

国际金融试验班 2018 年秋 · 时间序列

第 8 讲：时间序列回归分析拓展

授课人：刘 岩

武汉大学经管学院金融系

2018 年 12 月 14 日

本讲内容

- ① 模型设定与评估
- ② 稳健标准误
- ③ 极大似然估计

本节内容

- 1 模型设定与评估
- 2 稳健标准误
- 3 极大似然估计

动态回归模型

- 单变量自回归模型:

$$X_t = \phi_1 X_{t-1} + \cdots + \phi_p X_{t-p} + \varepsilon_t, \quad t = p + 1, \dots, T$$
$$\Rightarrow X_t = \mathbf{Y}_{t-1}^\top \boldsymbol{\phi} + \varepsilon_t$$

- 添加其他解释变量 \mathbf{Z}_t :

$$X_t = \mathbf{Y}_{t-1}^\top \boldsymbol{\phi} + \mathbf{Z}_t^\top \boldsymbol{\beta} + \varepsilon_t$$

称为动态回归模型

动态回归模型

- 动态回归模型示例：货币政策的 Taylor 规则

$$i_t = \rho i_{t-1} + (1 - \rho)[\phi_\pi(\pi_t - \bar{\pi}) + \phi_y(y_t - y_t^*)] + \varepsilon_t$$

其中 $\bar{\pi}$ 为目标通胀率， $y_t - y_t^*$ 为产出缺口

- OLS 估计的注意事项
 - X_t 平稳性取决于 ϕ 和 Z_t ，后者通常需要假设为平稳序列
 - OLS 估计的一致性取决于 ε_t 与 (Y_{t-1}, Z_t) 的相关性 \Rightarrow 通常假设 $\mathbb{E}[\varepsilon_t | Y_{t-1}, Z_t] = 0$
 - OLS 估计的渐近分布：拓展鞅差序列假设为 $\mathbb{E}[Y_{t-1}\varepsilon_t | \Omega_{t-1}] = 0$, $\mathbb{E}[Z_t\varepsilon_t | \Omega_{t-1}] = 0$, 信息集为 $\Omega_t = \{Y_{t-1}, Y_{t-2}, \dots, Z_t, Z_{t-1}, \dots\}$

回归分析的命门：内生性与识别问题

- 加总消费为 C_t ，加总产出（收入）为 Y_t ，考虑两个回归

$$\log(C_t) = \alpha \log(Y_t) + \varepsilon_t, \quad \log(Y_t) = \phi \log(C_t) + \eta_t$$

其中， ε_t, η_t 表示两种不同的冲击

- 完全不同的两种解释：
 - ① α 的估计值表示边际消费倾向 (marginal propensity to consume)
 - ② ϕ 的估计值表示消费乘数 (consumption multiplier)
- 两个回归方程联立得

$$\log(C_t) = \frac{\varepsilon_t + \alpha \eta_t}{1 - \alpha \phi}, \quad \log(Y_t) = \frac{\phi \varepsilon_t + \eta_t}{1 - \alpha \phi}$$

回归分析的命门：内生性与识别问题

- α 和 ϕ 在二战后的凯恩斯主义 (Keynesian) 经济学中都是反映经济运动规律的关键变量
 - 还有投资 (储蓄) 乘数、政府支出乘数、净出口乘数等
- 问题：两个回归方程的 OLS 估计，都是不一致的！
 - 令 $c_t = \log(C_t)$, $y_t = \log(Y_t)$, 则

$$\hat{\alpha} = \alpha + \left(\frac{1}{T} \sum_t y_t^2\right)^{-1} \frac{1}{T} \sum_t y_t \varepsilon_t \xrightarrow{\text{a.s.}} \alpha + [\mathbb{E}y_t^2]^{-1} \mathbb{E}y_t \varepsilon_t$$

$$\text{但 } \mathbb{E}y_t \varepsilon_t = \frac{\phi}{1-\alpha\phi} \sigma_\varepsilon^2$$

- $\hat{\phi}$ 有同样问题
- 回归分析中的内生性 (endogeneity): 若回归变量与残差项协方差不为 0, 则称回归存在内生性问题 \Rightarrow OLS 估计结果是不一致的

回归分析的命门：内生性与识别问题

- 回归存在内生性，又称回归变量的外生性 (exogeneity) 条件不满足
- 此时，OLS 估计方法无法识别 (identify) 模型参数
 - 又称为存在参数识别问题 (identification problem)
- 更重要的影响：内生性带来的参数识别问题，妨碍有效的因果性推断 (causal inference)
 - 所得结论仅为相关性 (correlation) \neq 因果性
 - 而经济学的核心问题之一：研究 X 的变动如何引起 Y 的变动

