

Multicolinearidade

Econometria

Alexandre Gori Maia

Ementa:

- Definição;
- Fator Inflacionário da Variância;
- Identificação: Estatística Conflitantes e Ajuste entre Regressores;
- Medidas Paliativas;

Bibliografia Básica:

- Maia, Alexandre Gori (2017). *Econometria: conceitos e aplicações*. Cap. 10.

Multicolinearidade - Conceito

Seja o modelo definido por: $Y = \alpha + \beta_1 X_{1_i} + \beta_2 X_{2_i} + e_i$

Variabilidade de Y explicada por X_1 ($SQReg_1$)

Variabilidade de Y explicada por X_2 ($SQReg_2$)

Se X_1 e X_2 são independentes, a variabilidade de Y explicada pelo modelo de RLM divide-se em duas partes disjuntas: o efeito isolado de X_1 ($SQReg_1$) e o efeito isolado de X_2 ($SQReg_2$).

Teríamos ainda os mesmos coeficientes angulares das regressões simples:


$$Y = \alpha_1 + \beta_1 X_{1_i} + e_{1_i} \Rightarrow SQReg_1$$

$$Y = \alpha_2 + \beta_2 X_{2_i} + e_{2_i} \Rightarrow SQReg_2$$

No outro extremo, poderíamos ter uma relação linear exata entre X_1 e X_2 (perfeita colinearidade), ou seja:


$$X_{1_i} = \lambda_2 X_{2_i}$$

Nesta situação, seria impossível estimar os efeitos isolados de X_1 e X_2 sobre Y.



Multicolinearidade - Conceito

Seja o modelo definido por: $Y = \alpha + \beta_1 X_{1_i} + \beta_2 X_{2_i} + e_i$



Frequentemente observamos relação entre as variáveis independentes X_1 e X_2 e, nesses casos, o efeito sobre Y poderá ser dividido em 3 partes: i) efeito isolado de X_1 ; ii) isolado de X_2 ; e iii) efeito conjunto de X_1 e X_2 .

O problema é que quando há uma forte relação linear entre X_1 e X_2 (*multicolinearidade*) pode ficar muito difícil identificar os efeitos isolados de X_1 e X_2 sobre Y . Ou seja, a maior parcela da variabilidade de Y é explicada pelo efeito conjunto de X_1 e X_2 .

Algebricamente, essa relação de multicolinearidade seria dada por:

$$X_{1_i} = \lambda_2 X_{2_i} + v_i$$

Multicolinearidade - Definição

Colinearidade Perfeita

Duas variáveis são ditas perfeitamente colineares quando há uma relação linear exata entre essas. De maneira genérica, podemos representar a linearidade perfeita por:

$$X_{j_i} = \lambda_1 X_{1_i} + \lambda_2 X_{2_i} + \dots + \lambda_k X_{k_i}$$

Multicolinearidade

Há multicolinearidade em um modelo de regressão múltipla quando duas ou mais variáveis independentes são fortemente relacionadas linearmente entre si. Nesse caso, teríamos:

$$X_{j_i} = \lambda_1 X_{1_i} + \lambda_2 X_{2_i} + \dots + \lambda_k X_{k_i} + v_i$$

Conseqüências da Multicolinearidade

A existência de uma colinearidade exata entre duas ou mais variáveis independentes torna impossível a obtenção dos coeficientes dos parâmetros por MQO. Por sua vez, na presença de multicolinearidade os estimadores de MQO continuam sendo os MELNV. O problema é que a multicolinearidade torna muitas vezes as estimativas dos coeficientes dos parâmetros (β 's) insignificantes, já que cada um pressupõe, por definição, a variação em Y dada uma variação unitária em X , mantendo-se constantes as demais informações. Ou seja, se duas variáveis independentes são fortemente correlacionadas, será muito difícil haver variação em uma sem que haja em outra.

