínimos utilizado para estimar os $p + 1$ parâmetros β_i

$$D(\beta_0, \beta_1, \beta_2, \dots, \beta_p) = \sum_{i=1}^n (y_i - u_i)^2 =$$

$$\sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_{i1} - \beta_2 x_{i2} - \dots - \beta_p x_{ip})^2.$$

- x_{ij} : i -ésima observação da j -ésima variável explicativa.

Método dos quadrados mínimos

□ Derivadas parciais de D

$$\frac{\partial D(\beta_0, \beta_1, \beta_2, \dots, \beta_p)}{\partial \beta_0} =$$

$$-2 \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_{i1} - \beta_2 x_{i2} - \dots - \beta_p x_{ip}),$$

$$\frac{\partial D(\beta_0, \beta_1, \beta_2, \dots, \beta_p)}{\partial \beta_1} =$$

$$-2 \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_{i1} - \beta_2 x_{i2} - \dots - \beta_p x_{ip}) x_{i1},$$

$$\frac{\partial D(\beta_0, \beta_1, \beta_2, \dots, \beta_p)}{\partial \beta_2} =$$

$$-2 \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_{i1} - \beta_2 x_{i2} - \dots - \beta_p x_{ip}) x_{i2},$$

⋮

$$\frac{\partial D(\beta_0, \beta_1, \beta_2, \dots, \beta_p)}{\partial \beta_p} =$$

$$-2 \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_{i1} - \beta_2 x_{i2} - \dots - \beta_p x_{ip}) x_{ip}.$$

Mínimo de $D(\beta_0, \beta_1, \beta_2, \dots, \beta_p)$

□ Se $D(b_0, b_1, b_2, \dots, b_p)$ for o ponto de mínimo da função $D(\beta_0, \beta_1, \beta_2, \dots, \beta_p)$

$$\frac{\partial D(b_0, b_1, b_2, \dots, b_p)}{\partial \beta_i} = 0, \quad i = 0, 1, \dots, p :$$

$$-2 \sum_{i=1}^n (y_i - b_0 - b_1 x_{i1} - b_2 x_{i2} - \dots - b_p x_{ip}) = 0 \leadsto$$

$$\sum_{i=1}^n b_0 + \sum_{i=1}^n b_1 x_{i1} + \sum_{i=1}^n b_2 x_{i2} + \dots + \sum_{i=1}^n b_p x_{ip} = \sum_{i=1}^n y_i,$$

$$-2 \sum_{i=1}^n (y_i - b_0 - b_1 x_{i1} - b_2 x_{i2} - \dots - b_p x_{ip}) x_{i1} = 0 \leadsto$$

$$\sum_{i=1}^n b_0 x_{i1} + \sum_{i=1}^n b_1 x_{i1} x_{i1} + \sum_{i=1}^n b_2 x_{i2} x_{i1} + \dots + \sum_{i=1}^n b_p x_{ip} x_{i1} = \sum_{i=1}^n x_{i1} y_i,$$

⋮

$$-2 \sum_{i=1}^n (y_i - b_0 - b_1 x_{i1} - b_2 x_{i2} - \dots - b_p x_{ip}) x_{ip} = 0 \leadsto$$

$$\sum_{i=1}^n b_0 x_{ip} + \sum_{i=1}^n b_1 x_{i1} x_{ip} + \sum_{i=1}^n b_2 x_{i2} x_{ip} + \dots + \sum_{i=1}^n b_p x_{ip} x_{ip} = \sum_{i=1}^n x_{ip} y_i.$$

Equações normais

Equações normais

$$\begin{bmatrix} n & \sum x_{i1} & \sum x_{i2} & \cdots & \sum x_{ip} \\ \sum x_{i1} & \sum x_{i1}x_{i1} & \sum x_{i2}x_{i1} & \cdots & \sum x_{ip}x_{i1} \\ \sum x_{i2} & \sum x_{i1}x_{i2} & \sum x_{i2}x_{i2} & \cdots & \sum x_{ip}x_{i2} \\ \vdots & \vdots & \vdots & \cdots & \vdots \\ \sum x_{ip} & \sum x_{i1}x_{ip} & \sum x_{i2}x_{ip} & \cdots & \sum x_{ip}x_{ip} \end{bmatrix} \begin{bmatrix} b_0 \\ b_1 \\ b_2 \\ \vdots \\ b_p \end{bmatrix} = \begin{bmatrix} \sum y_i \\ \sum x_{i1}y_i \\ \sum x_{i2}y_i \\ \vdots \\ \sum x_{ip}y_i \end{bmatrix}.$$