内生性问题的 3 大来源

- ① 遗漏变量 (omitted variable): 真实模型是 $Y_t = \alpha X_t + \gamma Z_t + \varepsilon_t$, 但回归模型仅考虑 X_t ,

$$Y_t = \alpha X_t + \underbrace{u_t}_{=\gamma Z_t + \varepsilon_t}$$

- ② 倒向因果 (inverse causality): 回归模型 $Y_t = \alpha X_t + \gamma Z_t + \varepsilon_t$, 但实际上 Z_t 是由 Y_t 所决定

$$Z_t = \beta Y_t + v_t \Rightarrow \mathbb{E}Z_t \varepsilon_t \neq 0$$

- ③ 共同因素 (common/confounding factor): 前述消费-产出回归就是一个典型例子——宏观经济变量几乎都受到共同冲击 (因素) 的作用

回归模型的评估： R^2 与调整 R^2

- 给定回归方程 $Y_t = X_t^T \beta + \varepsilon_t$, 称 $\hat{Y}_t = X_t^T \hat{\beta}$ 为回归估计的拟合值 (fitted value)
- 用矩阵表示 $\hat{Y} = X\hat{\beta} = X(X^T X)^{-1} X^T Y$
- 回归残差的估计值为 $\hat{\varepsilon} = Y - \hat{Y}$, 可验证 $\varepsilon \perp \hat{Y}$, 即 $\varepsilon^T \hat{Y} = 0 \Rightarrow \{Y_t\}$ 样本变动 (方差) 可分解为

$$\sum_t Y_t^2 = Y^T Y = \hat{Y}^T \hat{Y} + \hat{\varepsilon}^T \hat{\varepsilon} = \sum_t \hat{Y}_t^2 + \sum_t \hat{\varepsilon}_t^2$$

- 定义

$$R^2 = \frac{\sum_t \hat{Y}_t^2}{\sum_t Y_t^2} = \frac{\hat{Y}^T \hat{Y}}{Y^T Y} = 1 - \frac{\hat{\varepsilon}^T \hat{\varepsilon}}{Y^T Y} \in [0, 1]$$

- R^2 可理解为回归模型对 Y_t 的解释力 (explanatory power)

回归模型的评估： R^2 与调整 R^2

- 只有一个常数回归变量即 $\mathbf{X}_t^\top = 1$ 时， $\hat{Y}_t = \mu_Y$ ，此时有 $R^2 = T\mu_Y^2 / \mathbf{Y}^\top \mathbf{Y}$
- 增加回归变量可以提高 R^2 ：定义 $\tilde{\mathbf{X}} = [\mathbf{X}, \mathbf{X}_{K+1}]$ ， $\mathbf{b} = [\boldsymbol{\beta}^\top, \beta_{K+1}]^\top$ ，考虑回归 $\mathbf{Y} = \tilde{\mathbf{X}}\mathbf{b} + \mathbf{e}$ ，则

$$\tilde{\mathbf{Y}} = \tilde{\mathbf{X}}\hat{\mathbf{b}} \Rightarrow \tilde{\mathbf{Y}}^\top \tilde{\mathbf{Y}} \geq \hat{\mathbf{Y}}^\top \hat{\mathbf{Y}} \Rightarrow R^2 \uparrow$$

- 极端情况：如果 $K = T$ ，且 \mathbf{X} 满秩，则由 $\mathbf{X}\boldsymbol{\beta} = \mathbf{Y}$ 可直接解出 $\boldsymbol{\beta} \Rightarrow \boldsymbol{\varepsilon} = \mathbf{0}$ ， $R^2 = 1$
- 克服解释变量个数对解释力的影响：定义 调整 R^2

$$\bar{R}^2 = 1 - \frac{\hat{\boldsymbol{\varepsilon}}^\top \hat{\boldsymbol{\varepsilon}} / (T - K - 1)}{\mathbf{Y}^\top \mathbf{Y} / (T - 1)} = 1 - (1 - R^2) \frac{T - 1}{T - K - 1}$$

