

国际金融试验班 2018 年秋 · 时间序列

# 第 7 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

2018 年 11 月 16 日-12 月 7 日

# 本讲内容

- 1 统计推断基础
- 2 线性回归模型的推断
- 3 AR系数的推断

## 本节内容

- 1 统计推断基础
- 2 线性回归模型的推断
- 3 AR 系数的推断

## 统计推断的基本概念

- 假设样本的  $\{\mathbf{X}_t\}_{t=1}^T$  所满足的统计模型为给定的总体分布

$$M_{\theta} = \mathbb{P}(\{\mathbf{X}_t\}_{t=1}^T | \theta)$$

- 基本任务：从样本  $\{\mathbf{X}_t\}_{t=1}^T$  反推  $\theta$  未知的真实值  $\theta = \theta_0$
- 估计：从样本  $\{\mathbf{X}_t\}_{t=1}^T$  获得  $\theta_0$  的估计值  $\hat{\theta}_T$
- 推断：由样本计算得到的  $\hat{\theta}_T$  判断  $\theta$  是否为特定取值  $\theta_0$
- 误差：由于  $\hat{\theta}_T$  继承了样本的随机性，上述推断可能存在误差  $\Rightarrow$  统计推断需要控制误差

## 推断的逻辑

- 统计推断和悬疑破案有同样的问题：从已知事实（样本）推断未知真相（参数真实值）
  - 真相的可能取值：可能有无穷多中可能，但至少是两种可能
- ⇒ 即便是无穷多中可能，总可以使用二分法：把可能真相分为互不相交两组  $G, B$
- 推断的两种结论：支持  $G$ /反对  $B$  vs. 支持  $B$ /反对  $G$
  - 推断有误差 ⇒ 4 种结果：

		真相	
		$G$	$B$
推断	支持 $G$	正确	错误
	支持 $B$	错误	正确

## 统计假设与两类错误

- 将参数真实值（真相）分为互不相交的两类，等价于做两个相互排斥的假设 (hypothesis)
- 统计学的传统：将最希望被排除的假设，称为原假设 (null hypo.); 另一个假设，称为备择假设 (alternative hypo.)
  - 原假设又称为零假设，一般记做  $H_0$
  - 备择假设一般记做  $H_1$  或  $H_a$
- 假设检验 (hypo. testing): 通过检验决定是否支持假设
  - 第一类错误 (Type-I error): 在  $H_0$  成立时，支持  $H_1$
  - 第二类错误 (Type-II error): 在  $H_1$  成立时，支持  $H_0$

	$H_0$ 成立	$H_1$ 成立
支持 $H_0$		第二类错误
支持 $H_1$	第一类错误	

## 统计推断的原则：优先控制第一类错误

- 原假设是研究者最希望排除的假设
- ⇒ 优先控制住拒绝  $H_0$ 、接受  $H_1$  的可能错误
  - 如果嫌疑人真是个好人，我们希望尽可能避免将其判做坏人的情况 ⇒ 减少冤假错案
  - 现代统计学诞生于英国，优先控制第一类错误受到英国普通法 (common law) “疑罪从无”原则的影响
- 统计推断就是一个决策过程

	好人	坏人
无罪		逍遥法外 第二类错误
有罪	冤假错案 第一类错误	

统计量、显著性水平与  $p$ -值

- 如何支持/接受或反对/拒绝一个统计假设？
- 检验统计量 (test statistics): 从统计模型出发, 构造一个统计量  $\xi_T$  (r.v.) 并确定其在特定假设  $H_x$  下的分布  $\mathbb{P}(\xi_T|H_x)$
- 利用样本观测值, 计算统计量的具体取值  $\bar{\xi}_T$ ; 若在  $H_x$  下观测到  $\bar{\xi}_T$  的概率  $\mathbb{P}(\bar{\xi}_T|H_x)$  小于某个**临界值**, 则拒绝该假设
- 该**临界值**称为该检验的显著性水平 (significance level)
  - 常用取值包括 1%、5%、10%
- 观测到  $\bar{\xi}_T$  的概率  $\mathbb{P}(\bar{\xi}_T|H_x)$  本身, 称为检验假设  $H_x$  的  $p$ -值 ( $p$ -value)
  - 按惯例,  $p$ -值越低, 称“拒绝该假设的显著性越高”



