

国际金融试验班 2020 年秋 · 时间序列

# 第 8 讲：AR 模型的统计推断

授课人：刘 岩

武汉大学经管学院金融系

2020 年 11 月 5 日

## 本讲内容

- ① 线性回归模型的推断
- ② AR 系数的推断

## 本节内容

- 1 线性回归模型的推断
- 2 AR 系数的推断

## 线性回归 OLS 估计的大样本理论

- 考虑多元回归模型

$$Y_t = \sum_{k=1}^K \beta_k X_{kt} + \varepsilon_t = \mathbf{X}_t^\top \boldsymbol{\beta} + \varepsilon_t, \quad t = 1, \dots, T$$

- 矩阵形式为

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

- $\boldsymbol{\beta}$  的 OLS 估计为

$$\hat{\boldsymbol{\beta}}_T = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{Y}$$

- 对  $H_0: \boldsymbol{\beta} = \boldsymbol{\beta}_0$  等类假设进行推断, 需要知道  $\hat{\boldsymbol{\beta}}_T$  的渐近分布

## OLS 估计系数的注记

- OLS 估计系数  $\hat{\beta}_T$  是样本  $\mathcal{X} = \{Y_t, X_t\}$  的一个函数，因此当  $\mathcal{X}$  作为随机变量时， $\hat{\beta}_T$  也是一个随机变量
- 但当样本  $\mathcal{X}$  给定，即样本为其实现值  $\{y_t, x_t\}$  时，相应的估计系数有确定取值，非随机，此时通常将 OLS 估计值写为  $b_T$
- $\hat{\beta}_T$  是一个随机变量，需要进一步确定其分布，而  $b_T$  是这个随机变量的实现值

## 大样本的意义

- 大样本 (large sample) 时，概率极限理论可以直接确定估计量  $\hat{\beta}_T$  的 渐近分布 (asymptotic distribution)
  - 大数定律和中心极限定理
  - 后者的实质：标准化样本均值的分布收敛到标准正态分布
- 小样本时，只有在很强的假设之下，才有可能得到  $\hat{\beta}_T$  的分布，从而实现相关统计推断
  - 如残差项  $\varepsilon_t$  是正态分布

## 线性回归 OLS 估计系数的渐近分布

- 已知系数估计量  $\hat{\beta}_T \xrightarrow{\text{a.s.}} \beta_0$ , 且

$$\begin{aligned}\mathbb{E}\hat{\beta}_T &= \beta_0 + \mathbb{E}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \boldsymbol{\varepsilon} \\ &= \beta_0 + \mathbb{E}\{\mathbb{E}[(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \boldsymbol{\varepsilon} | \mathbf{X}]\} \\ &= \beta_0 + \mathbb{E}\{(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbb{E}[\boldsymbol{\varepsilon} | \mathbf{X}]\} = \beta_0\end{aligned}$$

- 通常而言  $\sqrt{T}(\hat{\beta}_T - \beta_0)$  收敛到一个多元正态分布  
 $\Rightarrow$  中心极限定理 (central limit theorem)

## 中心极限定理 (central limit theorem, CLT)

- 考虑 iid 样本  $\{X_t\}$ , 期望为  $\mu_X$ , 方差为  $\sigma_X^2$
- 由大数定律,  $\hat{\mu}_{X,T} - \mu_X = T^{-1} \sum_t (X_t - \mu_X) \xrightarrow{\text{a.s.}} 0$
- 计算可得,  $\text{var}(\hat{\mu}_{X,T}) = \sigma_X^2/T$ , 故  $\hat{\mu}_{X,T}$  的标准化

$$\xi_T = \frac{\hat{\mu}_{X,T} - \mu_X}{\sqrt{\text{var}(\hat{\mu}_{X,T})}} = \frac{T^{-1} \sum_t (X_t - \mu_X)}{\sqrt{T}^{-1} \sigma_X} = \frac{1}{\sqrt{T}} \sum_t \frac{X_t - \mu_X}{\sigma_X}$$


