

1

PRELIMINARES:

ESPERANÇA CONDICIONAL:

$$E(Y|X=x) = \sum_{i=1}^n y_i P(Y=y_i | X=x_i)$$

$E(Y|x) = \mu(x)$
 ↓
 variável dependente (aplicada)
 ↓
 variável independente (aplicativa)

Forma que $E(Y|x)$ é uma fç de x.

$$\tilde{\pi} = f(e, \theta) = \mu(e) + \theta = \mu(V) + \theta$$

Sempre é importante pensarmos em modelos. (Quem nos sabe como nossos componentes estão prejudicando sua matéria-prima)


$$P_l = \bar{w} + \beta G$$

(Preço do leite) = Preço mínimo + Qualidade

$$P_l = \bar{w} + \beta_1 G + \beta_2 C + \beta_3 D + \epsilon$$

→ contaminação
 → gordura no leite
 → resíduo (erro)
 → distância

Vamos olhar, por enquanto, somente G



Produto A (G, P_l) → Qtid de gordura
 Preço recebido pelo leite
 Refinado de uma planta: Produto A B ...
 Q de gord (%) 5%
 Preço recebido (\$) 2.00

Resumo

$$\pi = f(V, \theta)$$

$$\pi = \beta V + \theta$$

$$\mu_1 = \mu_2$$

$$\hat{\beta} = \beta$$

$$\left. \begin{array}{c} \hat{\beta} = 0,2 \\ \beta \end{array} \right\}$$

Amostra

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

Produto
(leite
y + g)

$$H: \beta = 0$$

$$W = f(G, G_p, \dots)$$

$$\hat{W} = \alpha + \beta_1 G + \beta_2 G_p + \varepsilon$$

Reg. Linear (múltipla)

Matrizes

$$X \sim \mu$$

μ_1	μ_2
μ_3	μ_4

$$\hat{\mu}_1 = \hat{\mu}_2 = \hat{\mu}_3 = \hat{\mu}_4$$

$$R = \bar{W} + \beta Q$$

(simples)

Parâmetro x Estatística (estimadores)

$$P = \bar{W} + \beta G$$

$$\hat{P} = \hat{\bar{W}} + \hat{\beta} G$$

↳ Média } $\bar{X}$
 Variância } $\left\{ \begin{array}{l} \sigma^2 \\ S^2 \end{array} \right\}$


2) Veja q. na nossa amostra haviam n indivíduos onde cada um recebeu P_i , dado G_i .

$$\Rightarrow E(P|G) = \bar{w} + \beta G + \epsilon$$


É uma regressão: Assume que o valor médio do P é uma f. linear de G
 $\hookrightarrow$ Posso considerar uma equação linear

erro ou Resíduo

$\downarrow$
 Há outros fatores q. afetam P



β - representa o qto. da o preço médio (P) varia q. aumento de uma unidade de quantidade



Veja q. isso só é válido p. modelo linear.
 Se $P = \bar{w} e^{\beta G} > \bar{n}$ linear $\therefore \bar{n}$ vale
 posso fazer $\ln P = \ln \bar{w} + \beta G$ (log linear)

$\Downarrow$
 O melhor $\hat{\beta}$ e $\hat{\alpha}$,
 então menor ϵ
 $\hat{\beta} \rightarrow \beta / \hat{\alpha} \rightarrow \bar{w}$

3) Nosso objetivo ESTIMAR $(\beta \text{ e } \bar{w})$
 $\hookrightarrow$ estimadores da
 negreio.

Se descobirmos estes
 valores conhecemos como G afeta

P (de outra forma: como meu concorrente
 valoriza a % de gordura
 no leite.

P/ descobrir esses estimadores usamos um
 Procedimento: Mínimo Quadrado Ordinários (MQO)
 (cap 11 - item 11.4)

$\Rightarrow$ Estamos interessados em descobrir o
 parâmetro populacional através do estimador
 da amostra.