Vetor solução b $((p+1) \times 1)$ fornece os parâmetros para a equação de quadrados mínimos

$$u = b_0 + b_1x_1 + b_2x_2 + \dots + b_px_p.$$

Coeficiente de determinação

$$r^2 = 1 - \frac{D(b_0, b_1, \dots, b_p)}{\sum y_i^2 - \frac{1}{n} (\sum y_i)^2}.$$

Variância residual

$$\sigma^2 = \frac{D(b_0, b_1, b_2, \dots, b_p)}{n - p}.$$

Regressão polinomial

- Caso particular da regressão linear múltipla.
- Relaciona a variável resposta y com uma variável explicativa x , segundo o modelo

$$y = \beta_0 + \beta_1 x + \beta_2 x^2 + \dots + \beta_g x^g + \epsilon.$$

- Equações normais

$$\begin{bmatrix} n & \sum x_i & \sum x_i^2 & \dots & \sum x_i^g \\ \sum x_i & \sum x_i^2 & \sum x_i^3 & \dots & \sum x_i^{g+1} \\ \sum x_i^2 & \sum x_i^3 & \sum x_i^4 & \dots & \sum x_i^{g+2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \sum x_i^g & \sum x_i^{g+1} & \sum x_i^{g+2} & \dots & \sum x_i^{2g} \end{bmatrix} \begin{bmatrix} b_0 \\ b_1 \\ b_2 \\ \vdots \\ b_g \end{bmatrix} = \begin{bmatrix} \sum y_i \\ \sum x_i y_i \\ \sum x_i^2 y_i \\ \vdots \\ \sum x_i^g y_i \end{bmatrix}.$$

Algoritmo: regressão linear múltipla

```
Algoritmo Regressão_múltipla
{ Objetivo: Calcular parâmetros de quadrados mínimos }
parâmetros de entrada n, v, p, x, y
parâmetros de saída b, r2, sigma2
  se  $v > 1$  e  $v + 1 \neq p$  então, escreva modelo inválido, abandone, fim se
  para  $i \leftarrow 1$  até  $n$  faça { inclusão de uma coluna de 1's relativa à  $b_0$  }
    para  $j \leftarrow v + 1$  até 2 passo -1 faça,  $x(i,j) \leftarrow x(i,j - 1)$ , fim para
     $x(i, 1) \leftarrow 1$ 
  fim para
  se  $v = 1$  e  $p > 2$  então { se reg. polinomial gera potências de  $x$  }
    para  $j \leftarrow 2$  até  $p - 1$  faça
      para  $i \leftarrow 1$  até  $n$  faça,  $x(i,j + 1) \leftarrow x(i, 2)^j$ , fim para
    fim para
  fim se { equações normais }
  para  $i \leftarrow 1$  até  $p$  faça
    para  $j \leftarrow 1$  até  $p$  faça
      Soma  $\leftarrow 0$ 
      para  $k \leftarrow 1$  até  $n$  faça
        Soma  $\leftarrow$  Soma +  $x(k,i) * x(k,j)$ 
      fim para;  $Sxx(i,j) \leftarrow$  Soma { matriz dos coeficientes }
    fim para; Soma  $\leftarrow 0$ 
    para  $k \leftarrow 1$  até  $n$  faça
      Soma  $\leftarrow$  Soma +  $x(k,i) * y(k)$ 
    fim para;  $Sxy(i) \leftarrow$  Soma { vetor dos termos independentes }
  fim para
   $L \leftarrow$  Cholesky( $p, Sxx$ ) { decomposição de Cholesky }
   $t \leftarrow$  Substituições_Sucessivas( $p, L, Sxy$ )
  para  $i \leftarrow 1$  até  $p$  faça
    para  $j \leftarrow 1$  até  $i$  faça,  $U(j,i) \leftarrow L(i,j)$ , fim para {  $U = L^T$  }
  fim para
   $b \leftarrow$  Substituições_Retroativas( $p, U, t$ ) { coeficientes }
   $D \leftarrow 0$ ;  $Sy2 \leftarrow 0$ 
  para  $i \leftarrow 1$  até  $n$  faça
    Soma  $\leftarrow 0$ 
    para  $j \leftarrow 1$  até  $p$  faça
      Soma  $\leftarrow$  Soma +  $b(j) * x(i,j)$ 
    fim para
     $u(i) \leftarrow$  Soma;  $d(i) \leftarrow y(i) - u(i)$ ;  $D \leftarrow D + d(i)^2$ ;  $Sy2 \leftarrow Sy2 + y(i)^2$ 
  fim para
   $r2 \leftarrow 1 - D / (Sy2 - Sxy(1)^2 / n)$  { coeficiente de determinação }
   $sigma2 \leftarrow D / (n - p)$  { variância residual }
fim algoritmo
```