方差为 1

## 定理 1 (iid 序列 CLT: 1-元情形)

假设有 iid 序列  $\{X_t\}$ , 则其标准化样本均值  $\xi_T \xrightarrow{d} N(0, 1)$ , 或等价的,  $\sqrt{T}(\hat{\mu}_{X,T} - \mu_X) \xrightarrow{d} N(0, \sigma_X^2)$



## CLT: Monte Carlo 模拟示例



## 多元情形下的中心极限定理

## 定理 2 (iid 序列 CLT: 多元情形)

假设有 iid 向量序列  $\{\mathbf{X}_t\}$ , 期望向量为  $\boldsymbol{\mu}$ , 协方差矩阵为  $\boldsymbol{\Sigma}$ , 则其样本均值向量有如下极限分布

$$\sqrt{T}(\hat{\boldsymbol{\mu}}_{X,T} - \boldsymbol{\mu}_X) \xrightarrow{d} N(0, \boldsymbol{\Sigma})$$

- 多元情形下仍然可以定义标准化样本均值: 当  $\boldsymbol{\Sigma}$  可逆时,

$$\boldsymbol{\xi}_T = \left( \frac{1}{\sqrt{T}} \boldsymbol{\Sigma}^{\frac{1}{2}} \right)^{-1} (\hat{\boldsymbol{\mu}}_{X,T} - \boldsymbol{\mu}_X)$$

## 协方差矩阵补充性质

- 协方差阵  $\Sigma_{n \times n}$  为半正定对称阵，故特征值  $\lambda_1, \dots, \lambda_n \geq 0$ ，且存在矩阵  $C$  满足  $C^{-1} = C^T$ ，使得  $\Sigma$  可对角化为

$$\Sigma = C \text{diag}(\lambda_1, \dots, \lambda_n) C^{-1}$$

其中  $\text{diag}$  表示由给定数组构造对角矩阵

- 此时有

$$\begin{bmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_n \end{bmatrix} = \begin{bmatrix} \sqrt{\lambda_1} & & \\ & \ddots & \\ & & \sqrt{\lambda_n} \end{bmatrix} \begin{bmatrix} \sqrt{\lambda_1} & & \\ & \ddots & \\ & & \sqrt{\lambda_n} \end{bmatrix}$$

- 定义  $\Sigma^{\frac{1}{2}} = C \text{diag}(\sqrt{\lambda_1}, \dots, \sqrt{\lambda_n}) C^{-1}$ ，仍为半正定对称阵，满足  $\Sigma = \Sigma^{\frac{1}{2}} \Sigma^{\frac{1}{2}}$

## 一般情况下的中心极限定理

- 上述定理 1/2 要求 iid 假设；应用中，iid 假设不一定满足
  - 仔细观察可见，iid 假设“形式”上主要用于确定样本均值的协方差矩阵；而这一步骤，主要依赖于不同期变量相关性为 0 这一事实
  - 如果只假设序列不相关，无法保证极限分布存在
- ⇒ 弱于 iid 而强于不相关的假设为：鞅差序列 (martingale difference series)
- $\Omega_t$  表示  $t$  时信息集； $\mathbb{E}[X_{t+1}|\Omega_t]$  表示对当期信息的条件期望 (conditional expectation)
  - 给定  $\{\Omega_t\}$ ， $\{X_t\}$  称为鞅差序列，若  $\mathbb{E}[X_{t+1}|\Omega_t] = 0$
  - 前述中心极限定理在鞅差序列假设下均成立！

## 线性回归 OLS 估计系数的统计推断

- 为分析  $\hat{\beta}_T$  的渐近分布, 考虑

$$\sqrt{T}(\hat{\beta}_T - \beta_0) = \left( \frac{1}{T} \sum_{t=1}^T \mathbf{X}_t \mathbf{X}_t^\top \right)^{-1} \underbrace{\sqrt{T} \frac{1}{T} \sum_{t=1}^T \mathbf{X}_t \varepsilon_t}_{\text{视作样本均值}}$$

