

AULA 16 - Autocorrelação

Econometria I

Área quantitativa - IE/UFRJ

Autocorrelação

- ▶ O mais comum problema de séries de tempo é a autocorrelação ou correlação serial dos distúrbios entre os períodos.
- ▶ Os problemas de estimação e inferência são semelhantes a heterocedasticidade. Sendo os mínimos quadrados ineficientes, e a inferência é afetada negativamente.
- ▶ Apesar de serem ineficientes, são não viesados.
- ▶ A forma de como o problema será atacado pode diferenciar da heterocedasticidade, pois em muitos casos o problema de autocorrelação está associado a um problema de má especificação do modelo.

Autocorrelação

O que vamos abordar:

- ▶ Qual é a natureza da autocorrelação?
- ▶ Quais são as consequências teóricas e práticas da autocorrelação?
- ▶ Uma vez que a hipótese de não haver autocorrelação diz respeito ao distúrbios não observados u_t , como se sabe que há autocorrelação em qualquer dada situação? Faremos testes
- ▶ Observe que agora usamos o subscrito t para enfatizar que estamos lidando com dados de séries temporais.
- ▶ Como se resolve o problema da autocorrelação?

A natureza da autocorrelação


- ▶ Na configuração de séries temporais, os distúrbios são assumidos homoscedásticos, mas correlacionados entre as observações, de modo que

$$E[uu'|X] = \sigma^2\Omega$$


em que $\sigma^2\Omega$ é uma matriz positiva definida de posto total

$$\sigma^2\Omega = \sigma^2 \begin{bmatrix} 1 & \rho_1 & \cdots & \rho_{n-1} \\ \rho_1 & 1 & \cdots & \rho_{n-2} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{n-1} & \rho_{n-2} & \cdots & 1 \end{bmatrix}$$


Comportamentos típicos de auto- e não autocorrelação




(a)




(b)



(c)



(d)



(e)

A natureza da autocorrelação

Questão: por que ocorre a correlação serial?

- ▶ **Inércia.** A maioria das séries temporais econômicas possuem um comportamento inercial, tais como: PIB, índices de preços, ciclos de produção, emprego.

Quando a recuperação econômica começa, a maioria dessas séries começam a se mover para cima. Nesta subida, o valor de uma série em um ponto no tempo é maior que seu valor anterior.

A natureza da autocorrelação

Questão: por que ocorre a correlação serial?

- ▶ **Viés de Especificação: Variáveis Excluídas.** Na análise empírica o pesquisador geralmente começa com um modelo de regressão plausível que pode não ser o mais “perfeito”.

Exemplo: Seja o modelo correto

$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + \beta_4 X_{4t} + u_t$$

onde Y = quantidade de carne demandada, X_2 = preço da carne, X_3 = renda do consumidor, X_4 = preço do frango

Entretanto, estimamos: $Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + v_t$ assim
 $v_t = \beta_4 X_{4t} + u_t$

Na medida em que o preço do frango afeta o consumo de carne bovina, o erro v refletirá um padrão sistemático, criando assim (falsa) autocorrelação.

A natureza da autocorrelação

Questão: por que ocorre a correlação serial?

- ▶ **Viés de Especificação: Forma Funcional Incorreta.**

Exemplo: Seja o modelo correto

$$\text{Custo marginal}_t = \beta_1 + \beta_2 \text{produto}_t + \beta_3 \text{produto}_t^2 + u_t$$

Entretanto, estimamos:

$$\text{Custo marginal}_t = \beta_1 + \beta_2 \text{produto}_t + u_t$$

A natureza da autocorrelação

Questão: por que ocorre a correlação serial?

- ▶ **Fenômeno de teia de aranha.** A oferta de muitas commodities agrícolas reage ao preço com uma defasagem de um período de tempo porque as decisões de fornecimento levam tempo para serem implementadas. Exemplo: Seja o modelo correto $Oferta_t = \beta_1 + \beta_2 P_{t-1} + u_t$

- ▶ **Defasagem** A variável dependente é explicada por sua variável defasada.

Exemplo: $Consumo_t = \beta_1 + \beta_2 renda_t + \beta_3 Consumo_{t-1} + u_t$

A natureza da autocorrelação

Questão: por que ocorre a correlação serial?

