



escola
britânica de
artes criativas
& tecnologia

Profissão: Cientista de Dados

Análise de Regressão

O que é um modelo?


O que é um modelo?



Base e premissas


	total_bill	tip	sex	smoker	day	time	size	tip_pct
0	16.99	1.01	Female	No	Sun	Dinner	2	0.063204
1	10.34	1.66	Male	No	Sun	Dinner	3	0.191244
2	21.01	3.50	Male	No	Sun	Dinner	3	0.199886
3	23.68	3.31	Male	No	Sun	Dinner	2	0.162494
4	24.59	3.61	Female	No	Sun	Dinner	4	0.172069

O que é um modelo?



Introdução

Introdução



Y = tip_pct (% de gorjeta)
X = net_bill (valor da conta)

$$y_i = \alpha + \beta x_i + \varepsilon_i$$


Com $i = 1, \dots, N$
 $\varepsilon_i \sim N(0, \sigma^2)$ i.i.d.

α e β são constantes desconhecidas.

Usando estimativas pontuais temos:

$$y = \hat{\alpha} + \hat{\beta}x + \hat{\varepsilon}$$

Entendendo a equação



$$\hat{y} = \hat{\alpha} + \hat{\beta}x$$

$$\hat{\alpha} = 1,33$$

$$\hat{\beta} = 0,10$$

Se $x = 10$:

$$\hat{y} = 1,33 + 0,10 * 10 = 2,33$$

Se $x = 20$:


$$\hat{y} = 1,33 + 0,10 * 20 = 3,33$$

Se $x = 30$:

$$\hat{y} = 1,33 + 0,10 * 30 = 4,33$$

Interpretação dos parâmetros


Interpretação dos parâmetros



$$y_i = \alpha + \beta x_i + \varepsilon_i$$

Com $i = 1, \dots, N$
 $\varepsilon_i \sim N(0, \sigma^2)$ i.i.d.

- α é o valor esperado de y quando x é zero.
- β é o aumento esperado em y para cada unidade que se incrementa em x .
- ε é um erro aleatório do valor de y , quando predito pelo modelo.
- σ^2 é a variância dos erros ε_i



Isto é um
modelo!

"All models are wrong,
but some are useful"


"Todos os modelos estão errados,
mas alguns são úteis"

George E. P. Box



Obtendo as estimativas

Os erros



Y = tip_pct (% de gorjeta)
X = net_bill (valor da conta)

$$y_i = \alpha + \beta x_i + \varepsilon_i$$

Com $i = 1, \dots, N$
 $\varepsilon_i \sim N(0, \sigma^2)$ i.i.d.

α e β são constantes desconhecidas.

Usando estimativas pontuais temos:

$$y = \hat{\alpha} + \hat{\beta}x + \hat{\varepsilon}$$

Os erros

$$\left. \begin{array}{l} \hat{y}_i = \hat{\alpha} + \hat{\beta}x_i \\ y_i = \hat{\alpha} + \hat{\beta}x_i + \hat{\varepsilon}_i \end{array} \right\} y_i = \hat{y}_i + \hat{\varepsilon}_i$$

$$\hat{\varepsilon}_i = y_i - \hat{y}_i \quad \Rightarrow \quad \hat{\varepsilon}_i = y_i - \hat{\alpha} - \hat{\beta}x_i$$

$$QME = \frac{1}{N} \sum_i^N \hat{\varepsilon}_i^2 \qquad SQE = \sum_i^N \hat{\varepsilon}_i^2$$


Minimizando os erros

$$SQE = \sum_i^N \left(y_i - (\hat{\alpha} + \hat{\beta}x_i) \right)^2$$


$\hat{\alpha}$ e $\hat{\beta}$ correspondem a a e b que minimizam:

$$SQE = \sum_i^N \left(y_i - (a + bx_i) \right)^2$$

Erro em
função dos
parâmetros



Erro em
função dos
parâmetros



Estimador de mínimos cuadrados

$$\frac{\partial SQE}{\partial \alpha} = 0 \quad \Rightarrow \quad \hat{\alpha} = \bar{y} - \hat{\beta} \bar{x}$$

$$\frac{\partial SQE}{\partial \beta} = 0 \quad \Rightarrow \quad \hat{\beta} = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^N (x_i - \bar{x})^2}$$

Propriedades dos estimadores de mínimos quadrados

- A soma dos resíduos é zero $\sum_{i=1}^N \hat{\varepsilon}_i = 0$
- Os resíduos não têm correlação linear com os preditores
- O ponto (\bar{x}, \bar{y}) está sempre na reta
- A distribuição dos estimadores é conhecida