- 注意  $\mathbb{E}[\mathbf{X}_t \varepsilon_t \cdot \varepsilon_t \mathbf{X}_t^\top] = \mathbb{E} \mathbb{E}[\varepsilon_t^2 \mathbf{X}_t \mathbf{X}_t^\top | \mathbf{X}_t] = \sigma_\varepsilon^2 \mathbb{E}[\mathbf{X}_t \mathbf{X}_t^\top] = \sigma_\varepsilon^2 \mathbf{M}$
- 在 OLS 常用假设下, 及  $\mathbf{X}_t \varepsilon_t$  鞅差序列假设下, 由 CLT 可得

$$\sqrt{T} \frac{1}{T} \sum_{t=1}^T \mathbf{X}_t \varepsilon_t \xrightarrow{d} N(\mathbf{0}, \sigma_\varepsilon^2 \mathbf{M})$$

- 再由  $T^{-1} \sum_t \mathbf{X}_t \mathbf{X}_t^\top \xrightarrow{\text{a.s.}} \mathbf{M}$  可得

$$\sqrt{T}(\hat{\beta}_T - \beta_0) \xrightarrow{d} N(\mathbf{0}, \sigma_\varepsilon^2 \mathbf{M}^{-1})$$

## 回归系数渐近分布的样本估计

- 总体分布未知，故  $\sigma_\varepsilon^2$  与  $M$  均需从样本  $\{Y, X\}$  进行估计
- $\{X_t\}$  平稳，LLN  $\Rightarrow \hat{M}_T \equiv T^{-1} \sum_t X_t X_t^\top \xrightarrow{\text{a.s.}} M$
- 由  $\hat{\beta}_T$  的一致性，可知样本残差

$$\hat{\varepsilon}_t = Y_t - X_t^\top \hat{\beta}_T$$

是  $\varepsilon_t$  的一致估计，LLN  $\Rightarrow \hat{\sigma}_{\varepsilon, T}^2 \equiv T^{-1} \sum_t \hat{\varepsilon}_t^2 \xrightarrow{\text{a.s.}} \sigma_\varepsilon^2$

- 有限样本下， $\hat{\sigma}_{\varepsilon, T}^2$  有偏差更小的无偏估计量
- 结合这两方面，可知

$$\hat{\beta}_T - \beta_0 \sim N\left(\mathbf{0}, \frac{1}{T} \hat{\sigma}_{\varepsilon, T}^2 \hat{M}_T^{-1}\right)$$

## 单系数假设检验

- $H_0: \hat{\beta}_{k,T} - \beta_{k,0} = 0 \Rightarrow$  标准  $t$ -检验

$$\xi_T = \frac{\hat{\beta}_{k,T} - \beta_{k,0}}{\sigma(\hat{\beta}_{k,T})}$$

- 其中  $\sigma(\hat{\beta}_{k,T})$  表示  $\hat{\beta}_{k,T}$  的**标准误** (standard error), 对应矩阵

$$\frac{1}{T} \hat{\sigma}_{\varepsilon,T}^2 \hat{M}_T^{-1}$$

对角线上第  $k$  个元素的平方根

- 给定  $\hat{\beta}_{k,T}$  与  $\hat{\sigma}_{\varepsilon,T}^2 \hat{M}_T^{-1}$  收敛, 则  $T$  越大, 标准误越小, 从而检验的显著性水平越高,  $p$ -值越小

## 系数检验的进一步说明

- $\xi_T$  是做为随机变量的样本  $\{Y_t, X_t\}$  的函数，因此也是**随机变量**
- 确定了 OLS 估计量  $\hat{\beta}_{k,T}$  及相应的  $\xi_T$  的分布后，即可以根据作为实现值的样本取值  $\{y_t, x_t\}$  来计算  $\hat{\beta}_{k,T}$  的实际取值  $\hat{b}_{k,T}$ ，进而计算  $t$ -统计量  $\xi_T$  的实际取值

$$\bar{\xi}_T = \frac{\hat{b}_{k,T} - \beta_{k,0}}{\sigma(\hat{\beta}_{k,T})}$$

- 回归系数  $\hat{\beta}_{k,T}$  关于原假设  $\beta_{k,0}$  检验的  $p$ -值为如下双尾概率

$$\mathbb{P}(|\xi_T| \geq |\bar{\xi}_T|)$$



## 多系数联合检验

- 考虑  $H_0: \beta_i - \beta_j = 0$ , 即第  $i$  和  $j$  个回归系数相等
  - $\Rightarrow$  只需从渐近分布中提取出  $\hat{\beta}_{i,T}, \hat{\beta}_{j,T}$  的联合分布
    - 考虑矩阵 (行向量)

