

国际金融试验班 2018 年秋 · 时间序列

第 6 讲：AR 模型的估计

授课人：刘 岩

武汉大学经管学院金融系

2018 年 11 月 8 日

本讲内容

- 1 AR 过程的自协方差结构
- 2 AR 过程的回归估计

本节内容

- 1 AR 过程的自协方差结构
- 2 AR 过程的回归估计

AR(1) 过程的例子

- 给定平稳 AR(1) 过程 $X_t = \phi X_{t-1} + \varepsilon_t$, $|\phi| < 1$
- 计算可知

$$\sigma_X^2(k) = \phi^k \frac{\sigma_\varepsilon^2}{1 - \phi^2}$$

- 由此, 可将高阶自协方差写为

$$\sigma_X^2(k) = \phi^k \sigma_X^2(0)$$

- 另一种写法: 首先注意到 $\mathbb{E}[\varepsilon_t X_{t-1}]$, 且

$$X_t X_{t-1} = \phi X_{t-1}^2 + \varepsilon_t X_{t-1}$$

$$\Rightarrow \mathbb{E}[X_t X_{t-1}] = \phi \mathbb{E}[X_{t-1}^2] + \mathbb{E}[\varepsilon_t X_{t-1}] \Rightarrow \sigma_X^2(1) = \phi \sigma_X^2(0)$$

$$X_t X_{t-(k+1)} = \phi X_{t-1} X_{t-(k+1)} + \varepsilon_t X_{t-(k+1)}$$

$$\Rightarrow \sigma_X^2(k+1) = \phi \sigma_X^2(k)$$

AR(2) 过程的例子

- 给定平稳 AR(2) 过程 $X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \varepsilon_t$, 特征多项式 $A(z) = 1 - \phi_1 z - \phi_2 z^2$ 的两个零点均位于单位圆之外
- 两端分别乘以 X_{t-1}, X_{t-2} 可得

$$\sigma_X^2(1) = \phi_1 \sigma_X^2(0) + \phi_2 \sigma_X^2(1)$$

$$\sigma_X^2(2) = \phi_1 \sigma_X^2(1) + \phi_2 \sigma_X^2(0)$$

- 两端乘以 X_t , 注意到 $\text{cov}(X_t, \varepsilon_t) = \sigma_\varepsilon^2$, 可得

$$\sigma_X^2(0) = \phi_1 \sigma_X^2(1) + \phi_2 \sigma_X^2(2) + \sigma_\varepsilon^2$$

Yule-Walker 方程

- 给定平稳 AR(p) 过程 $X_t = \sum_{i=1}^p \phi_i X_{t-i} + \varepsilon_t$, 特征多项式 $A(z) = 1 - \sum_{i=1}^p \phi_i z^i$ 的 p 个零点均位于单位圆之外
- 两端依次乘以 X_{t-1}, \dots, X_{t-p} , 可得

$$\begin{bmatrix} \sigma_X^2(1) \\ \vdots \\ \sigma_X^2(p) \end{bmatrix} = \begin{bmatrix} \sigma_X^2(0) & \cdots & \sigma_X^2(p-1) \\ \vdots & \ddots & \vdots \\ \sigma_X^2(p-1) & \cdots & \sigma_X^2(0) \end{bmatrix} \begin{bmatrix} \phi_1 \\ \vdots \\ \phi_p \end{bmatrix}$$

- 两端乘以 X_t 可得:

$$\sigma_X^2(0) = \sum_{i=1}^p \phi_i \sigma_X^2(i) + \sigma_\varepsilon^2$$

- 上述两组方程, 称为 Yule-Walker 方程

本节内容

- 1 AR 过程的自协方差结构
- 2 AR 过程的回归估计
 - 基础概念
 - AR(1) 过程的估计
 - AR(p) 过程的估计

统计模型：一般概念

- 统计模型：描述数据（样本）的一个联合分布，即总体分布 (population distribution)

$$\mathbb{P}(\{X_t\}|\theta)$$

- $\{X_t\}$ 对应一组观测值，即样本；上述联合分布又可理解为 数据产生过程 (data generating process, DGP)
- 其中 θ 表示这个统计模型的一组参数；即决定数据统计性质的一组参数
- 例如 AR(1) 模型 $X_t = \phi X_{t-1} + \varepsilon_t$ ，对应的参数向量为 $\theta = (\phi, \sigma_\varepsilon^2)$ ，决定了数据（样本）的一个特定联合分布