均值  $t$ -检验：简单情形

- 最常见的假设检验为均值  $t$ -检验，简称  $t$ -检验 ( $t$ -test)
- 考虑两个 iid 序列  $\{X_t\}_{t=1}^T$  与  $\{Y_t\}_{t=1}^T$  分别服从总体分布  $N(\mu_X, \sigma_X^2)$ ,  $N(\mu_Y, \sigma_Y^2)$
- 简化假设： $\mu_X, \mu_Y$  未知，但  $\sigma_X, \sigma_Y$  已知
- 需要检验的原假设为  $H_0: \mu_X = \mu_Y \Leftrightarrow H_0: \mu_X - \mu_Y = 0$
- 计算可知，两个样本均值  $\hat{\mu}_X, \hat{\mu}_Y$  分别服从如下分布

$$\hat{\mu}_X \sim N\left(\mu_X, \frac{1}{T}\sigma_X^2\right), \quad \hat{\mu}_Y \sim N\left(\mu_Y, \frac{1}{T}\sigma_Y^2\right)$$

- 选取统计量为  $\xi_T = \hat{\mu}_X - \hat{\mu}_Y$ ，在  $H_0$  下  $\xi_T$  的分布为

$$\xi_T = \hat{\mu}_X - \hat{\mu}_Y = N\left(\mu_X - \mu_Y, \frac{1}{T}(\sigma_X^2 + \sigma_Y^2)\right) = N\left(0, \frac{1}{T}(\sigma_X^2 + \sigma_Y^2)\right)$$

均值  $t$ -检验：简单情形

- 带入样本  $\{X_t, Y_t\}$  具体取值，可计算统计量  $\xi_T$  的取值  $\bar{\xi}_T$
- 考虑如下概率， $\Phi$  为标准正态 cdf:

$$\begin{aligned} \mathbb{P}(|\xi_T| \geq |\bar{\xi}_T|) &= \mathbb{P}\left(\frac{|\xi_T|}{\sigma(\xi_T)} \geq \frac{|\bar{\xi}_T|}{\sigma(\xi_T)}\right) \\ &= 2\Phi\left(-\frac{|\bar{\xi}_T|}{\sigma(\xi_T)}\right) \end{aligned}$$

- 若  $|\bar{\xi}_T|$  很大，说明观察到  $\xi_T \leq -|\bar{\xi}_T|$  或  $\xi_T \geq |\bar{\xi}_T|$  概率很小
- 此时拒绝  $H_0: \mu_X = \mu_Y$  出现（第一类）错误的概率很小！
- $\frac{\bar{\xi}_T}{\sigma(\xi_T)}$  称为  $t$ -统计量 ( $t$ -statistic)

大样本  $t$ -检验与标准误

- 考虑 iid 样本  $\{X_t\}_{t=1}^T$ , 服从总体分布  $N(\mu_X, \sigma_X^2)$
- 假设此时  $\mu_X, \sigma_X^2$  均为未知, 并考虑原假设  $H_0: \mu_X = \mu_0 \equiv 0$
- 自然的想法: 检验样本均值  $\hat{\mu}_T$  是否显著不同于  $\mu_0 = 0$
- $H_0$  之下,  $\hat{\mu}_T = \frac{1}{T} \sum_t X_t$  的分布为  $N(\mu_0, \frac{1}{T} \sigma_X^2) = N(0, \frac{1}{T} \sigma_X^2)$

$$\Rightarrow \frac{\hat{\mu}_T}{\frac{1}{\sqrt{T}} \sigma_X} \sim N(0, 1) \Rightarrow \text{统计量 } \xi_T = \frac{\hat{\mu}_T}{\frac{1}{\sqrt{T}} \hat{\sigma}_{X,T}} \xrightarrow{d} N(0, 1)$$

其中,  $\hat{\sigma}_{X,T}^2 = \frac{1}{T} \sum_t (X_t - \hat{\mu}_T)^2$  为  $\sigma_X^2$  的一致估计

- $\xi_T$  为  $\hat{\mu}_T$  的标准化 (standardization), 有极限分布  $N(0, 1)$
- $\hat{\mu}_T$  的样本标准差  $\frac{1}{\sqrt{T}} \hat{\sigma}_{X,T}$  称为标准误 (standard error)

## 本节内容

- 1 统计推断基础
- 2 线性回归模型的推断
- 3 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

## 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 估计的一致性

- 估计量  $\hat{\beta}_T$  统计推断的基础是一致性:  $\hat{\beta}_T \xrightarrow{\text{a.s.}} \beta_0$
- 假设模型系数真实值为  $\beta = \beta_0$ , 则  $\beta$  的 OLS 估计可以写为

$$\begin{aligned}
 \hat{\beta}_T &= (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{Y} \\
 &= (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top (\mathbf{X} \beta_0 + \boldsymbol{\varepsilon}) \\
 &= \beta_0 + (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \boldsymbol{\varepsilon} \\
 &= \beta_0 + \left( \frac{1}{T} \mathbf{X}^\top \mathbf{X} \right)^{-1} \frac{1}{T} \mathbf{X}^\top \boldsymbol{\varepsilon} \\
 &= \beta_0 + \left( \frac{1}{T} \sum_{t=1}^T \mathbf{X}_t \mathbf{X}_t^\top \right)^{-1} \frac{1}{T} \sum_{t=1}^T \mathbf{X}_t \varepsilon_t
 \end{aligned}$$