$\beta \rightarrow$ p/ população

$\hat{\beta} \rightarrow$ p/ amostra

$\Rightarrow \underline{P = \bar{w} + \beta G}$ > População
 $\hat{P} = \hat{\alpha} + \hat{\beta} G$ > Amostra
 O que queremos
 $\hat{\beta}$ e dele
 fazer inferência
 sobre β

Hipóteses importantes:

- 1) $G \rightarrow$ determinística
- 2) $E(e_i | G) = 0$ (valor médio do erro = 0)
- 3) $Var(e_i | G) = \sigma_e^2$ (variância constante)
- 4) Erros são não-correlacionados

$$\hat{P} = \hat{\alpha} + \hat{\beta} G_i + e_i$$

$$e = P - \hat{P}$$

$$\hat{P} = \hat{\alpha} + \hat{\beta} G_i + e =$$

$$Cov(e_i, e_j) = \frac{cov(e_i, e_j)}{\sigma(e_i) \sigma(e_j)} = 0$$

P/ encontrar $\hat{\alpha}$ e $\hat{\beta}$ (estimadores) devemos fazer:

$$e_i = P - (\alpha + \beta G_i) \Rightarrow \sum_{i=1}^n e_i = \sum_{i=1}^n (P_i - (\alpha + \beta G_i))$$

e levando ao quadrado temos:

$$SQ(\alpha, \beta) = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (P_i - \underline{\alpha + \beta G_i})^2$$

Ao derivar em relação a α e β temos:

REVISÃO

Modelo:

$$P_L = \hat{\omega} + \hat{\beta}G + e$$

$\hat{\omega}$
 $\hat{\beta}$ } estimadores

Quero saber se
G afeta o preço

$H_0: G \rightarrow P_L$
afeta

Posso escrever:

$$\left. \begin{array}{l} H_0: \beta = 0 \\ H_1: \beta \neq 0 \end{array} \right\} \underline{\text{teste}}$$

Sei que:

$$\left\{ \begin{array}{l} \hat{\alpha} = \bar{P} - \hat{\beta} \bar{G} \\ \hat{\beta} = \frac{\sum_{i=1}^n G_i P_i - n \bar{G} \bar{P}}{\sum_{i=1}^n G_i^2 - n \bar{G}^2} \end{array} \right.$$


P_L = dependente
 G = explicativa
estímulo
dados

$$G(\%) \rightarrow P_L$$

$$Y = \alpha + \beta_1 G + \beta_2 V + \epsilon$$

$\hat{Y} = \hat{\alpha} + \hat{\beta}_1 G + \hat{\beta}_2 V + \hat{e}$
 $Y - \hat{Y} = e$

ϵ erro
 $\hat{e}$ residual



4) 1) $n\bar{Y} + \hat{\beta} \sum_{i=1}^n G_i = \sum_{i=1}^n P_i$

2) $\hat{\alpha} \sum_{i=1}^n G_i + \hat{\beta} \sum_{i=1}^n G_i^2 = \sum_{i=1}^n G_i P_i$

Desse modo:
(1)

$$\hat{\alpha} = \bar{P} - \hat{\beta} \bar{G}$$

Desse modo:
(2)

$$\hat{\beta} = \frac{\sum_{i=1}^n G_i P_i - n \bar{G} \bar{P}}{\sum_{i=1}^n G_i^2 - n \bar{G}^2}$$

$E(\hat{\alpha}) = \alpha$
 $E(\hat{\beta}) = \beta$

modelo teorico

Nosso modelo para a amostra é:

$$\hat{P} = \hat{\alpha} + \hat{\beta} G_i$$

representa $\bar{P}$ representa β

$$P = \bar{P} + \beta G_i$$

Vamos a um exemplo:

TABELA 1 DADOS

Produtor	Preço (\$)	Gordura (%)	$P G$	P^2	G^2
1	4	1	4		
2	6	2	12		
3	8	4	32		
4	14	8	112		
5	12	6	72		
6	10	5	50		
7	16	8	128		
8	16	9	144		
9	12	7	84		