$$\mathbb{P}(\{X_t\}|\theta)$$

统计模型的估计：一般概念

- 统计学家（或一般研究者）关心的是从数据反推参数

$$\{\mathbf{X}_t\}_{t=1}^T \Rightarrow \theta$$

换言之，总体分布的参数未知，需要用数据反推

- 这个推测过程称为估计 (estimation)
- 一般来说，问题是需要找到一个函数 $f: \{\mathbf{X}_t\}_{t=1}^T \mapsto \hat{\theta}$ ，从数据出发得到参数 θ 的估计值 $\hat{\theta}$
- 这个估计值 $\hat{\theta} = f(\{\mathbf{X}_t\}_{t=1}^T)$ 需要满足一些条件，如一致性：

$$\lim_{T \rightarrow \infty} f(\{\mathbf{X}_t\}_{t=1}^T) = \theta$$

在某种概率收敛意义下成立

- 例如， $\{X_t\}$ iid 序列，均值为 μ （未知），则大数定律保证，简单的算术平均 $\hat{\mu}_T = \frac{1}{T} \sum_{t=1}^T X_t \xrightarrow{\text{a.s.}} \mu$

AR(1) 的估计：自回归系数

- 假设数据（观测值）序列 $\{X_t\}_{t=1}^T$ 满足一个 AR(1) 过程 $X_t = \phi X_{t-1} + \varepsilon_t$ ，但参数 ϕ, σ_ε 未知
 - 这个 AR(1) 过程就是 $\{X_t\}$ 的 DGP
- 问题：如何估计 ϕ 以及 σ_ε ？
- 联想 AR(1) 的 Yule-Walker 方程 $\phi = \sigma_X^2(1)/\sigma_X^2(0)$ ，可以得到一个 ϕ 的一个估计值

$$\hat{\phi} = \frac{\hat{\sigma}_X^2(1)}{\hat{\sigma}_X^2(0)}$$

其中， $\hat{\sigma}_X^2(1), \hat{\sigma}_X^2(0)$ 分别为 $\{X_t\}$ 的 1-阶样本自协方差与样本方差；后两者的一致性保证了 $\hat{\phi}$ 的一致性

AR(1) 自回归系数的 OLS 估计

- 上面的估计方法利用了 AR(1) 过程的特殊性质
- 更一般的方法，是直接进行线性回归 (linear regression):

$$X_t = \beta X_{t-1} + e_t$$

回归系数 β 可以使用一般最小二乘 (ordinary least square, OLS) 进行估计

- OLS 法：最小化残差平方和

$$\min_{\beta} \sum_{t=2}^T (X_t - \beta X_{t-1})^2$$

该最小化问题的解称为 OLS 估计量，记为 $\hat{\beta}$

AR(1) 自回归系数的 OLS 估计

- OLS 估计量的直接推导：最小化问题 1-阶条件

$$\sum_{t=2}^T X_{t-1}(X_t - \beta X_{t-1}) = 0 \Rightarrow \hat{\beta}_T = \frac{\sum_{t=2}^T X_{t-1}X_t}{\sum_{t=2}^T X_{t-1}^2}$$

- 上式中分子分母同时除以 T 可得

$$\hat{\beta}_T = \frac{\frac{1}{T} \sum_{t=2}^T X_{t-1}X_t}{\frac{1}{T} \sum_{t=2}^T X_{t-1}^2} \xrightarrow{\text{a.s.}} \frac{\sigma_X^2(1)}{\sigma_X^2(0)} = \phi$$

故 X_t 自回归方程系数的 OLS 估计值具有一致性

- 这里的 $\hat{\beta}$ 就是之前介绍的 (1-阶) 偏自相关系数

OLS 估计的矩阵形式：单一解释变量

- 单一解释变量线性回归的一般写法

$$Y_t = \beta X_t + e_t$$

其向量形式为

$$Y = X\beta + e$$

其中 $Y = [Y_1, \dots, Y_T]^T$ 为被解释变量, $X = [X_1, \dots, X_T]^T$ 解释变量, $e = [e_1, \dots, e_T]^T$ 残差项

