

Revisão de Regressão Múltipla

Prof. Alexandre Gori Maia

Universidade Estadual de Campinas

Disciplina: Econometria Aplicada II

Universidade Nacional Agraria La Molina

Ementa

Regressão Linear – Definição e Interpretação

Método de Mínimos Quadrados Ordinários

Análise de Variabilidade


Teste de Hipóteses para os Coeficientes

Bibliografia

Maia, A. G. 2014. Econometria: conceitos e aplicações. Insittuto de Economica. Caps. 1 a 8.

Função de Regressão Populacional

Seja a relação entre Y e X na população:



$$Y_i = \alpha + \beta X_i + e_i$$

Modelo de
Regressão Linear
Simples para Y na
população

ou

$$E(Y/X_i) = \alpha + \beta X_i$$

Onde:

Y é a variável dependente ou regressando
 X é a variável independente ou regressor
 α é o intercepto ou constante do modelo
 β é o coeficiente angular do modelo

Erro de previsão:

Seja X_i a i -ésima observação de X , teremos:


Y_i é o valor observado em Y para a i -ésima observação da amostra

$E(Y/X_i)$ é a esperança condicional de Y para o i -ésimo valor de X

e_i é o erro, ou variação de Y_i não explicada pelo modelo

Função de Regressão Amostral

A relação entre Y e X estimada na amostra será dada por:



Função de regressão amostral:

$$Y_i = \hat{\alpha} + \hat{\beta}X_i + \hat{e}_i$$

Y previsto pelo ajuste:

$$\hat{Y}_i = \hat{\alpha} + \hat{\beta}X_i$$

Resíduo, valor não previsto pelo ajuste:

$$\hat{e}_i = Y_i - \hat{Y}_i$$

Função de Erro Quadrático Total (EQT):

$$EQT = \hat{e}_1^2 + \hat{e}_2^2 + \dots + \hat{e}_n^2$$


$$EQT = (Y_1 - \hat{Y}_1)^2 + (Y_2 - \hat{Y}_2)^2 + \dots + (Y_n - \hat{Y}_n)^2$$

$$EQT = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n [Y_i - (\hat{\alpha} + \hat{\beta}X_i)]^2$$

Interpretação dos Coeficientes

Regressão Linear Simples:

$$Y_i = \alpha + \beta X_i + e_i$$



Temos que:


$E[Y / X = 0] = \alpha$ Valor esperado de Y quando X é nulo.

$$\frac{dY}{dX} = \beta$$

Varição marginal esperada em Y para cada variação unitária em X.

Regressão Linear Múltipla:

$$Y_i = \alpha + \beta_1 X_{1_i} + \beta_2 X_{2_i} + e_i$$



Temos que:

$E[Y / X_1 = 0, X_2 = 0] = \alpha$ Valor esperado de Y quando ambos X_1 e X_2 são nulos.

$$\frac{\partial Y}{\partial X_1} = \beta_1$$

Varição marginal esperada em Y para cada variação unitária em X_1 , mantendo X_2 constante.

$$\frac{\partial Y}{\partial X_2} = \beta_2$$


Varição marginal esperada em Y para cada variação unitária em X_2 , mantendo X_1 constante.

Regressão Múltipla - Definição

Seja a função de regressão: $Y_i = \alpha + \beta_1 X_{1_i} + \beta_2 X_{2_i} + \dots + \beta_k X_{k_i} + e_i$

Pressupomos que a variável dependente Y será determinada por k variáveis independentes X mais um erro aleatório e .

O modelo de regressão estabelece a relação esperada na população (**FRP - função de regressão populacional**). Como usualmente estimamos a relação com base em dados da amostra, trabalhamos com a **função de regressão amostral (FRA)**.



$$Y_i = \alpha + \beta_1 X_{1_i} + \beta_2 X_{2_i} + e_i \quad (\text{FRP})$$


$$Y_i = \hat{\alpha} + \hat{\beta}_1 X_{1_i} + \hat{\beta}_2 X_{2_i} + \hat{e}_i \quad (\text{FRA})$$

Os parâmetros α e β estabelecem a relação esperada na população e os estimadores $\hat{\alpha}$ e $\hat{\beta}$ estimam valores com base em observações de uma amostra. Analogamente, e representa os **erros** na população e \hat{e} os **resíduos** estimados com base nos valores da amostra.