## 线性回归 OLS 估计的一致性

- OLS 回归的一般默认假设：

- ①  $\{X_t\}$  平稳，故交叉 2-阶矩矩阵  $M_{K \times K} = \mathbb{E}X_t X_t^\top$  存在
- ② 进一步， $M$  可逆，即  $M^{-1}$  存在
- ③  $\{\varepsilon_t\}$  为 iid 序列，且给定  $X_t$  时的条件均值为 0，即  $\mathbb{E}[\varepsilon_t | X_t] = 0$ ；由此知  $\mathbb{E}X_t \varepsilon_t = \mathbf{0}_{K \times 1}$

- 在此组假设之下，应用大数定律

$$\begin{aligned} \left( \frac{1}{T} \sum_{t=1}^T X_t X_t^\top \right)^{-1} \frac{1}{T} \sum_{t=1}^T X_t \varepsilon_t &\xrightarrow{\text{a.s.}} M_{K \times K}^{-1} \mathbf{0}_{K \times 1} \\ &= \mathbf{0}_{K \times 1} \end{aligned}$$

故  $\hat{\beta}_T \xrightarrow{\text{a.s.}} \beta_0$ ，即 OLS 估计量具有一致性



## 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  $\Sigma_{n \times n}$  为非负定对称阵，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  $\Sigma^{\frac{1}{2}} = C \text{diag}(\sqrt{\lambda_1}, \dots, \sqrt{\lambda_n}) C^{-1}$ ，仍为非负定对称阵，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  $\mathbb{E}[\mathbf{X}_t \varepsilon_t \cdot \varepsilon_t \mathbf{X}_t^\top] = \sigma_\varepsilon^2 \mathbb{E}[\mathbf{X}_t \mathbf{X}_t^\top] = \sigma_\varepsilon^2 \mathbf{M}$
- 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  $\mathbf{M}$  均需从样本  $\{\mathbf{Y}, \mathbf{X}\}$  进行估计
- $\{\mathbf{X}_t\}$  平稳，LLN  $\Rightarrow \hat{\mathbf{M}}_T \equiv T^{-1} \sum_t \mathbf{X}_t \mathbf{X}_t^\top \xrightarrow{\text{a.s.}} \mathbf{M}$
- 由  $\hat{\boldsymbol{\beta}}_T$  的一致性，可知样本残差

$$\hat{\varepsilon}_t = Y_t - \mathbf{X}_t^\top \hat{\boldsymbol{\beta}}_T$$

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

- 结合这两方面，可知

$$\hat{\boldsymbol{\beta}}_T - \boldsymbol{\beta}_0 \sim N\left(\mathbf{0}, \frac{1}{T} \hat{\sigma}_{\varepsilon, T}^2 \hat{\mathbf{M}}_T^{-1}\right)$$



## 回归系数 OLS 估计：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**，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

## 回归系数 OLS 估计：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）

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

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

## 回归系数 OLS 估计：多系数联合检验

- 一般情况，多系数线性联合假设检验，可引入联合选取矩阵 (joint selection matrix)  $J_{L \times K}$ ：

$$H_0 : J\beta = \mathbf{0}_{L \times 1}$$

此时，检验统计（向）量  $\xi_T = J\hat{\beta}_T$  的渐近分布为

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

- 如何检验？ $\Rightarrow$  将  $\xi_T$  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  $\chi^2(L)$ 
  - $\chi^2$ -分布是一种特殊的  $\Gamma$ -分布
- 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

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

- 上述多系数联合检验, 可使用如下统计量

$$\zeta_T \equiv \xi_T^T \left( \frac{1}{T} \hat{\sigma}_{\varepsilon, T}^2 J \hat{M}_T^{-1} J^T \right)^{-1} \xi_T = \frac{T}{\hat{\sigma}_{\varepsilon, T}^2} \hat{\beta}_T^T J^T (J \hat{M}_T^{-1} J^T)^{-1} J \hat{\beta}_T$$

服从  $\chi^2(L)$ -分布; 当  $\zeta_T$  大于临界值时, 拒绝  $H_0: J\beta = \mathbf{0}$

## 本节内容

- 1 统计推断基础
- 2 线性回归模型的推断
- 3 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!