

AULA 8 - MQO em regressão múltipla: Definição, Estimação e Propriedades Algébricas

Econometria I

Área quantitativa - IE/UFRJ

Regressão Múltipla: Definição e Derivação

- ▶ A partir de agora vamos alterar o nosso modelo populacional de modo a incorporarmos mais variáveis explicativas em nossa análise.
- ▶ Seja, portanto, o modelo:

$$y = \alpha + \beta_1 x_1 + \beta_2 x_2 + u \Rightarrow \text{linear nos parâmetros}$$

onde $\alpha + \beta_1 x_1 + \beta_2 x_2$ é termo determinístico, u é termo estocástico independente de X , com $E[u|x_1, x_2] = 0$.

- ▶ Ou seja, u não é correlacionado com x_1 e x_2 por hipótese (supondo que o modelo populacional é assim).
- ▶ Vamos começar por: interpretação, estimação e propriedades algébricas do MQO múltiplo.

Regressão Múltipla: Definição e Derivação

- ▶ Interpretação, preliminares: efeitos de x_1 ou x_2 sobre y

$$\frac{\partial y}{\partial x_1} = \beta_1$$

$$\frac{\partial y}{\partial x_2} = \beta_2$$

- ▶ Notem que aqui devemos nos lembrar da interpretação da derivada parcial: o efeito de Δx_1 sobre y é β_1 , ceteris paribus (tudo o mais constante, incluindo x_2)

Estimação por MQO

- ▶ Vamos continuar com o modelo populacional

$$y = \alpha + \beta_1 x_1 + \beta_2 x_2 + u$$

com $E[u|x_1, x_2] = 0$. Suponha que temos uma amostra aleatória em mãos $\{(y_i, x_{i1}, x_{i2}), i = 1, \dots, n\}$.

- ▶ Como estimar os parâmetros α , β_1 e β_2 ?
- ▶ Os métodos que aprendemos para regressão simples podem ser aplicados aqui também.
- ▶ Vejamos o MQO: vamos escolher $\hat{\alpha}$, $\hat{\beta}_1$ e $\hat{\beta}_2$ que minimizem a soma dos resíduos ao quadrado (logo é análogo):

$$\min_{\alpha, \beta_1, \beta_2} S(\alpha, \beta_1, \beta_2) = \sum_{i=1}^n (y_i - \alpha - \beta_1 x_{i1} - \beta_2 x_{i2})^2$$

Estimação por MQO

- ▶ Agora, no entanto, caímos em um sistema de 3 equações e 3 incógnitas:

$$\frac{\partial S(\alpha, \beta_1, \beta_2)}{\partial \alpha} = 0$$

$$\frac{\partial S(\alpha, \beta_1, \beta_2)}{\partial \beta_1} = 0$$

$$\frac{\partial S(\alpha, \beta_1, \beta_2)}{\partial \beta_2} = 0$$

- ▶ Podemos generalizar nosso problema para $k \geq 2$ variáveis independentes. Suponha agora que o modelo populacional é:

$$y = \alpha + \beta_1 x_1 + \dots + \beta_k x_k + u$$

onde

$$E[u|x_1, \dots, x_k] = 0$$

e temos amostra aleatória para $\{(y_i, x_{1i}, \dots, x_{ki}), i = 1, \dots, n\}$

Estimação por MQO

- ▶ Neste caso, temos k variáveis e $k + 1$ parâmetros a serem estimados por $\min_{\alpha, \beta_1, \dots, \beta_k} S(\alpha, \beta_1, \dots, \beta_k)$
- ▶ Resolvendo um sistema com $k + 1$ equações...

$$\frac{\partial S(\cdot)}{\partial \alpha} = -2 \sum (y_i - \hat{\alpha} - \hat{\beta}_1 x_{1i} - \dots - \hat{\beta}_k x_{ki})$$

$$\frac{\partial S(\cdot)}{\partial \beta_1} = -2 \sum x_{1i} (y_i - \hat{\alpha} - \hat{\beta}_1 x_{1i} - \dots - \hat{\beta}_k x_{ki})$$

⋮

$$\frac{\partial S(\cdot)}{\partial \beta_k} = -2 \sum x_{ki} (y_i - \hat{\alpha} - \hat{\beta}_1 x_{1i} - \dots - \hat{\beta}_k x_{ki})$$

- ▶ Solução do sistema:

$$\hat{\alpha}, \hat{\beta}_1, \dots, \hat{\beta}_k \Rightarrow \text{Estimadores de MQO.}$$

Estimação por MQO

► Observações importantes:

1. Para resolver sistemas lineares \Rightarrow revisão de álgebra linear.

- Veremos isso com mais detalhes quando revisitarmos a regressão múltipla com notação matricial. Por enquanto, basta a intuição - lembrando que nem sempre um sistema de equações lineares tem solução única.
- Em particular: não pode existir colinearidade perfeita entre as explicativas. No MQO simples, precisávamos de menos. Agora precisamos impor restrições sobre como essas variáveis x_1, x_2, \dots, x_k se relacionam entre si na amostra. Ainda: Na amostra, $n > k + 1$.