Regressão Múltipla - Interpretação

- Em um modelo de regressão linear, os coeficientes angulares β 's captam o **efeito parcial** de uma variável independente sobre a variável dependente. Em outras palavras, qual seria a variação marginal em Y para uma variação unitária (pressupostamente marginal) em X_j , mantendo-se constante as demais variáveis independentes;

Seja a função: $Y_i = \alpha + \beta_1 X_1 + \beta_2 X_2 + e_i$



$$E[Y / X_1 = 0, X_2 = 0] = \alpha$$

$$\frac{\partial Y}{\partial X_1} = \beta_1$$

$$\frac{\partial Y}{\partial X_2} = \beta_2$$

MQO – Notação Matricial

- Obtém os estimadores da função de regressão de tal forma que os erros sejam mínimos ;

Seja a função: $Y_i = \alpha + \beta_1 X_{1_i} + \beta_2 X_{2_i} + \dots + \beta_k X_{k_i} + e_i$

E a equivalente matricial: $\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{e}$


Que representa o sistema:

$$\underbrace{\begin{pmatrix} Y_1 \\ Y_2 \\ \dots \\ Y_n \end{pmatrix}}_{\mathbf{y}_{n \times 1}} = \underbrace{\begin{pmatrix} 1 & X_{1_1} & X_{2_1} & \dots & X_{k_1} \\ 1 & X_{1_2} & X_{2_2} & \dots & X_{k_2} \\ \dots & \dots & \dots & \dots & \dots \\ 1 & X_{1_n} & X_{2_n} & \dots & X_{k_n} \end{pmatrix}}_{\mathbf{X}_{n \times p}} \underbrace{\begin{pmatrix} \alpha \\ \beta_1 \\ \dots \\ \beta_k \end{pmatrix}}_{\boldsymbol{\beta}_{p \times 1}} + \underbrace{\begin{pmatrix} e_1 \\ e_2 \\ \dots \\ e_n \end{pmatrix}}_{\mathbf{e}_{n \times 1}}$$

Minimizando, chegaremos a: $\frac{\partial EQT}{\partial \hat{\boldsymbol{\beta}}} = 0 \Rightarrow \hat{\boldsymbol{\beta}} = (\mathbf{X}^T \mathbf{X})^{-1} (\mathbf{X}^T \mathbf{y})$

Análise de Variabilidade

- A variabilidade total de Y representa a diversidade de valores que Y pode assumir;
- Uma parcela da variabilidade de Y pode ser explicada isoladamente pela variável independente X_1 , outra explicada isoladamente por X_2 e outra explicada conjuntamente por X_1 e X_2 ;
- A variabilidade não explicada por X será refletida nos erros do modelo de regressão;







Soma dos Quadrados

- Permitem estimar a qualidade do ajuste;
- Bons modelos implicam variabilidade relativamente baixa dos resíduos (*SQRes*) e variabilidade relativamente alta do ajuste de regressão (*SQReg*);

$$STQ = \sum_{i=1}^n (Y_i - \bar{Y})^2 = \mathbf{y}^T \mathbf{y} - n\bar{Y}^2$$

$$SQReg = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 = \hat{\boldsymbol{\beta}}^T \mathbf{X}^T \mathbf{y} - n\bar{Y}^2$$


$$SQRes = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \mathbf{y}^T \mathbf{y} - \hat{\boldsymbol{\beta}}^T \mathbf{X}^T \mathbf{y}$$




Coeficiente de Determinação

- Estima a proporção da variabilidade da variável dependente Y que é explicada pelo conjunto das k variáveis independentes do modelo de regressão X .

$$R^2 = \frac{SQ\text{ Reg}}{STQ} = 1 - \frac{SQ\text{ Res}}{STQ}$$



Escala de R^2 :



0

Independência
linear

A relevância do R^2 depende muito do tipo de
variável dependente (Y) sendo analisada


1

Relação
linear exata

Distribuição Amostral

- Os valores estimados em uma amostra podem diferir daqueles existentes na população;
- Ademais, os valores irão variar em função da combinação de observações selecionadas na amostra;

Supor população com 10 elementos (★)



$\beta_0 + \beta_1 X$
Reta da população

$\hat{\beta}_0 + \hat{\beta}_1 X$
Reta ajustada para a amostra 1

Amostra de 5 elementos (★)



$\hat{\beta}_0 + \hat{\beta}_1 X$
Reta ajustada para a amostra 2

Outra amostra (★)


Teste F

- Estima o nível de significância do ajuste, ou seja, qual a probabilidade de erro (p) se afirmarmos que o modelo contribui para explicar a variabilidade da variável dependente (rejeitar H_0).

