

时间序列分析(初级)

平稳时间序列分析

陈垚翰

安徽大学 大数据与统计学院



安徽大学
Anhui University

本章结构

- 方法性工具
 - 延迟算子
 - 差分运算
 - 线性差分方程

- ARMA 模型

- 单位根检验

- 平稳序列建模

方法性工具

延迟算子

- 延迟算子(Lag operator)类似于一个时间指针,当前序列值乘以一个延迟算子,就相当于把当前序列值的时间向过去拨了一个时刻

延迟算子

- 延迟算子(Lag operator)类似于一个时间指针,当前序列值乘以一个延迟算子,就相当于把当前序列值的时间向过去拨了一个时刻
- 记 B 为延迟算子,有

$$x_{t-p} = B^p x_t, \forall p \geq 1 \quad (1)$$

延迟算子的性质

- $B^0 = 1$

延迟算子的性质

- $B^0 = 1$
- $B(c \cdot x_t) = c \cdot B(x_t) = c \cdot x_{t-1}$, c 为任意常数

延迟算子的性质

- $B^0 = 1$
- $B(c \cdot x_t) = c \cdot B(x_t) = c \cdot x_{t-1}$, c 为任意常数
- $B(x_t \pm y_t) = x_{t-1} \pm y_{t-1}$

延迟算子的性质

- $B^0 = 1$
- $B(c \cdot x_t) = c \cdot B(x_t) = c \cdot x_{t-1}$, c 为任意常数
- $B(x_t \pm y_t) = x_{t-1} \pm y_{t-1}$
- $B^n x_t = x_{t-n}$

延迟算子的性质

- $B^0 = 1$
- $B(c \cdot x_t) = c \cdot B(x_t) = c \cdot x_{t-1}$, c 为任意常数
- $B(x_t \pm y_t) = x_{t-1} \pm y_{t-1}$
- $B^n x_t = x_{t-n}$
- $(1 - B)^n = \sum_{i=0}^n (-1)^i C_n^i B^i$, 其中 $C_n^i = \frac{n!}{i!(n-i)!}$

延迟算子的性质

- $B^0 = 1$
- $B(c \cdot x_t) = c \cdot B(x_t) = c \cdot x_{t-1}$, c 为任意常数
- $B(x_t \pm y_t) = x_{t-1} \pm y_{t-1}$
- $B^n x_t = x_{t-n}$
- $(1 - B)^n = \sum_{i=0}^n (-1)^i C_n^i B^i$, 其中 $C_n^i = \frac{n!}{i!(n-i)!}$
- $\Phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$

Green 函数

- 原理

$$\begin{cases} \Phi(B) x_t = \varepsilon_t \\ x_t = \Psi(B) \varepsilon_t \end{cases} \Rightarrow \Phi(B) \Psi(B) \varepsilon_t = \varepsilon_t$$

- 方法

- 待定系数法

- 递推公式

$$\begin{cases} \psi_0 = 1 \\ \psi_i = \sum_{j=1}^i \psi_{i-j} \phi'_j \quad i \geq 1 \end{cases} \quad (2)$$

其中,

$$\phi'_j = \begin{cases} \phi_j & , \quad j \leq p \\ 0 & , \quad j > p \end{cases}$$

- $\{\psi_j\}$ 称为 Green 函数。

用延迟算子表示差分运算

- 1 阶差分

$$\nabla x_t = x_t - x_{t-1} \quad (3)$$

1 阶差分也记作 Δx_t .

用延迟算子表示差分运算

- 1 阶差分

$$\nabla x_t = x_t - x_{t-1} \quad (3)$$

1 阶差分也记作 Δx_t .

- p 阶差分

$$\nabla^p x_t = (1 - B)^p x_t = \sum_{i=0}^p (-1)^i C_p^i x_{t-i}. \quad (4)$$

用延迟算子表示差分运算

- 1 阶差分

$$\nabla x_t = x_t - x_{t-1} \quad (3)$$

1 阶差分也记作 Δx_t .

