

Ajustamento e Análise de Variância.

Seja i um vetor $(n \times 1)$ de 1's, então,

$$\sum x_i = x_1 + x_2 + \dots + x_n = i'x = n\bar{x}$$

$$i'x = \begin{bmatrix} 1 & 1 & \dots & 1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}$$

$$\bar{x} = \frac{1}{n} \sum x_i = \frac{1}{n} i'x$$

$$i\bar{x} = i \frac{1}{n} i'x = \frac{1}{n} ii'x = \begin{bmatrix} \bar{x} \\ \bar{x} \\ \vdots \\ \bar{x} \end{bmatrix}$$

$$\begin{bmatrix} x_1 - \bar{x} \\ x_2 - \bar{x} \\ \vdots \\ x_n - \bar{x} \end{bmatrix} = [x - i\bar{x}] = \left[x - \frac{1}{n} ii'x \right]$$

ou

$$\left[x - \frac{1}{n} ii'x \right] = \left[Ix - \frac{1}{n} ii'x \right] = \left[I - \frac{1}{n} ii' \right] x = M^0 x$$

que é o vetor de desvios com relação a média.

Considere agora,

$$y = Xb + e$$

Colocando todas as variáveis na forma de desvio tem-se,

$$M^0 y = M^0 Xb + M^0 e$$

uma vez que os resíduos tem média zero,

$$M^0 e = e$$

e então,

$$M^0 y = M^0 Xb + e$$

Premultiplicando por $y' = b'X' + e'$

$$y'M^0 y = (b'X' + e')(M^0 Xb + e)$$

$$y'M^0 y = b'X'M^0 Xb + b'X'e + e'M^0 Xb + e'e$$

mas, $e'M^0 X = e'X = 0$

$$\begin{aligned} [e_1 \quad \dots \quad e_n] \begin{bmatrix} X_1 - \bar{X} \\ \vdots \\ X_n - \bar{X} \end{bmatrix} &= e_1(X_1 - \bar{X}) + \dots + e_n(X_n - \bar{X}) = e_1X_1 + \dots + e_nX_n - \bar{X}(e_1 + \dots + e_n) = \\ &= e_1X_1 + \dots + e_nX_n - \frac{\sum X}{n} \cancel{\sum e}^0 = e'X = 0 \end{aligned}$$

Portanto,

$$y'M^0y = b'X'M^0Xb + e'e$$

Dividindo - se por $y'M^0y$ tem - se,

$$1 = \frac{b'X'M^0Xb}{y'M^0y} + \frac{e'e}{y'M^0y}$$

ou

$$1 - \frac{SQ_{res}}{SQ_{Total}} = \frac{SQ_{regr}}{SQ_{Total}} = R^2$$

O coeficiente de determinação R^2 é uma medida de ajuste do modelo.

Mede a proporção da variação de y que é explicada por X .

A prova de que $0 \leq R^2 \leq 1$ requer X conter uma coluna de 1's, isto é, ter constante. Senão, $M^0e \neq e$ e $e'M^0X \neq 0$.

R^2 depende do uso de MQO e se o modelo tem constante.

$R^2 = 0$ se todos os valores previstos de y forem \bar{y} , isto é, a regressão é uma linha horizontal. Neste caso, $SQ_{res} = SQ_{total}$

$R^2 = 1$ se a regressão passar exatamente pelos pontos observados. Neste caso, $SQ_{res} = 0$.

Cuidado:

Contextos diferentes, pouco pode ser dito sobre o R^2 .
séries temporais x cross-section

A variável dependente deve ser a mesma para se comparar o R^2 em dois modelos diferentes.

Ex: mesmo modelo, mas R^2 diferentes.

Renda = poupança + consumo

\Rightarrow Consumo = $a + b$ renda

Renda – Poupança = $a + b$ renda

\Rightarrow Poupança = $-a + (1-b)$ renda

O R^2 nunca diminuirá quando outra variável for adicionada à equação. Devido a isso, geralmente é apresentado o R^2 ajustado para graus de liberdade.

$$\bar{R}^2 = 1 - \frac{e'e/(n-K)}{y'M^0y/(n-1)} = 1 - \frac{(n-1)(1-R^2)}{(n-K)}$$