- ▶ **Manipulação dos dados.**

Por exemplo, em regressões envolvendo dados trimestrais, esses são geralmente derivados dos dados mensais simplesmente somando e dividindo por 3. Tornando assim a série mais suave.

Outra fonte de manipulação é a interpolação ou extrapolação de dados. Por exemplo, o Censo da População é realizado a cada 10 anos em um país, sendo o último em 2000 e o anterior em 1990. Agora, se existe uma necessidade de obter dados por algum ano dentro do período 1990-2000, a prática comum é interpolar com base em algumas suposições subjetivas.

A natureza da autocorrelação

Questão: por que ocorre a correlação serial?

► **Transformação dos dados.**

Considere o modelo $Y_t = \beta_1 + \beta_2 X_t + u_t$

Se isto é verdade, então para o período anterior será verdade também $Y_{t-1} = \beta_1 + \beta_2 X_{t-1} + u_{t-1}$ que são os valores defasados de Y , X e u .

Agora de subtrairmos os dois modelos temos

$\Delta Y_t = \beta_2 \Delta X_t + \Delta u_t$ onde o operado $\Delta Y = (Y_t - Y_{t-1})$ e o mesmo para as demais

Para a modelagem empírica usamos $\Delta Y_t = \beta_2 \Delta X_t + v_t$ onde $v_t = \Delta u_t = (u_t - u_{t-1})$ Chamamos de forma na diferença, o que significa a variação da variável.

Muitas vezes temos usar a modelagem na diferença, porque as séries são não estacionárias (tendência estocástica).

MQO na presença de autocorrelação

- ▶ Como mostramos acima

$$\sigma^2 \Omega = \sigma^2 \begin{bmatrix} 1 & \rho_1 & \cdots & \rho_{n-1} \\ \rho_1 & 1 & \cdots & \rho_{n-2} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{n-1} & \rho_{n-2} & \cdots & 1 \end{bmatrix}$$

- ▶ Definimos as autocovariâncias:

$$Cov[u_t, u_{t-s}|X] = Cov[u_{t+s}, u_t|X] = \sigma^2 \Omega_{t,t-s} = \gamma_s$$

- ▶ A correlação entre u_t e u_{t-s} é a sua autocorrelação

$$Corr[u_t, u_{t-s}|X] = \frac{Cov[u_t, u_{t-s}|X]}{\sqrt{Var[u_t|X]Var[u_{t-s}|X]}} = \frac{\gamma_s}{\gamma_0} = \rho_s$$

MQO na presença de autocorrelação

- ▶ Para derivarmos a matriz var-covar quando as observações são autocorrelacionadas, mostraremos o processo AR(1) - modelos com ordem maior são construídos como um refinamento.
- ▶ O processo AR(1) é representado na forma autoregressiva como

$$u_t = \rho u_{t-1} + \epsilon_t, \quad -1 < \rho < 1$$

em que $E[\epsilon_t] = 0$, $var[\epsilon_t] = \sigma_\epsilon^2$ e $Cov[\epsilon_t, \epsilon_{t+s}] = 0$ se $s \neq 0$

- ▶ Dividindo por γ_0 a autocorrelação é definida por:

$$Corr[u_t, u_{t-1}] = \rho_1$$

MQO na presença de autocorrelação

- ▶ Voltando ao modelo de regressão simples $Y_t = \beta_1 + \beta_2 X_t + u_t$ temos que o coeficiente do estimador MQO é

$$\hat{\beta}_2 = \frac{\sum x_t y_t}{\sum x_t^2}$$

e sua variância:

$$var(\hat{\beta}_2) = \frac{\sigma^2}{\sum x_t^2}$$

para simplificar a notação dizemos que a letra em minúscula é o desvio da média.

- ▶ Agora, sob o esquema AR(1), pode-se mostrar que a variância deste estimador é:

$$var(\hat{\beta}_2)_{AR1} = \frac{\sigma^2}{\sum x_t^2} \left[1 + 2\rho \frac{\sum x_t x_{t-1}}{\sum x_t^2} + 2\rho^2 \frac{\sum x_t x_{t-2}}{\sum x_t^2} + \dots + 2\rho^{n-1} \frac{\sum x_t x_n}{\sum x_t^2} \right]$$

Testes para autocorrelação

- ▶ **Teste LM:** é o teste do multiplicador de Lagrange sendo

H_0 : não autocorrelação

H_1 : $\epsilon_t = AR(P)$ ou $\epsilon_t = MA(P)$

O teste faz a regressão por MQO dos resíduos e_t em x_t , $e_{t-1} \dots e_{t-p}$ e TR^2 o valor crítico para uma distribuição qui-quadrado com P graus de liberdade.