$$\mathbf{R} = [\dots, 0, \underbrace{1}_{i^{\text{th}}}, 0, \dots, 0, \underbrace{-1}_{j^{\text{th}}}, 0, \dots],$$

$$\text{则 } \mathbf{R}\hat{\boldsymbol{\beta}}_T = \hat{\beta}_{i,T} - \hat{\beta}_{j,T} \sim N\left(0, \underbrace{\frac{1}{T}\hat{\sigma}_{\varepsilon,T}^2 \mathbf{R}\hat{\mathbf{M}}_T^{-1}\mathbf{R}^T}_{1 \times 1}\right)$$

## 多系数联合检验

- 一般情况，多系数线性联合假设检验，可引入线性约束矩阵 (linear restriction matrix)  $\mathbf{R}_{L \times K}$  及约束目标向量  $\mathbf{r}_{L \times 1}$ ：

$$H_0 : \mathbf{R}\boldsymbol{\beta} = \mathbf{r} \quad \Leftrightarrow \quad H_0 : \mathbf{R}\boldsymbol{\beta} - \mathbf{r} = \mathbf{0}_{L \times 1}$$

此时，检验统计（向）量  $\boldsymbol{\xi}_T = \mathbf{R}\hat{\boldsymbol{\beta}}_T - \mathbf{r}$  的渐近分布近似等于

$$N\left(\mathbf{0}, \frac{1}{T} \hat{\sigma}_{\varepsilon, T}^2 \mathbf{R} \hat{\mathbf{M}}_T^{-1} \mathbf{R}^\top\right)$$

- $L \leq K$ ，最多同时检验所有  $K$  个回归系数的取值
- 如何检验？ $\Rightarrow$  将  $\boldsymbol{\xi}_T$  变形为  $\chi^2$ -分布

$\chi^2$ -分布与正态分布的关系


- 给定  $L$  个独立标准正态 r.v.  $X_1, \dots, X_L$ , 平方和  $Y = \sum_{\ell} X_{\ell}^2$  的分布称做自由度为  $L$  的  $\chi^2$ -分布 ( $\chi^2$ -dist. with the degree of freedom of  $L$ ), 记做  $\chi^2(L)$

- PDF 如下

$$\frac{1}{2^{L/2}\Gamma(L/2)} x^{L/2-1} e^{-x/2}$$

- $\chi^2$ -分布是一种特殊的  $\Gamma$ -分布
- 取值范围为  $(0, +\infty)$
- 若  $\mathbf{X} = [X_1, \dots, X_L]^T \sim N(\mathbf{0}, \Sigma)$ , 则  $\Sigma^{-1/2}\mathbf{X} \sim N(\mathbf{0}, I_{L \times L})$ , 故

$$(\Sigma^{-1/2}\mathbf{X})^T(\Sigma^{-1/2}\mathbf{X}) = \mathbf{X}^T\Sigma^{-1}\mathbf{X} \sim \chi^2(L)$$

$\chi^2$ -分布的密度函数

## 多系数检验：Wald 检验与 F-检验

- 上述多系数联合检验，可使用如下 Wald 统计量

$$W_T \equiv \boldsymbol{\xi}_T^T \left( \frac{1}{T} \hat{\sigma}_{\varepsilon, T}^2 \mathbf{R} \hat{\mathbf{M}}_T^{-1} \mathbf{R}^T \right)^{-1} \boldsymbol{\xi}_T = \frac{T}{\hat{\sigma}_{\varepsilon, T}^2} \hat{\boldsymbol{\beta}}_T^T \mathbf{R}^T (\mathbf{R} \hat{\mathbf{M}}_T^{-1} \mathbf{R}^T)^{-1} \mathbf{R} \hat{\boldsymbol{\beta}}_T$$