Voltando a igualdade,

$$y'M^0y = b'X'M^0Xb + e'e$$

ou

$$y'M^0y = b'X'M^0(y - e) + e'e$$

$$y'M^0y = b'X'M^0y - b'X'M^0e + e'e$$

Mas, $M^0e = e$ e $b'X'e = 0$, então

$$y'M^0y = b'X'M^0y + e'e$$

$$\begin{aligned}
y'M^0y &= [y_1 y_2 \dots y_n] \begin{bmatrix} y_1 - \bar{y} \\ y_2 - \bar{y} \\ \dots \\ y_n - \bar{y} \end{bmatrix} = y_1^2 - y_1\bar{y} + y_2^2 - y_2\bar{y} + \dots + y_n^2 - y_n\bar{y} \\
&= y_1^2 + y_2^2 + \dots + y_n^2 - \bar{y}(y_1 + \dots + y_n) \\
&= \sum y_i^2 - \bar{y} \sum y_i \cdot \frac{n}{n} \\
&= \sum y_i^2 - n\bar{y}^2
\end{aligned}$$

Analogamente,

$$b'X'M^0y = b'X'y - n\bar{y}^2$$

Causa de variação	g. l.	SQ	QM	F
Regressão	$K - 1$	$b'X'y - n\bar{y}^2$	$b'X'y - n\bar{y}^2 / K - 1$	QM_{regr}/QM_{res}
Resíduo	$n - K$	$e'e$	$e'e / n - K$	
Total	$n - 1$	$y'y - n\bar{y}^2$		

$SQ_{res} = \sum (y_i - \hat{y}_i)^2$ Mede a variação de y que não é explicada pela regressão

$SQ_{regr} = \sum (\hat{y}_i - \bar{y})^2$ Mede a variação de y que é explicada pela regressão

$SQ_{total} = \sum (y_i - \bar{y})^2$ Mede a variação de y em relação a média

Teste de significância da regressão.

Queremos testar a hipótese de que todos os coeficientes, exceto o termo constante, são zero.

$$F(K - 1, n - K) = \frac{R^2 / (K - 1)}{(1 - R^2) / (n - K)} = \frac{\frac{SQ_{Re gr}}{SQ_{total}} / \frac{K - 1}{n - K}}{\frac{SQ_{res}}{SQ_{total}}} = \frac{\frac{SQ_{Re gr}}{K - 1}}{\frac{SQ_{res}}{n - K}} = \frac{QM_{reg}}{QM_{res}}$$

EXEMPLO

$$y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \varepsilon$$

Y	X ₁	X ₂
-4	0	3
5	1	1
4	2	2
11	3	0

$$SQ_{total} = \sum y^2 - \frac{(\sum y)^2}{n} = 178 - \frac{16^2}{4} = 114$$

$$SQ_{total} = y'y - n\bar{y}^2 = 178 - 4 \cdot 4^2 = 114$$

$$SQ_{regr} = b'X'y - n\bar{y}^2 = \begin{bmatrix} 5,5 & 2 & -3 \end{bmatrix} \begin{bmatrix} 16 \\ 46 \\ 1 \end{bmatrix} - 64 = 113$$

$$SQ_{res} = SQ_{total} - SQ_{regr} = 114 - 113 = 1$$

	gl.	SQ	QM	F
regressão	2	113	56,5	56,5
resíduo	1	1	1	
total	3	114		

$$R^2 = \frac{SQ_{regr}}{SQ_{total}} = \frac{113}{114} = 0,99$$

Previsão:

Suponha que desejamos prever o valor y^o associado com o vetor de regressão X^o

$$y^o = X^o \beta + \varepsilon^o$$

Segue do teorema de Gauss-Markov que

$$\hat{y}^o = X^o b$$

é o estimador linear não tendencioso de variância mínima de $E(y^o)$.

O erro de previsão é:

$$e^o = \hat{y}^o - y^o = X^o b - X^o \beta - \varepsilon^o = X^o (b - \beta) - \varepsilon^o \Rightarrow E(e^o) = 0$$

$$\begin{aligned} \text{var}(e^o) &= E\left[(\hat{y}^o - y^o)(\hat{y}^o - y^o)'\right] = E\left[\left(X^o(b - \beta) - \varepsilon^o\right)\left((b - \beta)' X^{o'} - \varepsilon^{o'}\right)\right] \\ &= X^o E\left[(b - \beta)(b - \beta)'\right] X^{o'} + E\left(\varepsilon^o \varepsilon^{o'}\right) = X^o \sigma^2 (X'X)^{-1} X^{o'} + \sigma^2 \end{aligned}$$

$$X^o E[(b - \beta)\varepsilon^o'] = E[\varepsilon^o(b - \beta)'] X^{o'} = 0 \quad \text{porque não existe correlação entre } b \text{ e } \varepsilon^o$$

Intervalo de previsão:

$$\hat{y}^o - t \sqrt{s^2 \left(1 + X^o (X'X)^{-1} X^{o'} \right)} \leq y^o \leq \hat{y}^o + t \sqrt{s^2 \left(1 + X^o (X'X)^{-1} X^{o'} \right)}$$

A variância da previsão pode ser estimada utilizando-se s^2 ao invés de σ^2 .