Qualidade do modelo

Decomposição da variância

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

$$\text{SQM} = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$$

$$\text{SQE} = \sum_{i=1}^n (y_i - \hat{y}_i)^2$$




Decomposição da variância

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

$$\text{SQM} = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$$

$$\text{SQE} = \sum_{i=1}^n (y_i - \hat{y}_i)^2$$




Decomposição da variância

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

$$\text{SQM} = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$$

$$\text{SQE} = \sum_{i=1}^n (y_i - \hat{y}_i)^2$$


$$\text{SQT} = \text{SQM} + \text{SQE}$$



Coeficiente de determinação


R^2 – coeficiente de determinação

$$R^2 = \frac{SQM}{SQT} = 1 - \frac{SQE}{SQT}$$



Análise de Resíduos

Análise de resíduos






Desejado:


- Nenhum padrão evidente
- Aspecto de independência
- Variância uniforme

Análise de resíduos


$Y * X$




Res * X



Resíduo aumenta



Relação convexa



Relação côncava

Multiplicação de matrizes

Multiplicação de matrizes

$$A = \begin{pmatrix} 1 & 2 \\ 1 & 3 \\ 2 & 4 \end{pmatrix}$$

$$B = \begin{pmatrix} 1 & 3 \\ 2 & 4 \end{pmatrix}$$

$$A.B = \begin{pmatrix} 1 & 2 \\ 1 & 3 \\ 2 & 4 \end{pmatrix} \begin{pmatrix} 1 & 3 \\ 2 & 4 \end{pmatrix} = \begin{pmatrix} 5 & 11 \\ 7 & 15 \\ 10 & 22 \end{pmatrix}$$

Multiplicação de matrizes

$$A = \begin{pmatrix} 1 & 2 \\ 1 & 3 \\ 2 & 4 \end{pmatrix}$$

$$B = \begin{pmatrix} 1 & 3 \\ 2 & 4 \end{pmatrix}$$

$$A.B = \begin{pmatrix} 1 & 2 \\ 1 & 3 \\ 2 & 4 \end{pmatrix} \begin{pmatrix} 1 & 3 \\ 2 & 4 \end{pmatrix} = \begin{pmatrix} 5 & 11 \\ 7 & 15 \\ 10 & 22 \end{pmatrix}$$

$\textcolor{blue}{3} \times 2 \qquad 2 \times \textcolor{red}{2} \qquad \textcolor{blue}{3} \times \textcolor{red}{2}$

Multiplicação de matrizes

$$A = \begin{pmatrix} 1 & 2 \\ 1 & 3 \\ 2 & 4 \end{pmatrix}$$

$$B = \begin{pmatrix} 1 & 3 \\ 2 & 4 \end{pmatrix}$$

$$A.B = \begin{pmatrix} 1 & 2 \\ 1 & 3 \\ 2 & 4 \end{pmatrix} \begin{pmatrix} 1 \\ 2 \\ 3 \\ 4 \end{pmatrix} = \begin{pmatrix} 5 & 11 \\ 7 & 15 \\ 10 & 22 \end{pmatrix}$$

$$1 \times 1 + 2 \times 2 = 5$$

Multiplicação de matrizes

$$A = \begin{pmatrix} 1 & 2 \\ 1 & 3 \\ 2 & 4 \end{pmatrix}$$

$$B = \begin{pmatrix} 1 & 3 \\ 2 & 4 \end{pmatrix}$$

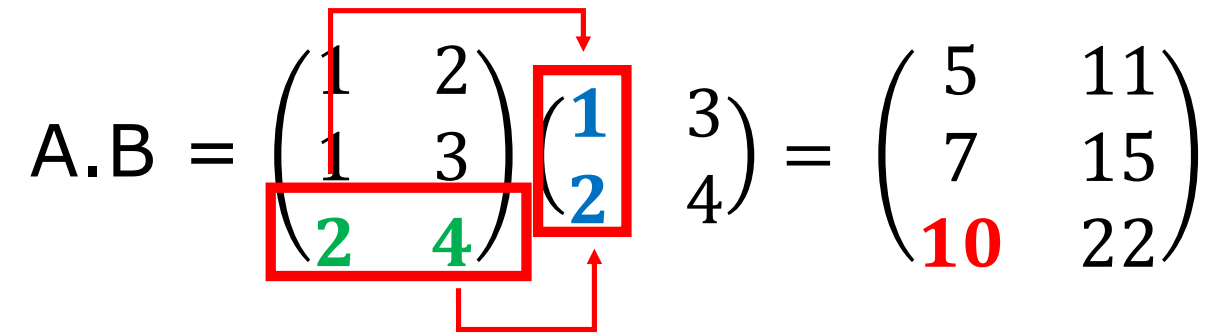
$$A.B = \begin{pmatrix} 1 & 2 \\ \boxed{1} & \boxed{3} \\ 2 & 4 \end{pmatrix} \begin{pmatrix} \boxed{1} \\ \boxed{2} \\ 3 \\ 4 \end{pmatrix} = \begin{pmatrix} 5 & 11 \\ 7 & 15 \\ 10 & 22 \end{pmatrix}$$