模型选择

- 建立回归模型：首先决定选取哪些变量作为解释变量
 - 理想状态：经济、金融理论“完全决定”选取哪些解释变量
 - 实际情况：理论只能做部分决定 \Rightarrow 部分变量仍需人工决策
- 模型选择 (model selection)：根据给定的信息准则 (information criterion) 进行变量选取
 - AIC (Akaike's IC): $AIC = \log \hat{\sigma}_{\varepsilon, K}^2 + 2K/T$; 小样本效果较好
 - BIC (Bayesian IC): $BIC = \log \hat{\sigma}_{\varepsilon, K}^2 + (K \log T)/T$; 大样本效果较好
- 从备选解释变量中，选择对应 IC 最小的一组变量

本节内容

- 1 模型设定与评估
- 2 稳健标准误**
- 3 极大似然估计

残差项：同方差 v.s. 异方差

- 到目前为止，均使用同方差 (homoskedasticity) 假设：

$$\mathbb{E}[\varepsilon_t^2 | \mathbf{X}_t] = \sigma_\varepsilon^2$$

- 该假设排除了残差项波动率随时间或解释变量的改变而改变的情况
- 更一般假设：条件异方差 (conditional heteroskedasticity)

$$\mathbb{E}[\varepsilon_t^2 | \mathbf{X}_t] = \sigma_{\varepsilon,t}^2$$

中心极限定理：异方差情形

定理 1 (鞅差序列 CLT：多元、异方差情形)

假设 $\{\mathbf{X}_t\}$ 为 (向量) 鞅差序列, $\mathbb{E}[\mathbf{X}_t | \Omega_{t-1}] = \mathbf{0}$, Ω_t 为 t -时的信息集: $\mathbb{E}[\mathbf{X}_t \mathbf{X}_t^\top] = \Sigma_t$ 为 t -时协方差矩阵。若序列平均协方差矩阵收敛

$$\frac{1}{T} \sum_t \Sigma_t \rightarrow \Sigma,$$

且样本交叉矩收敛到同样矩阵

$$\frac{1}{T} \sum_t \mathbf{X}_t \mathbf{X}_t^\top \xrightarrow{\text{a.s.}} \Sigma,$$

则对应的样本均值向量有如下极限分布

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

OLS 估计的渐近分布：异方差情形

- 考察 $\hat{\beta}_T$ 的渐近分布

$$\sqrt{T}(\hat{\beta}_T - \beta_0) = \left(\frac{1}{T} \sum_{t=1}^T \mathbf{X}_t \mathbf{X}_t^\top \right)^{-1} \sqrt{T} \frac{1}{T} \sum_{t=1}^T \underbrace{\mathbf{X}_t \varepsilon_t}_{\text{鞅差序列}}$$

- 样本均值为 $\mu_{\mathbf{X}\varepsilon, T} = \frac{1}{T} \sum_t \mathbf{X}_t \varepsilon_t$ ，需要确定 $\sqrt{T} \mu_{\mathbf{X}\varepsilon, T}$ 的分布
 \Rightarrow 确定其极限协方差矩阵
- 将 OLS 估计同方差假设替换为如下 **异方差假设**：

$$\frac{1}{T} \sum_t \varepsilon_t^2 \mathbf{X}_t \mathbf{X}_t^\top \xrightarrow{\text{a.s.}} \Sigma \equiv \lim_T \frac{1}{T} \sum_t \mathbb{E}[\varepsilon_t^2 \mathbf{X}_t \mathbf{X}_t^\top]$$

- 由前页 CLT 知

$$\sqrt{T} \frac{1}{T} \sum_t \mathbf{X}_t \varepsilon_t \xrightarrow{d} N(\mathbf{0}, \Sigma)$$

OLS 估计的渐近分布：异方差情形

- 继续假设 $\frac{1}{T} \sum_t \mathbf{X}_t \mathbf{X}_t^\top = \mathbf{M}$ ，则此时

$$\sqrt{T}(\hat{\boldsymbol{\beta}}_T - \boldsymbol{\beta}_0) \xrightarrow{d} N(\mathbf{0}, \mathbf{M}^{-1} \boldsymbol{\Sigma} \mathbf{M}^{-1})$$