服从  $\chi^2(L)$ -分布，又称为 Wald 检验

- 当  $W_T$  的样本取值  $\bar{W}_T = \frac{T}{\hat{\sigma}_{\varepsilon, T}^2} \hat{\boldsymbol{b}}_T^T \mathbf{R}^T (\mathbf{R} \hat{\mathbf{M}}_T^{-1} \mathbf{R}^T)^{-1} \mathbf{R} \hat{\boldsymbol{b}}_T$  大于  $\alpha$ -显著性临界值  $\chi_\alpha^2(L)$ ，或者该检验  $p$ -值  $\Pr(W_T \geq \bar{W}_T)$  小于显著性水平  $\alpha$  时，拒绝  $H_0: \mathbf{R}\boldsymbol{\beta} = \mathbf{r}$
- $\alpha$  通常为 1%, 5%, 10%;  $\chi_\alpha^2(L)$  为分布对应的  $\alpha$ -分位数
- F-检验：统计量为  $F_T = W_T/L$ ，分布为 F-分布  $F(L, T-K)$ 
  - 但这是一个小样本检验，需要残差项  $\varepsilon_t$  为 iid 正态分布才能得出 F-分布

## 本节内容

- ① 线性回归模型的推断
- ② AR 系数的推断

## AR 模型的 OLS 估计

- 平稳 AR( $p$ ) 模型:  $X_t = \phi_1 X_{t-1} + \cdots + \phi_p X_{t-p} + \varepsilon_t$ ,  $\{\varepsilon_t\}$  iid, 0-均值
- 给定样本  $\{X_t\}_{t=1}^T$ , AR( $p$ ) 模型的 OLS 回归矩阵形式:

$$Y = X\phi + \varepsilon$$

$$Y = \begin{bmatrix} X_{p+1} \\ \vdots \\ X_T \end{bmatrix}, \quad X = \begin{bmatrix} \mathbf{X}_{p+1}^\top \\ \vdots \\ \mathbf{X}_T^\top \end{bmatrix} = \begin{bmatrix} X_p & \cdots & X_1 \\ \vdots & \ddots & \vdots \\ X_{T-1} & \cdots & X_{T-p} \end{bmatrix}, \quad \phi = \begin{bmatrix} \phi_1 \\ \vdots \\ \phi_p \end{bmatrix}$$

- OLS 估计量:  $\hat{\phi}_T = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top Y$

## AR 模型 OLS 估计系数的渐近分布

- 一致性：平稳性  $\Rightarrow \mathbb{E}[\varepsilon_t | X_{t-1}, X_{t-2}, \dots, X_{t-p}] = 0$ , 即  $\mathbb{E}[\varepsilon_t | \mathbf{X}_t^T] = 0$ , 故  $T^{-1} \sum_t \mathbf{X}_t \varepsilon_t = \mathbf{0}$
- 渐近分布：关键在于验证  $\mathbf{X}_t^T \varepsilon_t$  是鞅差序列, 等价于各个分量  $Z_t \equiv X_{t-i} \varepsilon_t$  是鞅差序列,  $\forall i = 1, \dots, p$ 
  - 需要验证  $\mathbb{E}[Z_{t+1} | \Omega_t] = 0$ ;  $t$ -期信息集  $\Omega_t = \{X_t, X_{t-1}, \dots\} = \{\varepsilon_t, \varepsilon_{t-1}, \dots\}$
  - $\mathbb{E}[Z_{t+1} | \Omega_t] = \mathbb{E}[X_t \varepsilon_{t+1} | \Omega_t] = \mathbb{E}[X_t \varepsilon_{t+1} | X_t, \dots] = X_t \mathbb{E}[\varepsilon_{t+1} | X_t] = 0$
  - $\mathbb{E}[\varepsilon_{t+1} | X_t] = 0$  是因为  $X_t$  由  $\{\varepsilon_t, \varepsilon_{t-1}, \dots\}$  决定, 后者与  $\varepsilon_{t+1}$  相互独立, 故  $\mathbb{E}[\varepsilon_{t+1} | X_t] = \mathbb{E} \varepsilon_{t+1} = 0$
- 前面 OLS 回归统计推断的所有结论均适用!