- p 阶差分

$$\nabla^p x_t = (1 - B)^p x_t = \sum_{i=0}^p (-1)^i C_p^i x_{t-i}. \quad (4)$$

- k 步差分

$$\nabla_k = x_t - x_{t-k} = (1 - B^k) x_t. \quad (5)$$

线性差分方程

线性差分方程

- 线性差分方程

$$z_t + a_1 z_{t-1} + a_2 z_{t-2} + \cdots + a_p z_{t-p} = h(t). \quad (6)$$

线性差分方程

- 线性差分方程

$$z_t + a_1 z_{t-1} + a_2 z_{t-2} + \cdots + a_p z_{t-p} = h(t). \quad (6)$$

- 齐次线性差分方程

$$z_t + a_1 z_{t-1} + a_2 z_{t-2} + \cdots + a_p z_{t-p} = 0. \quad (7)$$

齐次线性差分方程的解

齐次线性方程的特征方程

$$\lambda^p + a_1\lambda^{p-1} + a_2\lambda^{p-2} + \cdots + a_p = 0. \quad (8)$$

特征方程的解称为**特征根**, 记为 $\lambda_1, \lambda_2, \dots, \lambda_p$.

齐次线性差分方程的解

齐次线性方程的特征方程

$$\lambda^p + a_1\lambda^{p-1} + a_2\lambda^{p-2} + \cdots + a_p = 0. \quad (8)$$

特征方程的解称为**特征根**, 记为 $\lambda_1, \lambda_2, \dots, \lambda_p$.

Case 1. $\lambda_1, \lambda_2, \dots, \lambda_p$ 为 p 个不同的实数

$$z_t = c_1\lambda_1^t + c_2\lambda_2^t + \cdots + c_p\lambda_p^t. \quad (9)$$

Case 2. $\lambda_1, \lambda_2, \dots, \lambda_p$ 有相同实数根

$$z_t = \left(c_1 + c_2 t + \dots + c_d t^{d-1} \right) \lambda_1^t + c_{d+1} \lambda_{d+1}^t + \dots + c_p \lambda_p^t. \quad (10)$$

其中, $\lambda_1 = \lambda_2 = \dots = \lambda_d$ 为相同实数根, $\lambda_{d+1}, \lambda_{d+2}, \dots, \lambda_p$ 为互不相同的实数根。

Case 2. $\lambda_1, \lambda_2, \dots, \lambda_p$ 有相同实数根

$$z_t = \left(c_1 + c_2 t + \dots + c_d t^{d-1} \right) \lambda_1^t + c_{d+1} \lambda_{d+1}^t + \dots + c_p \lambda_p^t. \quad (10)$$

其中, $\lambda_1 = \lambda_2 = \dots = \lambda_d$ 为相同实数根, $\lambda_{d+1}, \lambda_{d+2}, \dots, \lambda_p$ 为互不相同的实数根。

Case 3. $\lambda_1, \lambda_2, \dots, \lambda_p$ 有复数根

$$z_t = \sum_{j=1}^d \left(c_1 + c_2 t + \dots + c_d t^{d-1} \right) \lambda_j^t + \sum_{j=d+1}^{p-2m} c_j \lambda_j^t + \sum_{j=1}^m r_j^t \left(c_{1j} e^{it\omega_j} + c_{2j} e^{-it\omega_j} \right). \quad (11)$$

其中, $\lambda_1, \lambda_2 \dots \lambda_d$ 为相同实数根, $r_1 e^{i\omega_1}, r_1 e^{-i\omega_1}, \dots, r_m e^{i\omega_m}, r_m e^{-i\omega_m}$ 为 m 对共轭复数根, $\lambda_{d+1}, \dots, \lambda_{p-2m}$ 为不同实数根。