$n = 9$

$\sum_{i=1}^9 P_i = 98$

$\sum_{i=1}^9 G_i = 50$

$\sum_{i=1}^9 G_i P_i$

Veja que precisamos gerar $\hat{\alpha}$ e $\hat{\beta}$ p/ chegar a $\hat{P} = \hat{\alpha} + \hat{\beta} G$

$$5) \text{ como } \left\{ \begin{array}{l} \hat{Z} = \bar{P} + \hat{\beta} \bar{G} \\ \hat{\beta} = \frac{\sum_{i=1}^n G_i P_i - n \bar{G} \bar{P}}{\sum_{i=1}^n G_i^2 - n \bar{G}^2} \end{array} \right.$$

Para fazer os cálculos:

$$\sum_{i=1}^n G_i P_i = 638 \quad \bar{G} = \frac{50}{9} = 5,556$$

$$\sum_{i=1}^n G_i^2 = 340 \quad \bar{P} = \frac{98}{9} = 10,89$$

$$\text{daí: } \hat{\beta} = \frac{638 - 9(5,6)(10,9)}{340 - 9(5,6)^2} = \frac{638 - 549,36}{340 - 282,24}$$


$$\hat{\beta} = \frac{88,64}{57,76} \approx 1,5$$

$$\text{daí: } \hat{Z} = \bar{P} - 1,5 \bar{G} = 10,9 - 1,5(5,6) = 10,9 - 8,4 \approx 2,5 //$$

Assim:

$$\hat{P} = 2,5 + 1,5 G$$

A priori aumento em 1% em G faz o P aumentar 1,5 vezes



$$\begin{array}{l} P/G = 4\% \quad P = 2,5 + 1,5(4) = 8,5 \\ G = 5\% \quad \hat{P} = 2,5 + 1,5(5) = 10,0 \end{array}$$

b) Como saber se nosso modelo está adequado?

⇒ Usamos o coeficiente de determinação: R^2

Da aula passada aprendemos a gerar as seguintes somas de Quadrado (SQ)

P/ Regressão linear podemos fazer:

$$\underline{SQ_{Total}} = \sum_{i=1}^n (P_i - \bar{P})^2$$

desvio entre preço observado e o preço médio.

$$\underline{SQ_{Res}} = \sum_{i=1}^n \hat{e}_i^2 = \sum_{i=1}^n (\hat{P}_i - \bar{P})^2$$

↳ soma dos quadrados do resíduo.

Podemos fazer: $SQ_{Reg} = SQ_{Tot} - SQ_{Res}$

Podemos fazer:

$$SQ_{Tot} = SQ_{Reg} + SQ_{Res}$$

sempre: $(P_i - \bar{P}) = \underbrace{P_i - \hat{P}_i}_{e_i} + \underbrace{\hat{P}_i - \bar{P}}$

$$\Rightarrow (P_i - \bar{P}) = e_i + (\hat{P}_i - \bar{P})$$

elevando ao quadrado e somando

$$\sum (P_i - \bar{P})^2 = \sum_{i=1}^n e_i^2 + \sum_{i=1}^n (\hat{P}_i - \bar{P})^2$$

$$SQ_{Tot} = \sum_{i=1}^n (P_i - \bar{P})^2 + SQ_{Res}$$

$$\therefore SQ_{Reg} = \sum_{i=1}^n (\hat{P}_i - \bar{P})^2$$

7)

