

金融工程 2024 年秋 · 时间序列

第 9 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

2024 年 10 月 28 日

本讲内容

- ① 模型设定与评估
- ② 稳健标准误
- ③ MA 模型的估计

本节内容

- 1 模型设定与评估
- 2 稳健标准误
- 3 MA 模型的估计

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：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 $\Omega_t = \{Y_{t-1}, Y_{t-2}, \dots, Z_t, Z_{t-1}, \dots\}$

回归分析的关键：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

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

回归分析的关键：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

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

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 (causality)
 - 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
 - 进一步的，如果 W, Z, \dots 也是 Y 的影响因素，则要研究的问题聚焦为：保持所有其他因素不变， X 对 Y 的边际作用 (marginal effect)

相关性与因果性的区分

- 新冠检测越多，则发现的病例越多——检测量与病例数存在正相关
 - 特朗普：“我们的病例多，是因为我们检测多！” **FAKE NEWS**
 - 这不是因果关系：即便不检测，病例依然在
- 病例多，PPE（防护装备）、呼吸机、疫苗需求多——病例数与医用物资用量存在正相关
 - 这就是因果关系：如果没有病例，则没有医用物资的需求
- 在实证分析中，因果判断的本质是反事实 (counterfactual) 推理

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 ,

$$Y_t = \alpha X_t + u_t = \alpha X_t + \gamma Z_t + \varepsilon_t$$

而 X_t 与 Z_t 通常具有相关性 $\mathbb{E}X_t Z_t \neq 0$

- 最常见类型为遗漏共同因素 (common/confounding factor) 问题: 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
- 如果能观测到所有共同因素, 则加入回归可以消除内生性问题: $Y_t = \gamma Z_t + u_t$, $X_t = \delta Z_t + v_t$, 则 $Y_t = \alpha X_t + \beta Z_t + \varepsilon_t$ 可以得到正确的 X_t 边际作用 α (保持 Z 不变, X 的变化对 Y 的影响), 即 FWL 定理

内生性问题的 3 大来源

- 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 测量误差 (measurement error): 无法观测 X_t , 只能观测其代理 (proxy) 变量 $\tilde{X}_t = X_t + u_t$, 回归模型有内生性

$$Y_t = \alpha X_t + \varepsilon_t = \alpha \tilde{X}_t + (\varepsilon_t - \alpha u_t)$$

$$\text{即 } \mathbb{E}\tilde{X}_t(\varepsilon_t - \alpha u_t) \neq 0$$

内生性问题的解决

- 近 20 年：经济学实证研究领域的因果推断 (causal inference) 革命
 - 2019 年诺奖 Banerjee, Duflo, and Kreme 随机控制实验 (randomized controlled trials, RCT)
 - 2021 年诺奖 Angrist, Card, and Imbens 潜在结果与反事实因果推断计量理论
- 常见方法：非随机实验方法
 - 工具变量 (instrumental variables)
 - 双重差分 (difference in difference, DID)
 - 断点回归 (regression discontinuity)
- 参考书
 - Angrist and Pischke, *Mostly Harmless Econometrics*, 2009
 - 邱嘉平, 《因果推断实用计量方法》, 2020

回归模型的评估： R^2 与调整 R^2

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

$$\sum_t Y_t^2 = \mathbf{Y}^\top \mathbf{Y} = \hat{\mathbf{Y}}^\top \hat{\mathbf{Y}} + \hat{\boldsymbol{\varepsilon}}^\top \hat{\boldsymbol{\varepsilon}} = \sum_t \hat{Y}_t^2 + \sum_t \hat{\varepsilon}_t^2$$

- 定义

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

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

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

- 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

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

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 MA 模型的估计

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 $\{X_t\}$ 为 (向量) 鞅差序列, $\mathbb{E}[X_t|\Omega_{t-1}] = \mathbf{0}$, Ω_t 为 t -时的信息集:

$\mathbb{E}[X_t X_t^T] = \Sigma_t$ 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 $\frac{1}{T} \sum_t X_t X_t^T \xrightarrow{\text{a.s.}} \Sigma$, 则对应的样本均值向量有如下极限分布

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

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，

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

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

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

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

- 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 MA 模型的估计**

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 $\Leftrightarrow B(z) = 1 + \theta_1z + \cdots + \theta_qz^q$ 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:

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

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

MA 模型的近回归估计

- 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, $\hat{\vartheta}_j \xrightarrow{\text{a.s.}} \theta_j$
- 也可以直接计算 X_t 自协方差关于 $\theta_1, \dots, \theta_q$ 的表达式, 然后用 X_t 的样本自协方差对 $\{\theta_j\}$ 进行估计

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

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

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：

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

- 考虑 β 的 ML 估计：

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

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

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

ARMA 模型的极大似然估计

- 考虑 ARMA(p, q) 模型 $A(\mathcal{L})X_t = B(\mathcal{L})\varepsilon_t$

$$X_t = \phi_1 X_{t-1} + \cdots + \phi_p X_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \cdots + \theta_q \varepsilon_{t-q}, \quad t = 1, \dots, T$$

- 假设 $\varepsilon_t \stackrel{\text{iid}}{\sim} N(0, \sigma_\varepsilon^2)$, 则 $A(\mathcal{L})X_t, t = 1, \dots, T$, 服从多元正态分布 $N(\mathbf{0}, \Sigma)$, 其中 Σ 为 $\theta_1, \dots, \theta_q, \sigma_\varepsilon^2$ 的函数
- 进一步的, 定义 $Y_t \equiv A(\mathcal{L})X_t = X_t - \phi_1 X_{t-1} - \cdots - \phi_p X_{t-p}$, 以及 $\mathbf{Y} = [Y_1, \dots, Y_T]^T$, 则可以写出样本 $\mathbf{X} = \{X_t\}_{1-p}^T$ 对应的 (对数) 似然函数

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

- 数值求解系数 $\phi_1, \dots, \phi_p, \theta_1, \dots, \theta_q, \sigma_\varepsilon^2$ 的极大似然估计