非齐次线性方程的解

非齐次线性方程的解

- 非齐次线性方程的特解
 - 使得非齐次线性差分方程成立的任意解

$$z_t'' + a_1 z_{t-1}'' + a_2 z_{t-2}'' + \cdots + a_p z_{t-p}'' = h(t).$$

非齐次线性方程的解

- 非齐次线性方程的特解
 - 使得非齐次线性差分方程成立的任意解

$$z_t'' + a_1 z_{t-1}'' + a_2 z_{t-2}'' + \cdots + a_p z_{t-p}'' = h(t).$$

- 非齐次线性方程的通解
 - 齐次线性差分方程的通解和非齐次线性差分方程的特解之和

$$z_t = z_t' + z_t''.$$

ARMA 模型

Wold 分解定理

- 对于任何一个离散平稳过程 $\{x_t\}$ 它都可以分解为两个不相关的平稳序列之和, 其中一个为确定性的, 另一个为随机性的,

$$x_t = V_t + \xi_t \quad (12)$$

- V_t 为确定性序列, 历史序列值的线性组合

$$V_t = \sum_{j=1}^{\infty} \phi_j x_{t-j}$$

- ξ_t 为随机序列, 表示不能由历史信息解读的部分

$$\xi_t = \sum_{j=0}^{\infty} \theta_j \varepsilon_{t-j}$$

AR 模型的的定义

- 具有如下结构的模型称为 p 阶自回归模型, $\text{AR}(p)$

$$\left\{ \begin{array}{l} x_t = \phi_0 + \phi_1 x_{t-1} + \phi_2 x_{t-2} + \cdots + \phi_p x_{t-p} + \varepsilon_t \end{array} \right. \quad (13)$$

$$\left\{ \begin{array}{l} \phi_p \neq 0 \end{array} \right. \quad (14)$$

$$\left\{ \begin{array}{l} \mathbb{E}(\varepsilon_t) = 0, \quad \text{Var}(\varepsilon_t) = \sigma_\varepsilon^2, \quad \mathbb{E}(\varepsilon_t \varepsilon_s) = 0, \quad s \neq t \end{array} \right. \quad (15)$$

$$\left\{ \begin{array}{l} \mathbb{E}(x_s \varepsilon_t) = 0, \quad \forall s < t \end{array} \right. \quad (16)$$

- 引进延迟算子后, $\text{AR}(p)$ 可简记为

$$\Phi(B) x_t = \phi_0 + \varepsilon_t. \quad (17)$$

其中,

$$\Phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \cdots - \phi_p B^p.$$

AR 模型的定义

- 对 (17) 两边同时取期望(为什么可以),

$$\Phi(B) \underbrace{\mathbb{E}(x_t)}_{:=\mu} = \phi_0$$

\Downarrow

$$(1 - \phi_1 - \phi_2 - \cdots - \phi_p) \mu = \phi_0$$

AR 模型的定义

- 称 $\{y_t\}$ 为 $\{x_t\}$ 的去中心化序列, 令

$$\mu = \frac{\phi_0}{1 - \phi_1 - \cdots - \phi_p},$$
$$y_t = x_t - \mu.$$

- 去中心化序列的 $\text{AR}(p)$ 模型可以表示为

$$\Phi(B)y_t = \varepsilon_t. \tag{18}$$

AR 模型平稳性判别

- 为什么要判别

AR 模型平稳性判别

- 为什么要判别
 - AR 模型是常用的平稳序列模型之一,但是并非所有的 AR 模型都是平稳的
- 判别方法


AR 模型平稳性判别

- 为什么要判别
 - AR 模型是常用的平稳序列模型之一,但是并非所有的 AR 模型都是平稳的
- 判别方法
 - 单位根判别法
 - 平稳域判别法


AR 模型平稳性判别

- 为什么要判别
 - AR 模型是常用的平稳序列模型之一,但是并非所有的 AR 模型都是平稳的
- 判别方法
 - 单位根判别法
 - 平稳域判别法
- 考察如下四个 AR 序列(例 3.1)
 - (1) $x_t = 0.8x_{t-1} + \varepsilon_t$
 - (2) $x_t = -1.1x_{t-1} + \varepsilon_t$
 - (3) $x_t = x_{t-1} - 0.5x_{t-2} + \varepsilon_t$
 - (4) $x_t = x_{t-1} + 0.5x_{t-1} + \varepsilon_t$