Sei tbm que $\hat{P}_i = \hat{\omega} + \hat{\beta} \xi_i$

posso fazer $\hat{P}_i = \bar{P} - \hat{\beta} \bar{\xi} + \hat{\beta} \xi_i$

$\hat{P}_i = \bar{P} + \hat{\beta} (\bar{\xi} - \xi_i)$

$\Rightarrow \hat{P}_i - \bar{P} = \hat{\beta} (\bar{\xi} - \xi_i)$

$\therefore SQ_{Reg} = \hat{\beta}^2 \sum_{i=1}^n (\bar{\xi} - \xi_i)^2$

Posso fazer agora $R^2 = \frac{SQ_{Reg}}{SQ_{TOT}}$ nunca negativo

Explica o qto da variacao total e explicada pela regressao


Ajusta a linha de regressao

$R^2 = 1$ (explica totalmente)

$R^2 = 0$ (n explicada nada)

$R^2 = \frac{\sum_{i=1}^n (\hat{P}_i - \bar{P})^2}{\sum_{i=1}^n (P_i - \bar{P})^2}$

R^2



Ind. corr $\rightarrow$ Associação entre duas variáveis

$n = \pm \sqrt{R^2} \Rightarrow R^2 = n'^2$

coeficiente linear de Pearson

7)

$$R^2 = \frac{\left[\sum_{i=1}^n G_i P_i - \sum_{i=1}^n G_i \sum_{i=1}^n P_i \right]^2}{\left[n \sum_{i=1}^n G_i^2 - \left(\sum_{i=1}^n G_i \right)^2 \right] \left[n \sum_{i=1}^n P_i^2 - \left(\sum_{i=1}^n P_i \right)^2 \right]}$$

outra forma

$$G \rightarrow P$$

Assumindo que $\hat{\alpha}$ e $\hat{\beta}$ são os melhores estimadores p/ α e β
 eficiente
 consistente
 menor variância

Podemos testar, por exemplo, se $\hat{\beta} = 0$
 $\hat{\alpha} = 0$

H_0 :
 P/ tanto tempo q. conhecer sua distribuição
 $\Rightarrow$ Vamos assumir que:

$$\hat{\alpha} \sim N\left(\alpha; \frac{\sigma_e^2 \sum G_i^2}{n \sum (G_i - \bar{G})^2}\right) \rightarrow \text{Var}(\hat{\alpha})$$

$E(\hat{\alpha}) = \alpha$

$$\hat{\beta} \sim N\left(\beta; \frac{\sigma_e^2}{\sum (G_i - \bar{G})^2}\right) \rightarrow \text{Var}(\hat{\beta})$$

$E(\hat{\beta}) = \beta$

Podemos fazer:

$$\frac{\hat{\alpha} - \alpha}{\sigma_e} \sqrt{\frac{n \sum (G_i - \bar{G})^2}{\sum G_i^2}} \sim N(0, 1)$$

$$\frac{\hat{\beta} - \beta}{\sigma_e} \sqrt{\sum (G_i - \bar{G})^2} \sim N(0, 1)$$

Substituindo σ_e por S_e (desvio padrão amostral)
 Aplicar um teste t c/ $n-2$ gl

Posso montar IC e testar hipóteses:

8) IC ρ/α :
 chame o coeficiente de confiança de $\mathbb{C}$.
 $\Rightarrow IC(\alpha, \mathbb{C}) = \hat{\alpha} \pm t_{\mathbb{C}}(n-2) Se \sqrt{\frac{\sum G_i^2}{n \sum (G_i - \bar{G})^2}}$

IC ρ/β :

$$IC(\beta, \mathbb{C}) = \hat{\beta} \pm t_{\mathbb{C}}(n-2) Se \sqrt{\frac{1}{\sum (G_i - \bar{G})^2}}$$

P/ testar hipóteses: ($\alpha=0$)

$$\underbrace{t(\hat{\alpha})}_{t \text{ calculado}} = \frac{\hat{\alpha}}{Se} \sqrt{\frac{n \sum (G_i - \bar{G})^2}{\sum (G_i^2)}}$$

P/ testar $\beta=0$

$$\underbrace{t(\hat{\beta})}_{t \text{ calculado}} = \frac{\hat{\beta}}{Se} \sqrt{\sum (G_i - \bar{G})^2}$$

mais
comum