- 最小化残差和可表示为

$$\min_{\beta} e^T e = \min_{\beta} (Y - X\beta)^T (Y - X\beta)$$

- 单一解释变量不易体现矩阵形式的优越性；多变量则不同

AR(1) 的估计：冲击项方差

- 暂时回归 σ_ε^2 的估计问题
- 利用大数律，自然的想法是利用样本方差 $\hat{\sigma}_\varepsilon^2 = \frac{1}{T} \sum_{t=1}^T \varepsilon_t^2$ 来估计 σ_ε^2 ；但唯一的观测值为 $\{X_t\}$ ，而非 $\{\varepsilon_t\}$
- 但是，若有一致估计量 $\hat{\phi}_T$ ，则大样本下

$$e_t = X_t - \hat{\phi}_T X_{t-1} \xrightarrow{\text{a.s.}} X_t - \phi X_{t-1} = \varepsilon_t$$

因此，可利用冲击项 ε_t 的样本估计值 e_t 来估计 σ_ε^2 ：

$$\hat{\sigma}_e^2 = \frac{1}{T-1} \sum_{t=2}^T e_t^2 = \frac{1}{T-1} \sum_{t=2}^T (X_t - \hat{\phi}_T X_{t-1})^2 \xrightarrow{\text{a.s.}} \sigma_\varepsilon^2$$

AR(p) 的估计：自回归系数

- 假设数据（观测值）序列 $\{X_t\}_{t=1}^T$ 满足一个 AR(p) 过程 $X_t = \sum_{i=1}^p \phi_i X_{t-i} + \varepsilon_t$ ，但参数 $\phi_1, \dots, \phi_p, \sigma_\varepsilon$ 未知
- 类似于 AR(1)，如果有 ϕ_i 的一致估计 $\hat{\phi}_i$ ，则可计算样本冲击 e_t ，从而用 $\hat{\sigma}_e^2$ （一致）估计 σ_ε^2
- 从 Yule-Walker 方程出发，可以得到

$$\begin{bmatrix} \phi_1 \\ \vdots \\ \phi_p \end{bmatrix} = \begin{bmatrix} \sigma_X^2(0) & \cdots & \sigma_X^2(p-1) \\ \vdots & \ddots & \vdots \\ \sigma_X^2(p-1) & \cdots & \sigma_X^2(0) \end{bmatrix}^{-1} \begin{bmatrix} \sigma_X^2(1) \\ \vdots \\ \sigma_X^2(p) \end{bmatrix}$$

AR(p) 自回归系数的 Yule-Walker 估计

- 给定样本 T 足够大, 则样本自协方差是对 X_t 总体自协方差的一致估计
- 在 Yule-Walker 方程中应用样本自协方差, 则可以得到 ϕ_1, \dots, ϕ_p 的一致估计

$$\begin{bmatrix} \hat{\phi}_1 \\ \vdots \\ \hat{\phi}_p \end{bmatrix} = \begin{bmatrix} \hat{\sigma}_X^2(0) & \cdots & \hat{\sigma}_X^2(p-1) \\ \vdots & \ddots & \vdots \\ \hat{\sigma}_X^2(p-1) & \cdots & \hat{\sigma}_X^2(0) \end{bmatrix}^{-1} \begin{bmatrix} \hat{\sigma}_X^2(1) \\ \vdots \\ \hat{\sigma}_X^2(p) \end{bmatrix}$$

AR(p) 自回归系数的 OLS 估计

- AR(p) 的自回归系数也可在线性回归框架下，用 OLS 方法进行估计
- 将 X_t 写为线性回归形式

$$X_t = \beta_1 X_{t-1} + \cdots + \beta_p X_{t-p} + e_t$$

- 则 OLS 估计为最小化残差平方和问题的解

$$\min_{\{\beta_i\}} \sum_{t=p+1}^T (X_t - \beta_1 X_{t-1} + \cdots + \beta_p X_{t-p})^2$$