Exemplo

- Dados relacionando o peso y de embriões de frangos desidratados, em gramas, com a sua idade x , em dias.

i	x_i	y_i
1	6	0,029
2	7	0,052
3	8	0,079
4	9	0,125
5	10	0,181
6	11	0,261
7	12	0,425
8	13	0,738
9	14	1,130
10	15	1,882
11	16	2,812

Diagrama de dispersão

- ❑ O ajuste não deve ser feito por um polinômio de grau 1.
- ❑ Usar um polinômio de grau mais elevado.



Resultados

- Valores do coeficiente de determinação r^2 e da variância residual σ^2 para o modelo polinomial


$$u = b_0 + b_1x + b_2x^2 + \dots + b_gx^g$$

g	r^2	σ^2
1	0,74418	$2,32178 \times 10^{-1}$
2	0,96984	$3,07961 \times 10^{-2}$
3	0,99883	$1,36642 \times 10^{-3}$
4	0,99957	$5,86451 \times 10^{-4}$
5	0,99962	$6,21028 \times 10^{-4}$
6	0,99966	$7,04092 \times 10^{-4}$

- r^2 aumenta quando o grau do polinômio de quadrados mínimos é aumentado.
- σ^2 apresenta o menor valor para o grau $g = 4$.
- Este deve ser o grau escolhido para o ajuste polinomial.

Polinômio de regressão

- ❑ Polinômio de grau 4 traçado no diagrama de dispersão.



Transformações não lineares

- ❑ Modelos não lineares nos parâmetros podem ser transformados em modelos lineares.
- ❑ Faz-se uma simples substituição de variáveis por funções dessas variáveis.

$$y = ax^b \rightsquigarrow \log_e(y) = \log_e(a) + b \log_e(x);$$

$$y = ab^x \rightsquigarrow \log_e(y) = \log_e(a) + \log_e(b)x;$$

$$y = ae^{bx} \rightsquigarrow \log_e(y) = \log_e(a) + bx;$$

$$y = e^{a+bx_1+cx_2} \rightsquigarrow \log_e(y) = a + bx_1 + cx_2;$$

$$y = ax_1^b x_2^c \rightsquigarrow \log_e(y) = \log_e(a) + b \log_e(x_1) + c \log_e(x_2);$$

$$y = \frac{1}{a + bx_1 + cx_2} \rightsquigarrow \frac{1}{y} = a + bx_1 + cx_2;$$

$$y = \frac{1}{1 + e^{a+bx_1+cx_2}} \rightsquigarrow \log_e\left(\frac{1}{y} - 1\right) = a + bx_1 + cx_2.$$

Malcondicionamento

- Seja a equação de regressão polinomial

$$u = b_0 + b_1x + b_2x^2 + \dots + b_gx^g.$$

- Parâmetros b_i calculados via equações normais.
- Coeficiente de determinação r^2 e número de condição espectral $\kappa_2(X^T X)$ (embriões de frango)

g	r^2	$\kappa_2(X^T X)$
1	0,74418	$1,74040 \times 10^3$
2	0,96984	$3,93510 \times 10^6$
3	0,99883	$1,15846 \times 10^{10}$
4	0,99957	$4,12715 \times 10^{13}$
5	0,99962	$1,75113 \times 10^{17}$
6	0,99966	$4,83023 \times 10^{19}$
7	0,99972	$3,30131 \times 10^{21}$

- À medida que o grau g do polinômio aumenta, $r^2 \longrightarrow 1$ e $\kappa_2(X^T X) \longrightarrow \infty$.
- As equações normais possuem a matriz dos coeficientes malcondicionada.