- 故当 T 足够大时， $\hat{\boldsymbol{\beta}}_T - \boldsymbol{\beta}_0 \sim N(\mathbf{0}, \frac{1}{T} \mathbf{M}^{-1} \boldsymbol{\Sigma} \mathbf{M}^{-1})$
- 由条件异方差假设，

$$\begin{aligned} \mathbb{E}[\varepsilon_t^2 \mathbf{X}_t \mathbf{X}_t^\top] &= \mathbb{E} \mathbb{E}[\varepsilon_t^2 \mathbf{X}_t \mathbf{X}_t^\top | \mathbf{X}_t] \\ &= \mathbb{E}[\mathbf{X}_t \mathbf{X}_t^\top \mathbb{E}(\varepsilon_t^2 | \mathbf{X}_t)] = \mathbb{E}[\sigma_{\varepsilon,t}^2 \mathbf{X}_t \mathbf{X}_t^\top] \end{aligned}$$

- 对比同方差假设： $\mathbb{E}[\varepsilon_t^2 \mathbf{X}_t \mathbf{X}_t^\top] = \sigma_\varepsilon^2 \mathbb{E}[\mathbf{X}_t \mathbf{X}_t^\top] = \sigma_\varepsilon^2 \mathbf{M}$

OLS 估计的渐近分布：异方差情形

- 给定样本 $\{Y_t, \mathbf{X}_t\}_{t=1}^T$ ，需要估计 M 与 Σ
- M 的估计与同方差情形一致： $\hat{M} = \frac{1}{T} \sum_t \mathbf{X}_t \mathbf{X}_t^\top = \frac{1}{T} \mathbf{X}^\top \mathbf{X}$
- Σ 的估计：首先利用 $\hat{\beta}$ 得到 $\hat{\varepsilon}_t = Y_t - \mathbf{X}_t^\top \hat{\beta}$ ，进而由

$$\frac{1}{T} \sum_t \varepsilon_t^2 \mathbf{X}_t \mathbf{X}_t^\top \xrightarrow{\text{a.s.}} \Sigma$$

$$\Rightarrow \hat{\Sigma} = \frac{1}{T} \sum_{t=1}^T \hat{\varepsilon}_t^2 \mathbf{X}_t \mathbf{X}_t^\top = \frac{1}{T} \mathbf{X}^\top \text{diag}(\hat{\varepsilon}_1^2, \dots, \hat{\varepsilon}_T^2) \mathbf{X}$$

- 样本渐近分布： $\hat{\beta}_T - \beta_0 \sim N(0, \frac{1}{T} \hat{M}^{-1} \hat{\Sigma} \hat{M}^{-1})$
- 样本渐近协方差矩阵 $\frac{1}{T} \hat{M}^{-1} \hat{\Sigma} \hat{M}^{-1}$ 对角线第 k 个元素平方根：
 $\hat{\beta}_{k,T}$ 的 稳健标准误 (robust s.e.)

本节内容

- 1 模型设定与评估
- 2 稳健标准误
- 3 极大似然估计**

极大似然估计：基本想法

- 极大似然估计 (maximum likelihood estimation, ML) 是一类基础的统计估计方法
 - 基本想法：统计模型暨联合分布 $\Pr(\{X_t\}|\theta)$ ；给定样本数据 $\{X_t\}$ ，这个概率又称为似然 (likelihood)
 - 一般总认为，给定 $\{X_t\}$ ，似然值在模型参数真实值 θ_0 处达到最大 \Rightarrow 寻找 θ 使得观察到该样本数据的概率最大

$$\max_{\theta \in \Theta} \Pr(\{X_t\}|\theta) \Rightarrow \hat{\theta}_{ML,T} = \operatorname{argmax}_{\theta \in \Theta} \Pr(\{X_t\}|\theta)$$

- $\hat{\theta}_{ML,T}$ 也是样本的一个函数，故也是一个随机变量 \Rightarrow 大样本性质：一致性，渐近分布
- OLS 估计，属于另一大类估计方法：矩估计 (moment estimation)

线性回归模型的极大似然估计

- 考虑线性回归模型： $Y_t = \mathbf{X}_t^\top \boldsymbol{\beta} + \varepsilon_t, t = 1, \dots, T$
- 若残差为正态独立同分布 $\varepsilon_t \stackrel{\text{iid}}{\sim} N(0, \sigma_\varepsilon^2)$ ，则可将样本数据 $(\mathbf{Y}, \mathbf{X}) = \{Y_t, \mathbf{X}_t\}$ 的似然值写为

$$L(\mathbf{Y}, \mathbf{X} | \boldsymbol{\beta}, \sigma_\varepsilon^2) = \frac{1}{\sqrt{(2\pi)^T \sigma_\varepsilon^{2T}}} \exp \left\{ -\frac{1}{2\sigma_\varepsilon^2} \sum_{t=1}^T (Y_t - \mathbf{X}_t^\top \boldsymbol{\beta})^2 \right\}$$