Fator Inflacionário da Variância

O vetor de variância e covariância dos estimadores será dada por:


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

E a variância de cada estimador β_j será dada por:

$$\text{Var}(\hat{\beta}_j) = \frac{\sigma^2}{\sum_{i=1}^n x_{ji}^2 (1 - R_j^2)} = \frac{\sigma^2}{\sum_{i=1}^n x_{ji}^2} \frac{1}{(1 - R_j^2)} = \frac{\sigma^2}{\sum_{i=1}^n x_{ji}^2} FIV_j$$

Onde R_j^2 é o coeficiente de determinação do ajuste:

$$X_{ji} = \lambda_0 + \lambda_1 X_{1i} + \dots + \lambda_{k-1} X_{ki} + v_i$$



Fator Inflacionário da Variância - FIV

Representa o quanto a variância de $\hat{\beta}_j$ está sendo inflacionada pela relação de multicolinearidade entre X_j e as demais variáveis independentes. Quando não houver relação entre as variáveis independentes ($R_j^2 = 0$) o FIV_j será igual a 1 e, à medida que aproximamos de uma relação exata ($R_j^2 = 1$), o FIV_j tenderá a infinito.

Multicolinearidade - Identificação

Alguns sinais de multicolinearidade:

Conflito entre estatísticas R^2 e F do modelo e testes t para os parâmetros β : as estatísticas R^2 e F podem indicar um modelo significativo, enquanto os testes t dos parâmetros β 's seriam insignificantes.

$$Y = \alpha + \beta_1 X_{1_i} + \beta_2 X_{2_i} + e_i \quad \Rightarrow \quad H_0 : \beta_1 = \beta_2 = 0 \quad \mathbf{X} \quad H_0 : \beta_1 = 0 \quad \mathbf{e} \quad H_0 : \beta_2 = 0$$

Ajuste linear significativo entre as variáveis independentes: uma das variáveis independentes apresentaria forte relação de linearidade com as demais.

$$X_{j_i} = \lambda_0 + \lambda_1 X_{1_i} + \dots + \lambda_{k-1} X_{k_i} + v_i \quad \Rightarrow \quad R_j^2$$

Fator Inflacionário da Variância: medida de inflacionamento da variância devido à multicolinearidade.

$$R_j^2 \quad \Rightarrow \quad FIV_j$$

Multicolinearidade - Exemplo

Sejam as informações sobre emissões de CO², PIB e população de 8 países:


CO ₂	1.5	8.7	2.8	9.4	4.4	8.4	3.2	0.9
PIB	13.2	197.0	128.6	286.4	72.6	167.8	114.4	58.0
Pop	3.2	35.5	19.1	40.4	3.1	22.3	8.4	9.0

As estimativas de MQO para o modelo linear são:

$$CO_2 = \beta_0 + \beta_1 PIB + \beta_2 Pop + e \quad \Rightarrow \quad CO_2 = 0,472 + 0,030 PIB + 0,028 Pop + \hat{e}$$

Os resultados da tabela ANOVA:

Fonte	gl	SQ	QM	F	p
Regressão	2	63.9	31.9	8.80	0.023
Resíduos	5	18.2	3.6		
Total	7	82.0			



E os testes *t* para os coeficientes:

Variável	$\hat{\beta}$	$S_{\hat{\beta}}$	<i>t</i>	<i>p</i>
Intercepto	0.472	1.328	0.356	0.737
PIB	0.030	0.025	1.226	0.275
Pop	0.028	0.150	0.183	0.862

Embora o ajuste seja significativo no conjunto (teste *F*), as contribuições marginais de cada variável são insignificantes. Resultados que sugerem a presença de multicolinearidade.

Multicolinearidade - Exemplo


Para nos certificarmos da presença de multicolinearidade, relacionamos os regressores *PIB* e *Pop*:

O ajuste de MQO forneceu os seguintes resultados para a relação entre os regressores:

$$PIB = \lambda_0 + \lambda_1 Pop + v \quad \Rightarrow \quad PIB = 29,2 + 5,7 Pop + \hat{v}$$

Os resultados da tabela ANOVA:

Fonte	gl	SQ	QM	F	p
Regression	1	46.871,2	46.871,2	47,88	0,0005
Residual	6	5.873,5	978,9		
Total	7	52.744,6			



$$R_{PIB}^2 = 0,889$$

Podemos ainda calcular o FIV por:

$$FIV = \frac{1}{(1 - R_j^2)} = \frac{1}{(1 - 0,889)} = 8,98$$

Há multicolinearidade nos regressores, o que estaria dificultando a identificação dos impactos isolados dos regressores. O FIV é 9 vezes superior ao que seria na ausência de relação entre os regressores.