Formas alternativas de estimar os parâmetros

- ❑ Modelo de regressão linear múltipla

$$y = X\beta + \epsilon,$$

- ❑ y : vetor $(n \times 1)$ contendo as n observações da variável resposta,
- ❑ X : matriz $(n \times (p + 1))$, $n \geq p + 1$, contendo os n valores das p variáveis explicativas, além da primeira coluna de 1's relativa à β_0 ,
- ❑ β : vetor $((p + 1) \times 1)$ dos parâmetros a serem estimados e
- ❑ ϵ : vetor $(n \times 1)$ dos erros aleatórios

$$y = \begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ y_4 \\ \vdots \\ y_n \end{bmatrix}, X = \begin{bmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1p} \\ 1 & x_{21} & x_{22} & \cdots & x_{2p} \\ 1 & x_{31} & x_{32} & \cdots & x_{3p} \\ 1 & x_{41} & x_{42} & \cdots & x_{4p} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{np} \end{bmatrix}, \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_p \end{bmatrix}, \epsilon = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \epsilon_3 \\ \epsilon_4 \\ \vdots \\ \epsilon_n \end{bmatrix}.$$

Estimativa do vetor β

- Minimizar a função

$$f(\beta) = \|y - X\beta\|_2^2 = (y - X\beta)^T (y - X\beta).$$

- Pelas regras de diferenciação matricial

$$\begin{aligned}\frac{\partial f(\beta)}{\partial \beta^T} &= \frac{\partial f(\beta)}{\partial (y - X\beta)^T} \frac{\partial (y - X\beta)}{\partial \beta^T}, \\ &= 2(y - X\beta)^T (-X) = -2(y - X\beta)^T X.\end{aligned}$$

$$\frac{\partial f(\beta)}{\partial \beta} = -2X^T (y - X\beta).$$

- A função $f(\beta)$ apresenta um mínimo em $f(b)$, onde b é o ponto em que a derivada se anula

$$\frac{\partial f(b)}{\partial \beta} = -2X^T (y - Xb) = 0 \leadsto (X^T X)b = X^T y.$$

- Equações normais na forma matricial

$$\frac{\partial(\partial f(\beta)/\partial \beta)}{\partial \beta^T} = \frac{\partial(-2X^T y + 2X^T X\beta)}{\partial \beta^T} = 2X^T X.$$

Equações normais

- ❑ Matriz $X^T X$ tem elementos reais, é não singular, e é definida positiva.
- ❑ O ponto $f(b)$ é, de fato, um mínimo de $f(\beta)$.
- ❑ Equações normais formam um sistema malcondicionado.
- ❑ Processos alternativos para a estimativa de β que evitam a formação da matriz $X^T X$.

Decomposição QR

- O vetor b deve minimizar a soma de quadrados residual

$$\|y - Xb\|_2^2.$$

- Decomposição QR da matriz X ($n \times (p + 1)$)

$$X = QR,$$

- Q : matriz ortogonal ($n \times n$) e
- R : matriz triangular superior ($n \times (p + 1)$) da forma

$$R = \begin{bmatrix} R_1 \\ 0 \end{bmatrix},$$

- R_1 : matriz quadrada triangular superior de ordem $p + 1$.