O intervalo de confiança para y^o é

$$\hat{y}^o - t \sqrt{s^2 \left(X^o (X'X)^{-1} X^{o'} \right)} \leq y^o \leq \hat{y}^o + t \sqrt{s^2 \left(X^o (X'X)^{-1} X^{o'} \right)}$$

Comparação entre intervalo de previsão e intervalo de confiança

1) O intervalo de previsão prevê observação

$$y^o = \beta'X^o + \varepsilon^o$$

Ex: estamos interessados em prever os gastos com alimentos de uma família que recebe 2 s.m./mês.

2) O intervalo de confiança prevê média

$$E(y^0) = \beta'X^0$$

Ex: estamos interessados em prever os gastos com alimentos de todas as famílias que recebem 2 s.m./mês.

O mesmo previsor é usado em ambos os casos

$$\hat{y}^0 = E(\hat{y}^0) = b'X^0$$

Entretanto a variabilidade amostral é diferente. Para prever uma observação individual nós consideramos a variância do erro de previsão

$$\text{var}(\hat{y}^0 - y^0) = \sigma^2 \left(1 + X^{o'} (X'X)^{-1} X^o \right)$$

Enquanto a variância da média do previsor é

$$\text{var}(\hat{y}^0) = \sigma^2 \left(X^{o'} (X'X)^{-1} X^o \right)$$

Portanto,

$$\text{var}(\hat{y}^0 - y^0) = \text{var}(\hat{y}^0) + \sigma^2$$

Ao se prever uma observação individual, adiciona-se a incerteza de se prever o erro futuro \mathcal{E}^0 .

Medindo a Precisão das Previsões

Estatística U de Theil:
$$U = \sqrt{\frac{\left(\frac{1}{n^0}\right) \sum_i (y_i - \hat{y}_i^0)^2}{\left(\frac{1}{n^0}\right) \sum_i y_i^2}}$$

onde n^0 é o número de períodos sendo previsto

i é o número de previsões

Valores altos indicam má previsão

EXEMPLO

$$y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \varepsilon$$

Y	X ₁	X ₂
-4	0	3
5	1	1
4	2	2
11	3	0

Obter o valor estimado de y^0 para $X_1 = X_2 = 2,5$, e obter o intervalo de previsão a 90%.

$$\hat{y}^o - t \sqrt{s^2 \left(1 + X^o (X'X)^{-1} X^{o'} \right)} \leq y^o \leq \hat{y}^o + t \sqrt{s^2 \left(1 + X^o (X'X)^{-1} X^{o'} \right)}$$

$$\hat{y}^0 = 5,5 + 2.(2,5) - 3.(2,5) = 3$$

$$X^0 = [1 \quad 2,5 \quad 2,5] \quad X^o (X'X)^{-1} X^{o'} = 2,25$$

$$3 - 6,31 \sqrt{1.(1 + 2,25)} \leq y^0 \leq 3 + 6,31 \sqrt{1.(1 + 2,25)}$$

$$-8,38 \leq y^0 \leq 14,38$$

Restrições da demanda

1) Homogênea de grau zero

$$e_{i1} + e_{i2} + \dots + e_{in} = -e_{iY}$$

Elasticidade preço direta e cruzada = - elasticidade renda

2) Agregação de Engel

$$e_{1y}W_1 + e_{2y}W_2 + \dots + e_{ny}W_n = 1$$

↓
Proporção da despesa total gasta com o bem 1

3) Simetria

$$e_{ij} = e_{ji}$$

Elasticidades preço cruzada são iguais

Restrição na função de produção:

$$\ln Y = \gamma + \alpha \ln L + \beta \ln K + \varepsilon$$

impondo retornos constantes à escala

$$\alpha + \beta = 1$$

Regressão com Restrições

Exemplo:

$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \varepsilon$$

$$\beta_1 + \beta_2 = 1$$

A restrição é imposta ao modelo.

$$Y = \alpha + (1 - \beta_2)X_1 + \beta_2 X_2 + \beta_3 X_3 + \varepsilon$$

$$Y - X_1 = \alpha + \beta_2 (X_2 - X_1) + \beta_3 X_3 + \varepsilon$$

$$Z = \alpha + \beta_2 W + \beta_3 X_3 + \varepsilon$$

Considere o modelo

$$y = X\beta + \varepsilon$$

$$\text{onde} \quad R_{(J \times K)} \beta = q$$

O estimador de mínimos quadrados restrito é obtido da solução:

Minimizar

$$S(\beta) = (y - X\beta)'(y - X\beta) \quad \text{sujeito a} \quad R\beta = q$$

A solução Lagrangeana para este problema pode ser escrita como:

$$\begin{aligned} b_* &= \underset{\tilde{\beta}, \lambda}{\text{Min}} \quad S^*(\beta) = (y - X\beta)'(y - X\beta) + 2\lambda'(R\beta - q) \\ &= y'y - y'X\beta - \beta'X'y + \beta'X'X\beta + 2\lambda'(R\beta - q) \end{aligned}$$

As condições necessárias para a minimização são:

$$\frac{\partial S^*}{\partial \beta} = -2X'(y - Xb_*) + 2R'\lambda = 0$$

$$\frac{\partial S^*}{\partial \lambda} = 2(Rb_* - q) = 0$$

$$\text{ou} \quad -X'y + X'Xb_* + R'\lambda = 0$$

$$Rb_* = q$$

ou

$$X'Xb_* + R'\lambda = X'y$$

$$Rb_* = q$$

ou em forma de matriz,

$$\begin{bmatrix} X'X & R' \\ R & 0 \end{bmatrix} \begin{bmatrix} b_* \\ \lambda \end{bmatrix} = \begin{bmatrix} X'y \\ q \end{bmatrix}$$

Matriz Inversa Particionada

$$\begin{bmatrix} A & B \\ C & D \end{bmatrix}^{-1} = \begin{bmatrix} A^{-1}(I + BFCA^{-1}) & -A^{-1}BF \\ -FCA^{-1} & F \end{bmatrix}$$

$$F = (D - CA^{-1}B)^{-1}$$

$$\begin{bmatrix} X'X & R' \\ R & 0 \end{bmatrix}^{-1} = \begin{bmatrix} (X'X)^{-1} \left(I + R'(0 - R(X'X)^{-1}R')^{-1} R(X'X)^{-1} \right) & -(X'X)^{-1} R'(0 - R(X'X)^{-1}R')^{-1} \\ & \end{bmatrix}$$

Para obter b_* multiplica-se a 1ª linha da matriz inversa pelo vetor $\begin{bmatrix} X'y \\ q \end{bmatrix}$

$$(X'X)^{-1} \left(I + R'(0 - R(X'X)^{-1} R')^{-1} R(X'X)^{-1} \right) - (X'X)^{-1} R'(0 - R(X'X)^{-1} R')^{-1} \begin{bmatrix} X'y \\ q \end{bmatrix}$$

$$b_* = (X'X)^{-1} X'y - (X'X)^{-1} R' \left(R(X'X)^{-1} R' \right)^{-1} R(X'X)^{-1} X'y + (X'X)^{-1} R' \left(R(X'X)^{-1} R' \right)^{-1} q$$

$$b_* = b - (X'X)^{-1} R' \left(R(X'X)^{-1} R' \right)^{-1} (Rb - q)$$

No exemplo:

$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \varepsilon$$

$$\beta_1 + \beta_2 = 1$$

para obter b_* utiliza-se a fórmula acima e $R = \begin{bmatrix} 0 & 1 & 1 & 0 \end{bmatrix}$ e $q = 1$

$$b_* = b - (X'X)^{-1} R' \left(R(X'X)^{-1} R' \right)^{-1} (Rb - q)$$

$$e_* = y - Xb_* + Xb - Xb$$

$$e_* = y - Xb - X(b_* - b) = e - X(b_* - b)$$

$$e'_* e_* = (e - X(b_* - b))' (e - X(b_* - b))$$

$$e'_* e_* = e'e - e'X(b_* - b) - (b_* - b)' X'e + (b_* - b)' X'X(b_* - b)$$

$$e'_* e_* - e'e = (Rb - q)' \left(R(X'X)^{-1} R' \right)^{-1} R(X'X)^{-1} X'X(X'X)^{-1} R' \left(R(X'X)^{-1} R' \right)^{-1} (Rb - q)$$

$$e'_* e_* - e'e = (Rb - q)' \left(R(X'X)^{-1} R' \right)^{-1} (Rb - q)$$

$$F(J/n - K) = \frac{e'_* e_* - e'e / J}{e'e / (n - K)}$$

Nós vimos que:

$$F = (Rb - q)' \left[s^2 R(X'X)^{-1} R' \right]^{-1} (Rb - q) / J = \frac{(Rb - q)' \left[R(X'X)^{-1} R' \right]^{-1} (Rb - q) / J}{e'e / n - K}$$

O R^2 aumenta ao se aumentar o número de variáveis, portanto o R^2 do modelo restrito é menor que o R^2 do modelo não restrito.