Multicolinearidade - Correção

Algumas medidas paliativas na presença de multicolinearidade:

Aumentar o tamanho da amostra: aumentando o tamanho da amostra estaremos aumentando a variabilidade de X_j e, conseqüentemente, reduzindo a variância do estimador de β_j .

$$Y = \alpha + \beta_1 X_{1_i} + \beta_2 X_{2_i} + e_i \quad \Rightarrow \quad \text{Var}(\hat{\beta}_j) = \frac{\sigma^2}{\sum_{i=1}^n x_{j_i}^2} FIV_j$$

Transformar as variáveis: a multicolinearidade pode ser eliminada a partir de funções das variáveis independentes.

$$Y = \alpha + \beta_1 X_{1_i} + \beta_2 X_{2_i} + e_i \quad \Rightarrow \quad Y = \delta_0 + \delta_0 Z_i + u_i \quad \text{onde} \quad Z_i = f(X_{1_i}, X_{2_i})$$

Omitir regressor que apresentar alta colinearidade com os demais: uma solução simples, mas perigosa, é excluir uma ou mais variáveis que apresentam multicolinearidade. A exclusão de variáveis essenciais para compreensão do problema pode, entretanto, gerar **viés de omissão**.

$$Y = \alpha + \beta_1 X_{1_i} + \beta_2 X_{2_i} + e_i \quad \Rightarrow \quad Y = \alpha + \beta_1 X_{1_i} + e_i$$

Correção Multicolinearidade - Exemplo

Sejam as informações sobre emissões de CO², PIB e população de 8 países:

O ajuste de MQO nos forneceu os seguintes resultados :


$$CO2 = \beta_0 + \beta_1 PIB + \beta_2 Pop + e \quad \Rightarrow \quad CO2 = 0,472 + 0,030PIB + 0,028 Pop + \hat{e}$$

Como havia multicolinearidade e os coeficientes eram insignificantes estatisticamente, podemos propor um novo ajuste:

$$\frac{CO2}{Pop} = \delta_0 + \delta_1 \frac{PIB}{Pop} + v \quad \Rightarrow \quad \frac{CO2}{Pop} = -0,123 + 0,058 \frac{PIB}{Pop} + \hat{v}$$

Os resultados da ANOVA seriam:

<i>Fonte</i>	<i>gl</i>	<i>SQ</i>	<i>QM</i>	<i>F</i>	<i>p</i>
Regressão	1	0,96	0,96	20,1	0,004
Resíduos	6	0,29	0,05		
Total	7	1,25			



O ajuste é significativo. Como se trata de um modelo de RLS, a significância do teste t será igual à da estatística F .

Correção Multicolinearidade - Exemplo

Sejam as informações sobre emissões de CO², PIB e população de 8 países:

O ajuste de MQO nos forneceu os seguintes resultados :


$$CO2 = \beta_0 + \beta_1 PIB + \beta_2 Pop + e \quad \Rightarrow \quad CO2 = 0,472 + 0,030 PIB + 0,028 Pop + \hat{e}$$

Uma solução para eliminar a multicolinearidade seria excluir um dos regressores:

$$CO2 = \beta_0 + \beta_1 PIB + e \quad \Rightarrow \quad CO2 = 0,401 + 0,035 PIB + \hat{e}$$

Os resultados da ANOVA seriam:

<i>Fonte</i>	<i>gl</i>	<i>SQ</i>	<i>QM</i>	<i>F</i>	<i>p</i>
Regressão	1	63,77	63,77	20,93	0,004
Resíduos	6	18,28	3,05		
Total	7	82,05			



As estimativas dos dois modelos para a variável PIB diferem apenas ligeiramente. E a relação entre CO₂ e PIB passou a ser significativa. Neste caso, a omissão parece não ter ocasionado um viés de omissão muito grave.

Mas a exclusão de variáveis deve ser analisada com muita cautela!