Estimativa dos parâmetros

- Soma de quadrados residual

$$\|y - Xb\|_2^2 = \|y - QRb\|_2^2.$$

- Como Q é uma matriz ortogonal, $Q^T Q = I$

$$\|y - Xb\|_2^2 = \|Q^T y - Q^T QRb\|_2^2 \leadsto$$

$$\|y - Xb\|_2^2 = \|Q^T y - Rb\|_2^2.$$

- Definindo

$$Q^T y = c = \begin{bmatrix} c_1 \\ c_2 \end{bmatrix},$$

- c_1 : vetor $(p + 1)$ e c_2 : vetor $(n - p - 1)$

$$Rb = \begin{bmatrix} R_1 \\ 0 \end{bmatrix} b = \begin{bmatrix} R_1 b \\ 0 \end{bmatrix},$$

$$\|y - Xb\|_2^2 = \left\| \begin{bmatrix} c_1 \\ c_2 \end{bmatrix} - \begin{bmatrix} R_1 b \\ 0 \end{bmatrix} \right\|_2^2 = \|c_1 - R_1 b\|_2^2 + \|c_2\|_2^2.$$

Estimativa dos parâmetros cont.

- Soma de quadrados residual será mínima quando

$$R_1 b - c_1 = 0,$$

- b for a solução do sistema triangular superior

$$R_1 b = c_1.$$

- Soma de quadrados residual SQRes

$$D(b_0, b_1, \dots, b_p) = \|c_2\|_2^2 = c_2^T c_2.$$

- Valores preditos

$$u = Xb = QRb = Q \begin{bmatrix} R_1 b \\ 0 \end{bmatrix} \rightsquigarrow u = Q \begin{bmatrix} c_1 \\ 0 \end{bmatrix}.$$

- Vetor dos desvios $d = y - Xb$

$$d = Qc - QRb = Q(c - Rb) = Q \begin{bmatrix} c_1 - R_1 b \\ c_2 - 0b \end{bmatrix},$$

$$d = Q \begin{bmatrix} 0 \\ c_2 \end{bmatrix}.$$

Decomposição do valor singular

- Decomposição do valor singular de uma matriz X ($n \times (p + 1)$)

$$X = USV^T,$$

- U : matriz ortogonal ($n \times n$),
- V : matriz ortogonal ($(p + 1) \times (p + 1)$) e
- S : matriz diagonal ($n \times (p + 1)$) da forma

$$S = \begin{bmatrix} S_1 \\ 0 \end{bmatrix},$$

- S_1 : matriz diagonal de ordem $p + 1$.

Estimativa dos parâmetros

- Soma de quadrados residual

$$\|y - Xb\|_2^2 = \|y - USV^T b\|_2^2.$$

- Matriz ortogonal U^T não altera o valor da norma

$$\|y - Xb\|_2^2 = \|U^T y - U^T USV^T b\|_2^2 = \|U^T y - SV^T b\|_2^2.$$

- Sendo

$$U^T y = a = \begin{bmatrix} a_1 \\ a_2 \end{bmatrix}, \quad \tilde{b} = V^T b$$

- a_1 : vetor $(p + 1)$ e a_2 : vetor $(n - p - 1)$

$$S\tilde{b} = \begin{bmatrix} S_1 \\ 0 \end{bmatrix} \tilde{b} = \begin{bmatrix} S_1 \tilde{b} \\ 0 \end{bmatrix},$$

$$\|y - Xb\|_2^2 = \left\| \begin{bmatrix} a_1 \\ a_2 \end{bmatrix} - \begin{bmatrix} S_1 \tilde{b} \\ 0 \end{bmatrix} \right\|_2^2 \leadsto$$

$$\|y - Xb\|_2^2 = \|a_1 - S_1 \tilde{b}\|_2^2 + \|a_2\|_2^2.$$

Estimativa dos parâmetros cont.

- Soma de quadrados residual será mínima quando \tilde{b} for a solução do sistema diagonal

$$S_1 \tilde{b} = a_1.$$

- Pela ortogonalidade de V

$$b = V \tilde{b}.$$

- Soma de quadrados residual

$$D(b_0, b_1, \dots, b_p) = \|a_2\|_2^2 = a_2^T a_2.$$

- Valores preditos

$$u = Xb = USV^T b = US \tilde{b} = U \begin{bmatrix} S_1 \tilde{b} \\ 0 \end{bmatrix} \rightsquigarrow u = U \begin{bmatrix} a_1 \\ 0 \end{bmatrix}.$$

- Vetor desvio $d = y - Xb$

$$d = U \begin{bmatrix} 0 \\ a_2 \end{bmatrix}.$$

Comparação dos métodos para RLM

□ Equações normais: vantagens

- Maior velocidade com que podem ser formadas e resolvidas.
- Com uso de *precisão dupla*, a diferença de exatidão dos dois métodos, poucas vezes, valerá a pena ser considerada.