Vimos que,

$$e'_*e_* = e'e - (b_* - b)' X'e - e'X(b_* - b) + (b_* - b)' X'X(b_* - b)$$

$$e'_*e_* = e'e + (b_* - b)' X'X(b_* - b) \geq e'e$$

Como
$$R^2 = 1 - \frac{e'e}{SQ_{total}}$$

$$R_*^2 < R^2$$

 Modelo restrito (menor número de variáveis)

Na tabela de análise de variância o teste F é obtido da seguinte forma:

Causa de variação	g. l.	SQ	QM	F
Regressão	$K - 1$	$b'X'y - n\bar{y}^2$	$b'X'y - n\bar{y}^2 / K - 1$	QM_{regr}/QM_{res}
Resíduo	$n - K$	$e'e$	$e'e / n - K$	
Total	$n - 1$	$y'y - n\bar{y}^2$		

A hipótese testada é a de que todos os coeficientes do modelo de regressão, exceto a constante, são zero:

$$H_0 : \beta_2 = \beta_3 = \dots = \beta_K = 0$$

Neste caso temos:

$$\begin{aligned}
 F &= \frac{SQ_{regr} / g.l.regr}{SQ_{res} / g.l.res} = \frac{SQ_{total} - SQ_{res} / J}{SQ_{res} / n - K} \\
 &= \frac{SQ_{res.restrito} - SQ_{res} / K - 1}{SQ_{res} / n - K} = \frac{(e'_*e_* - e'e) / J}{e'e / n - K}
 \end{aligned}$$

Se a hipótese sendo testada for imposta ao modelo teríamos:

$$y = \beta_1 + \varepsilon$$

Neste caso é fácil mostrar que,

$$\hat{\beta}_1 = \frac{\sum y_i}{n} = \bar{y}$$

e, então, a SQ_{total} coincide com a $SQ_{res.restrito}$.

Derivação de Matrizes

$$y = \beta_1 + \beta_2 x + \varepsilon$$

Considere 2 parâmetros e 4 observações :

$$b'x'y = [b_1 \quad b_2] \begin{bmatrix} 1 & 1 & 1 & 1 \\ x_1 & x_2 & x_3 & x_4 \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ y_4 \end{bmatrix} = [b_1 \quad b_2] \begin{bmatrix} \Sigma y \\ \Sigma xy \end{bmatrix}$$

$$A = b_1 \Sigma y + b_2 \Sigma xy$$

$$\frac{\partial A}{\partial b_1} = \Sigma y$$

$$\frac{\partial A}{\partial b_2} = \Sigma xy$$

$$\begin{bmatrix} \Sigma y \\ \Sigma xy \end{bmatrix} = x'y$$

$$R' = \begin{bmatrix} 1 & -1 \\ 0 & 1 \\ 1 & 0 \end{bmatrix}$$

$$\lambda = \begin{bmatrix} \lambda_1 \\ \lambda_2 \end{bmatrix}$$

$$J=2 \quad K=3$$

$$A = \lambda' R b \quad \longrightarrow \quad \frac{\partial A}{\partial b} = R' \lambda$$

$$A = \begin{bmatrix} \lambda_1 & \lambda_2 \end{bmatrix} \begin{bmatrix} 1 & 0 & 1 \\ -1 & 1 & 0 \end{bmatrix} \begin{bmatrix} b_1 \\ b_2 \\ b_3 \end{bmatrix}$$

$$= \begin{bmatrix} \lambda_1 - \lambda_2 & \lambda_2 & \lambda_1 \end{bmatrix} \begin{bmatrix} b_1 \\ b_2 \\ b_3 \end{bmatrix} = \lambda_1 b_1 - \lambda_2 b_1 + \lambda_2 b_2 + \lambda_1 b_3$$

$$A = \lambda_1 b_1 - \lambda_2 b_1 + \lambda_2 b_2 + \lambda_1 b_3$$

$$\frac{\partial A}{\partial b_1} = \lambda_1 - \lambda_2$$

$$\frac{\partial A}{\partial b_2} = \lambda_2$$

$$\frac{\partial A}{\partial b_3} = \lambda_1$$

$$\frac{\partial A}{\partial b} = \begin{bmatrix} \lambda_1 - \lambda_2 \\ \lambda_2 \\ \lambda_1 \end{bmatrix} = R' \lambda$$