Rejeita H_0 se $LM > \chi_*^2[P]$

- ▶ **Teste Q** Examina as correlações entre os resíduos e os P valores defasados dos resíduos.

O teste sugerido por Ljung e Box é:

$$Q = T(T + 2) \sum_{j=1}^P \frac{r_j^2}{T-j}$$

Rejeita H_0 se $Q > \chi_*^2[P]$

Testes para autocorrelação

- ▶ **Teste Durbin-Watson:** a estatística do teste é:

$$d = \frac{\sum_{t=2}^T (e_t - e_{t-1})^2}{\sum_{t=1}^T e_t^2} = 2(1 - r) - \frac{e_1^2 + e_T^2}{\sum_{t=1}^T e_t^2}$$

em que r é a autocorrelação de primeira ordem. Se a amostra é grande o último termo pode ser negligenciado e temos

$$d \approx 2(1 - r)$$

$$H_0: \rho = 0$$

$$H_1: \rho > 0$$

A distribuição amostral de d depende dos valores das variáveis explicativas e assim o teste tem limite superior (du) e inferior (dL) para o nível de significância.

Se $d < dL$ rejeitamos a H_0 Se $d > du$ não rejeitamos a H_0 Se $dL < d < du$ o teste é inconclusivo

- ▶ Este teste é limitado pois considera somente autocorrelação de primeira ordem e é inconclusivo se está entre dL e du .
- ▶ Existe uma versão para a presença de defasagem desenvolvida por Durbin.

Estimação eficiente com Ω conhecido

- ▶ Sendo Ω conhecido, então o estimador GLS

$$\hat{\beta} = (X'\Omega^{-1}X)^{-1}(X'\Omega^{-1}y)$$

e a estimativa da variância amostral

$$Est.Var[\hat{\beta}] = \hat{\sigma}_\epsilon^2[X'\Omega^{-1}X]^{-1}$$

em que

$$\hat{\sigma}_\epsilon^2 = \frac{(y-X\hat{\beta})'\Omega^{-1}(y-X\hat{\beta})}{T}$$

pode ser computada em um passo.

Estimação eficiente com Ω conhecido

- ▶ Os dados para o modelo são transformados. No caso AR(1) temos

$$y_* = \begin{bmatrix} \sqrt{1 - \rho^2} y_1 \\ y_2 - \rho y_1 \\ y_3 - \rho y_2 \\ \vdots \\ y_T - \rho y_{T-1} \end{bmatrix}, \quad X_* = \begin{bmatrix} \sqrt{1 - \rho^2} x_1 \\ x_2 - \rho x_1 \\ x_3 - \rho x_2 \\ \vdots \\ x_T - \rho x_{T-1} \end{bmatrix}$$

- ▶ A variância dos erros transformados são:
 $Var[\epsilon_t - \rho \epsilon_{t-1}] = Var[u_t] = \sigma_u^2$
- ▶ A variância dos erro pode ser estimada usando $(1 - \rho^2) \hat{\sigma}_\epsilon^2$

Estimação quando Ω é desconhecido

- ▶ É preciso achar um estimador consistente de $\Omega(\rho)$
- ▶ O modelo AR(1) é o mais amplamente utilizado e estudado.
- ▶ Podemos usar o FGLS com um estimador natural de ρ .
- ▶ Como b é consistente, nós podemos usar r .
- ▶ O segundo passo para o FGLS pode seguir a estimativa de Prais and Winsten ou omitir a primeira observação baseado na estimativa de Cochrane e Orcutt.
- ▶ Diferentemente do modelo com heterocedasticidade, interar quando tem autocorrelação não produz o estimador por máxima verossimilhança.
- ▶ Os estimadores de máxima verossimilhança podem ser obtidos maximizando a probabilidade de logaritmo em relação a β , σ_u^2 e ρ .