$$1 \times 1 + 3 \times 2 = 7$$

Multiplicação de matrizes

$$A = \begin{pmatrix} 1 & 2 \\ 1 & 3 \\ 2 & 4 \end{pmatrix}$$

$$B = \begin{pmatrix} 1 & 3 \\ 2 & 4 \end{pmatrix}$$

$$A.B = \begin{pmatrix} 1 & 2 \\ 1 & 3 \\ 2 & 4 \end{pmatrix} \begin{pmatrix} 1 \\ 2 \\ 3 \\ 4 \end{pmatrix} = \begin{pmatrix} 5 & 11 \\ 7 & 15 \\ \mathbf{10} & 22 \end{pmatrix}$$


$$2 \times 1 + 4 \times 2 = 10$$

Multiplicação de matrizes

$$A = \begin{pmatrix} 1 & 2 \\ 1 & 3 \\ 2 & 4 \end{pmatrix}$$

$$B = \begin{pmatrix} 1 & 3 \\ 2 & 4 \end{pmatrix}$$

$$A.B = \begin{pmatrix} 1 & 2 \\ 1 & 3 \\ 2 & 4 \end{pmatrix} \begin{pmatrix} 1 & 3 \\ 2 & 4 \end{pmatrix} = \begin{pmatrix} 5 & \mathbf{11} \\ 7 & 15 \\ 10 & 22 \end{pmatrix}$$

$$1 \times 3 + 2 \times 4 = 11$$

Multiplicação de matrizes

$$A = \begin{pmatrix} 1 & 2 \\ 1 & 3 \\ 2 & 4 \end{pmatrix}$$

$$B = \begin{pmatrix} 1 & 3 \\ 2 & 4 \end{pmatrix}$$

$$A.B = \begin{pmatrix} 1 & 2 \\ \color{green}{1} & \color{green}{3} \\ 2 & 4 \end{pmatrix} \begin{pmatrix} 1 & \color{blue}{3} \\ 2 & \color{blue}{4} \end{pmatrix} = \begin{pmatrix} 5 & 11 \\ 7 & \color{red}{15} \\ 10 & 22 \end{pmatrix}$$

$$\color{green}{1} \times \color{blue}{3} + \color{green}{3} \times \color{blue}{4} = \color{red}{15}$$

Multiplicação de matrizes

$$A = \begin{pmatrix} 1 & 2 \\ 1 & 3 \\ 2 & 4 \end{pmatrix}$$

$$B = \begin{pmatrix} 1 & 3 \\ 2 & 4 \end{pmatrix}$$

$$A \cdot B = \begin{pmatrix} 1 & 2 \\ 1 & 3 \\ 2 & 4 \end{pmatrix} \begin{pmatrix} 1 & \boxed{3} \\ 2 & \boxed{4} \end{pmatrix} = \begin{pmatrix} 5 & 11 \\ 7 & 15 \\ 10 & \mathbf{22} \end{pmatrix}$$

$2 \times 3 + 4 \times 4 = 22$

Multiplicação de matrizes e a regressão

$$X = \begin{pmatrix} 1 & 3 \\ 1 & 2 \\ 1 & 4 \end{pmatrix} \quad X \cdot \hat{B} = \begin{pmatrix} 1 & 3 \\ 1 & 2 \\ 1 & 4 \end{pmatrix} \begin{pmatrix} \hat{\alpha} \\ \hat{\beta} \end{pmatrix} = \begin{pmatrix} \hat{\alpha} + 3\hat{\beta} \\ \hat{\alpha} + 2\hat{\beta} \\ \hat{\alpha} + 4\hat{\beta} \end{pmatrix} = \begin{pmatrix} \hat{y}_1 \\ \hat{y}_2 \\ \hat{y}_3 \end{pmatrix}$$

$$\hat{B} = \begin{pmatrix} \hat{\alpha} \\ \hat{\beta} \end{pmatrix}$$

$$y = \begin{pmatrix} y_1 \\ y_2 \\ y_3 \end{pmatrix}$$

Matrizes e regressão múltipla

$$X = \begin{pmatrix} 1 & 3 & 1 \\ 1 & 2 & 0 \\ 1 & 4 & 0 \end{pmatrix}$$

$$X \cdot \hat{B} = \begin{pmatrix} 1 & 3 & 1 \\ 1 & 2 & 0 \\ 1 & 4 & 0 \end{pmatrix} \begin{pmatrix} \hat{\alpha} \\ \hat{\beta}_1 \\ \hat{\beta}_2 \end{pmatrix}$$

$$\hat{B} = \begin{pmatrix} \hat{\alpha} \\ \hat{\beta}_1 \\ \hat{\beta}_2 \end{pmatrix}$$

$$= \begin{pmatrix} \hat{\alpha} + 3\hat{\beta}_1 + 1\hat{\beta}_2 \\ \hat{\alpha} + 2\hat{\beta}_1 + 0\hat{\beta}_2 \\ \hat{\alpha} + 4\hat{\beta}_1 + 0\hat{\beta}_2 \end{pmatrix} = \begin{pmatrix} \hat{y}_1 \\ \hat{y}_2 \\ \hat{y}_3 \end{pmatrix}$$