□ Equações normais: desvantagens

- Número de condição da matriz $X^T X$ é o quadrado daquele da matriz X .
- Difícil computar $X^T X$ e $X^T y$, exatamente.
- Perturbações feitas no problema básico podem ter conseqüências desastrosas.

□ Métodos de ortogonalização: vantagens

- Superiores propriedades numéricas.
- Grande quantidade de memória disponível a custo baixo.

□ Métodos de ortogonalização: desvantagens

- Requerem maior quantidade de memória.
- Complexidade computacional é maior que a da decomposição de Cholesky.

Diferença entre regressão e interpolação

- ❑ Polinômio interpolador de grau $n - 1$ construído de modo a passar por n pontos

$$P_{n-1}(x) = a_0 + a_1x + a_2x^2 + \dots + a_{n-1}x^{n-1}.$$

- ❑ Possui n coeficientes a_i , $i = 0, 1, \dots, n - 1$.
- ❑ O número de pontos utilizados para gerar o polinômio interpolador é igual ao número de coeficientes do polinômio.
- ❑ Polinômio de regressão de grau g , usando n pontos

$$U_g(x) = b_0 + b_1x + b_2x^2 + \dots + b_gx^g,$$

- ❑ sendo $g \leq n - 1$.
- ❑ Quando $g = n - 1$ o polinômio de regressão será idêntico ao polinômio interpolador.

Sistema linear e equações normais

□ Polinômio interpolador de grau $g = 1$ que passa por $n = 2$ pontos (x_1, y_1) e (x_2, y_2) .

□ Coeficientes obtidos pela solução do sistema linear

$$\begin{bmatrix} 1 & x_1 \\ 1 & x_2 \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \end{bmatrix} = \begin{bmatrix} y_1 \\ y_2 \end{bmatrix}.$$

□ Pré-multiplicando pela transposta da matriz dos coeficientes


$$\begin{bmatrix} 1 & 1 \\ x_1 & x_2 \end{bmatrix} \begin{bmatrix} 1 & x_1 \\ 1 & x_2 \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \end{bmatrix} = \begin{bmatrix} 1 & 1 \\ x_1 & x_2 \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \end{bmatrix} \rightsquigarrow$$

$$\begin{bmatrix} 2 & x_1 + x_2 \\ x_1 + x_2 & x_1^2 + x_2^2 \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \end{bmatrix} = \begin{bmatrix} y_1 + y_2 \\ x_1 y_1 + x_2 y_2 \end{bmatrix}.$$

□ O sistema linear é idêntico às equações normais, para $n = 2$, utilizadas para calcular os parâmetros de uma regressão linear simples.


Regressão polinomial quadrática

- Polinômio de regressão de grau $g = 2$ com $n = 5$ pontos.



Regressão idêntica à interpolação

- ❑ Quando o polinômio de regressão possuir grau $g = n - 1 = 4$ ele se torna idêntico a um polinômio interpolador de mesmo grau.
- ❑ O polinômio passa por todos os pontos do diagrama de dispersão.



Uso da regressão e da interpolação

- ❑ Em termos de complexidade computacional, a interpolação é um processo mais simples que a regressão polinomial.
- ❑ A interpolação deve ser utilizada quando se necessita de um valor intermediário não constante de uma tabela.
- ❑ A regressão tem que ser utilizada quando se deseja estimar um parâmetro de um modelo semide-terminístico e/ou prever um valor dado por esse modelo.
- ❑ A variância residual tende ao infinito à medida que o número de parâmetros p do modelo se aproxima do número de pontos n

$$\sigma^2 = \frac{D(b_0, b_1, b_2, \dots, b_p)}{n - p}.$$