Dado o modelo: $Y = \alpha + \beta_1 X_1 + \dots + \beta_k X_k + e$

E as hipóteses: $\begin{cases} H_0 : \beta_1 = \dots = \beta_k = 0 \\ H_1 : \text{Pelo menos um } \beta_k \neq 0 \end{cases}$

$$F = \frac{SQ\text{Res}/k}{SQ\text{Res}/[n-(k+1)]}$$







| Rejeitar H_0 | Rejeitar H_0 | Rejeitar H_0 | Não Rejeitar H_0 |
|---|--|---|--|
|  |  |  |  |
| $\beta_1 \neq 0$ $\beta_2 \neq 0$ | $\beta_1 = 0$ $\beta_2 \neq 0$ | $\beta_1 \neq 0$ $\beta_2 = 0$ | $\beta_1 = 0$ $\beta_2 = 0$ |
| X_1 e X_2 contribuem para explicar Y . H_0 deveria ser rejeitado | Apenas X_2 contribui para explicar Y . H_0 deveria ser rejeitado | Apenas X_1 contribui para explicar Y . H_0 deveria ser rejeitado | Nenhuma variável contribui para explicar Y . H_0 não deveria ser rejeitado |

Tabela Anova - Definição

- Resume os resultados da Análise de Variância do modelo.
- Valores de p pequenos (usualmente menores que 5%) indicam que o modelo contribui significativamente para explicar a variabilidade da variável dependente ($R^2 > 0$);

| Fonte | gl | SQ | QM | F | p |
|-----------|---------------|--|------------------------------------|-------------------------------------|-----------|
| Regressão | k | $\hat{\boldsymbol{\beta}}^T \mathbf{X}^T \mathbf{y} - n\bar{Y}^2$ | $\frac{\text{SQReg}}{k}$ | $\frac{\text{QMReg}}{\text{QMRes}}$ | valor p |
| Resíduos | $n - (k + 1)$ | $\mathbf{y}^T \mathbf{y} - \hat{\boldsymbol{\beta}}^T \mathbf{X}^T \mathbf{y}$ | $\frac{\text{SQRes}}{n - (k + 1)}$ | | |
| Total | $n - 1$ | $\mathbf{y}^T \mathbf{y} - n\bar{Y}^2$ | | | |


Teste t

- Estima a significância de cada coeficiente do modelo, ou seja, qual a probabilidade de erro (p) se afirmarmos que a j -ésima variável independente contribui isoladamente para explicar a variabilidade da variável dependente (rejeitar H_0).

Dado o modelo: $Y = \alpha + \beta_1 X_1 + \dots + \beta_k X_k + e$

E as hipóteses: $\begin{cases} H_0: \beta_j = 0 \\ H_1: \beta_j \neq 0 \end{cases}$

$$t = \hat{\beta}_j / S_{\hat{\beta}_j}$$




Onde:

$$S_{\hat{\beta}}^2 = (\mathbf{X}^T \mathbf{X})^{-1} \hat{\sigma}^2$$

e:

$$\hat{\sigma}^2 = \frac{\mathbf{y}^T \mathbf{y} - \hat{\beta}^T \mathbf{X}^T \mathbf{y}}{n - (k + 1)}$$


Rejeitar $\beta_1=0$ e $\beta_2=0$



$\beta_1 \neq 0$ $\beta_2 \neq 0$

X_1 e X_2 contribuem para explicar Y . Os dois testes t deveriam ser rejeitados


Rejeitar apenas $\beta_2=0$



$\beta_1 = 0$ $\beta_2 \neq 0$

Apenas X_2 contribui para explicar Y . $H_0: \beta_2=0$ deveria ser rejeitado


Rejeitar apenas $\beta_1=0$



$\beta_1 \neq 0$ $\beta_2 = 0$

Apenas X_1 contribui para explicar Y . $H_0: \beta_1=0$ deveria ser rejeitado

Não Rejeitar $\beta_1=0$ e $\beta_2=0$



$\beta_1 = 0$ $\beta_2 = 0$

Nenhuma variável contribui para explicar Y . Nenhum dos testes t deveria ser rejeitado.

Exercícios

- 1) O arquivo Data_TravelCosts.xls contém informações sobre o custos médios de deslocamentos de municípios a um parque nacional ([MAIA, A. G., ROMEIRO, A. . Validade e confiabilidade do método de custo de viagem: um estudo aplicado ao Parque Nacional da Serra Geral. Revista de Economia Aplicada, v. 12, p. 103-123, 2008](#)):
 - a) Analise a relação entre o custo de viagem (variável independente) e a taxa de visitação (variável dependente);
 - b) Incorpore variáveis de controle;
 - c) Os resultados são consistentes com a teórica microeconômica?