2. Maneiras alternativas de estimar o nosso modelo:

- Método de momentos: $E[u] = 0, E[ux_j] = 0$ p/ $j = 1, 2, \dots, k$.
- MV (supondo distribuição conhecida p/ u):

$$\max \alpha, \beta_1, \dots, \beta_k \log L(\alpha, \beta_1, \dots, \beta_k)$$

Estimação por MQO

- ▶ Terminologia análoga á regressão simples:
 - ▶ Modelo populacional: $y = \alpha + \beta_1 x_1 + \dots + \beta_k x_k + u$
 - ▶ Reta de regressão (amostral): $\hat{y} = \hat{\alpha} + \hat{\beta}_1 x_1 + \dots + \hat{\beta}_k x_k$ ou, para um dado i : $\hat{y}_i = \hat{\alpha} + \hat{\beta}_1 x_{i1} + \dots + \hat{\beta}_k x_{ik}$
 - ▶ Resíduos: $\hat{u}_i = y_i - \hat{y}_i$
 - ▶ Estimativas: $\hat{\alpha}, \hat{\beta}_1, \dots, \hat{\beta}_k$ assumem valores para dada amostra.
- ▶ Interpretação dos coeficientes: efeito independente de x_1 em y não importando que valores x_2, \dots, x_k assumam
 $\frac{\partial y}{\partial x_1} = \hat{\beta}_1 \Rightarrow$ efeito de x_1 em \hat{y} mantendo-se x_2, \dots, x_k fixos ou condicional em x_2, \dots, x_k ou controlando por x_2, \dots, x_k .

Propriedades Algébricas do MQO

- ▶ Assim como no caso simples, temos:

$$\hat{u}_i = y_i - \hat{y}_i \Rightarrow \bar{\hat{u}} = \frac{\sum y_i - \hat{y}_i}{n} = 0 \Rightarrow \bar{y}_i = \bar{\hat{y}}_i$$

- ▶ Os valores estimados de MQO e os resíduos têm algumas propriedades que são extensões imediatas do caso simples:

1. A média amostral dos resíduos é zero.
2. $Cov(x_j, u) = 0 \forall j = 1, \dots, k$. Consequentemente, a covariância amostral entre os valores estimados de MQO e os resíduos de MQO é zero.
3. O ponto $(\bar{y}, \bar{x}_1, \bar{x}_2, \dots, \bar{x}_k)$ está sob a reta de regressão MQO:
$$\bar{y} = \hat{\alpha} + \hat{\beta}_1 \bar{x}_1 + \hat{\beta}_2 \bar{x}_2 + \hat{\beta}_k \bar{x}_k$$

As duas primeiras propriedades são consequências imediatas do conjunto de equações usadas para obter as estimativas de MQO. Vimos que no sistema acima a primeira equação diz que a soma dos resíduos é zero. As equações restantes são da forma $\sum x_{ij} \hat{u}_i = 0$, implicando que cada variável independente tem cov amostral zero com \hat{u}_i .

A propriedade 3 decorre imediatamente da propriedade 1.

Propriedades Algébricas do MQO

- ▶ Grau de ajuste: assim como na regressão simples, podemos definir:

$$\underbrace{\sum_{i=1}^n (y_i - \bar{y})^2}_{\text{SQT:}} = \underbrace{\sum_{i=1}^n (\hat{u}_i - \bar{\hat{u}}_i)^2}_{\text{SQR:}} + \underbrace{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}_{\text{SQE:}}$$

var. total existente em y_i var. total resíduos var. total em \hat{y}_i (explicada pelo modelo)

- ▶ A partir da expressão acima é possível então definir:

$$R^2 = \frac{SQE}{SQT} = 1 - \frac{SQR}{SQT}, \quad R^2 \in (0, 1)$$

é interpretado como a proporção da variação amostral em y_i que é explicada pela reta de regressão de MQO.

Propriedades Algébricas do MQO

- ▶ Um fato importante sobre R^2 é que ele nunca diminui, e geralmente aumenta, quando outra variável independente é adicionada à regressão.
- ▶ Esse fato algébrico ocorre por definição, pois a soma dos resíduos quadrados nunca aumenta quando regressores adicionais são acrescentados ao modelo.
- ▶ Isso faz com que R^2 seja um instrumento fraco para decidir se uma variável ou diversas variáveis deveriam ser adicionadas ao modelo.
- ▶ O fato que deve determinar se uma variável explicativa pertence a um modelo é se a variável explicativa tem, na população um efeito parcial sobre y diferente de zero (veremos mais tarde em inferência estatística).

R^2 ajustado

- ▶ Com a inclusão de variáveis explicativas sabemos que R^2 nunca diminui.
- ▶ Para contornarmos esse problema, podemos considerar um R^2 alternativo, chamado R^2 ajustado, denotado por \bar{R}^2 .
- ▶ O termo ajustado significa ajustado pelos graus de liberdade associados à soma de quadrados:

$$\bar{R}^2 = 1 - \frac{SQR/(n - k)}{SQT/(n - 1)} = 1 - \frac{SQR(n - 1)}{SQT(n - k)}$$

em que k = número de parâmetros do modelo, incluindo o termo de intercepto.

- ▶ Sendo $R^2 = 1 - \frac{SQR}{SQT}$, então podemos escrever

$$\bar{R}^2 = 1 - (1 - R^2) \frac{(n - 1)}{(n - k)}$$