- 若仍然用微积分求解极值问题的 1-阶最优条件来求解，会比较繁琐

OLS 估计的矩阵形式：多解释变量

- 多解释变量线性回归的一般写法

$$Y_t = \mathbf{X}_t^T \boldsymbol{\beta} + e_t, \quad t = 1, \dots, T$$

其中 $\mathbf{X}_t^T = [X_{1t}, \dots, X_{Kt}]$ 为 K 个回归变量

- 其矩阵形式为

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

其中

$$\mathbf{Y} = \begin{bmatrix} Y_1 \\ \vdots \\ Y_T \end{bmatrix}_{T \times 1}, \quad \mathbf{X} = \begin{bmatrix} \mathbf{X}_1^T \\ \vdots \\ \mathbf{X}_T^T \end{bmatrix}_{T \times K}, \quad \mathbf{e} = \begin{bmatrix} e_1 \\ \vdots \\ e_T \end{bmatrix}_{T \times 1}, \quad \boldsymbol{\beta} = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_K \end{bmatrix}_{K \times 1}$$

OLS 估计的矩阵形式：多解释变量

- OLS 估计量为最小化残差和问题的解

$$\min_{\beta} e^T e = \min_{\beta} (Y - X\beta)^T (Y - X\beta)$$

- 结论：若 $\hat{\beta}$ 满足 $X^T(Y - X\hat{\beta}) = 0$ (零向量)，则 $\hat{\beta}$ 为上述最小化问题的解；若 $X^T X$ 可逆，则 $\hat{\beta} = (X^T X)^{-1} X^T Y$
 - 只需要说明， $\forall \beta \in \mathbb{R}^K$ ，下列不等式成立即可

$$(Y - X\hat{\beta})^T (Y - X\hat{\beta}) \leq (Y - X\beta)^T (Y - X\beta)$$

- 为此，只需考虑下式的展开

$$(Y - X\beta)^T (Y - X\beta) = (Y - X\hat{\beta} + X\hat{\beta} - X\beta)^T (Y - X\hat{\beta} + X\hat{\beta} - X\beta)$$

及 $\hat{\beta}$ 所满足的性质即可

OLS 估计的几何视角

- 将 X 看做 \mathbb{R}^T 中的 K 个列向量, 则 $X\beta$ 为这 K 个向量张成的子空间 \mathcal{X} 中的一个向量
- $(Y - X\beta)^T(Y - X\beta)$ 为 Y 到 $X\beta$ 的距离
- 最小二乘估计就等价于寻找 β 使得 Y 到 \mathcal{X} 距离最短
- 这又等价于使得残差向量 $e = Y - X\beta$ 与子空间 \mathcal{X} 垂直, 即 $X^T e = 0$
- OLS 估计可看做被解释变量对解释变量的投影 (projection)

AR(p) 自回归系数 OLS 估计的一致性

- 将 AR(p) 模型写为 OLS 回归的矩阵形式

$$Y = X^T \beta + e$$

其中

$$Y = \begin{bmatrix} X_{p+1} \\ \vdots \\ X_T \end{bmatrix}_{(T-p) \times 1}, \quad X = \begin{bmatrix} X_p & \cdots & X_1 \\ \vdots & \ddots & \vdots \\ X_{T-1} & \cdots & X_{T-p} \end{bmatrix}_{(T-p) \times K}$$

AR(p) 自回归系数 OLS 估计的一致性

- AR(p) 自回归系数的 OLS 估计为

$$\begin{aligned}\hat{\beta}_T &= (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{Y} \\ &= \left(\frac{1}{T} \mathbf{X}^\top \mathbf{X} \right)^{-1} \frac{1}{T} \mathbf{X}^\top \mathbf{Y} \\ &\xrightarrow{\text{a.s.}} \begin{bmatrix} \sigma_X^2(0) & \cdots & \sigma_X^2(p-1) \\ \vdots & \ddots & \vdots \\ \sigma_X^2(p-1) & \cdots & \sigma_X^2(0) \end{bmatrix}^{-1} \begin{bmatrix} \sigma_X^2(1) \\ \vdots \\ \sigma_X^2(p) \end{bmatrix} = \begin{bmatrix} \phi_1 \\ \vdots \\ \phi_p \end{bmatrix}\end{aligned}$$

满足一致性

- 一致性的关键: $\mathbb{E}[\varepsilon_t X_{t-i}] = 0, \forall i \geq 1$