- ML 估计： $\max_{\boldsymbol{\beta}, \sigma_\varepsilon^2} L(\mathbf{Y}, \mathbf{X} | \boldsymbol{\beta}, \sigma_\varepsilon^2)$ ，等价于最大化对数似然值

$$\max_{\boldsymbol{\beta}, \sigma_\varepsilon^2} \log L(\mathbf{Y}, \mathbf{X} | \boldsymbol{\beta}, \sigma_\varepsilon^2)$$

线性回归模型的极大似然估计

- 对数似然函数：

$$\begin{aligned} \log L(\mathbf{Y}, \mathbf{X} | \boldsymbol{\beta}, \sigma_\varepsilon^2) = \\ -\frac{T}{2} \log 2\pi - \frac{T}{2} \log \sigma_\varepsilon^2 - \frac{1}{2\sigma_\varepsilon^2} \sum_{t=1}^T (Y_t - \mathbf{X}_t^\top \boldsymbol{\beta})^2 \end{aligned}$$

- 考虑 $\boldsymbol{\beta}$ 的 ML 估计：

$$\max_{\boldsymbol{\beta}} \log L \Leftrightarrow \min_{\boldsymbol{\beta}} \sum_{t=1}^T (Y_t - \mathbf{X}_t^\top \boldsymbol{\beta})^2$$

故， $\hat{\boldsymbol{\beta}}_{ML,T} = \hat{\boldsymbol{\beta}}_{OLS,T} = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{Y}$

- 考虑 $\hat{\sigma}_{\varepsilon,ML}^2 \Rightarrow$ 计算 $\partial_{\sigma_\varepsilon^2} \log L(\mathbf{Y}, \mathbf{X} | \boldsymbol{\beta}, \sigma_\varepsilon^2)$

MA 模型的估计

- 考虑 MA(q) 模型: $X_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \cdots + \theta_q \varepsilon_{t-q} = B(\mathcal{L})\varepsilon_t$
 - X_t 可逆 $\Leftrightarrow B(z) = 1 + \theta_1 z + \cdots + \theta_q z^q$ 的零点 z_1, \dots, z_q 均位于单位圆之外
- 若 X_t 可逆, 则 $B^{-1}(\mathcal{L})X_t = \varepsilon_t$, 是一个 AR(∞) 过程:

$$B^{-1}(z) = \frac{1}{\left(1 - \frac{z}{z_1}\right) \cdots \left(1 - \frac{z}{z_q}\right)} = 1 + \sum_{i=1}^{\infty} \phi_i z^i$$

$$\Rightarrow X_t = \sum_{i=1}^{\infty} \phi_i X_{t-i} + \varepsilon_t$$

MA 模型的近似矩估计

- 首先将 X_t 看做一个 $AR(p)$ 过程, p 较大, 进行 OLS 估计, 得到残差序列 $\{\hat{\varepsilon}_t\}$
- 再用 $\hat{\varepsilon}_t$ 代替 ε_t , 估计回归方程

$$X_t = \hat{\varepsilon}_t + \vartheta_1 \hat{\varepsilon}_{t-1} + \cdots + \vartheta_q \hat{\varepsilon}_{t-q} + e_t$$

- 可以证明, 当样本量 $T \rightarrow \infty$ 时, $\hat{\vartheta}_j \xrightarrow{\text{a.s.}} \theta_j$

MA 模型的极大似然估计

- 另一种估计办法是 ML 估计，但需要额外的分布假设
- 若 $\varepsilon_t \stackrel{\text{iid}}{\sim} N(0, \sigma_\varepsilon^2)$ ，则 $\mathbf{X} = [X_{q+1}, \dots, X_T]^\top$ 服从多元正态分布 $N(0, \Sigma)$
 - Σ 的每个元素都是 $\boldsymbol{\theta} = [\theta_1, \dots, \theta_q]^\top$ 与 σ_ε^2 的函数
 - 可以记做 $\Sigma(\boldsymbol{\theta}, \sigma_\varepsilon^2)$
- 可以写出对数似然函数

$$\log L(\mathbf{X} | \boldsymbol{\theta}, \sigma_\varepsilon^2) = -\frac{T}{2} \log 2\pi - \frac{1}{2} \log \det \Sigma - \frac{1}{2} \mathbf{X}^\top \Sigma^{-1} \mathbf{X}$$