平稳 AR 序列




$$(1) x_t = 0.8x_{t-1} + \varepsilon_t$$




$$(3) x_t = x_{t-1} - 0.5x_{t-2} + \varepsilon_t$$

非平稳 AR 序列



$$(2) x_t = -1.1x_{t-1} + \varepsilon_t$$



$$(4) x_t = 1.5x_{t-1} + \varepsilon_t$$

AR 模型平稳性判别方法

- 特征根判别
 - AR(p) 模型平稳的充要条件是 p 个特征根在单位圆内
 - AR(p) 模型平稳的等价条件是 p 个自回归多项式的根在单位圆外
- 平稳域判别
 - 平稳域

$$\{\phi_1, \phi_2, \dots, \phi_p \mid \text{单位根都在单位圆内}\} \quad (19)$$

AR(1) 模型平稳条件

- 特征根

$$\lambda = \phi$$

- 平稳域

$$|\phi| < 1$$


AR(2) 模型平稳条件

- 特征根

$$\lambda_1 = \frac{\phi_1 + \sqrt{\phi_1^2 + 4\phi_2}}{2}$$

$$\lambda_2 = \frac{\phi_1 - \sqrt{\phi_1^2 + 4\phi_2}}{2}$$

- 平稳域



$$\{\phi_1, \phi_2 \mid |\phi_2| < 1, \text{ 且 } \phi_2 \pm \phi_1 < 1\}$$

例 3.1 平稳性判别

模型	特征根判别	平稳域判别	结论
(1)	$\lambda_1 = 0.8$	$\phi_1 = 0.8$	平稳
(2)	$\lambda_1 = -1.1$	$\phi_1 = -1.1$	非平稳
(3)	$\lambda_1 = \frac{1+i}{2}$ $\lambda_2 = \frac{1-i}{2}$	$ \phi_2 = 0.5, \phi_2 + \phi_1 = 0.5, \phi_2 - \phi_1 = -1.5$	平稳
(4)	$\lambda_1 = \frac{1+\sqrt{3}}{2}$ $\lambda_2 = \frac{1-\sqrt{3}}{2}$	$ \phi_2 = 0.5, \phi_2 + \phi_1 = 1.5, \phi_2 - \phi_1 = -0.5$	非平稳

AR 模型的统计性质

- 均值
- 方差
- 协方差
- 自相关系数
- 偏自相关系数

均值

- 如果 $AR(p)$ 满足平稳性条件,

$$\mathbb{E}(x_t) = \mathbb{E}(\phi_0 + \phi_1 x_{t-1} + \cdots + \phi_p x_{t-p} + \varepsilon_t)$$

- 注意到,

$$\mathbb{E}(x_t) = \mu, \quad \mathbb{E}(\varepsilon_t) = 0, \quad \forall t$$

所以,

$$\mu = \frac{\phi_0}{1 - \phi_1 - \cdots - \phi_p}$$

- 注意到

$$x_t = \sum_{j=0}^{\infty} \psi_j \varepsilon_{t-j}$$

且 $\{\varepsilon_t\}$ i.i.d., 有

$$\text{Var}(x_t) = \sum_{j=0}^{\infty} \psi_j^2 \sigma_{\varepsilon}^2 \quad (20)$$

自协方差函数

- 假设 x_t 为中心化序列, 并且 $\text{AR}(p)$ 为平稳序列, $\forall k > 1$, 两边同时乘以 x_{t-k} 再求期望,

$$\mathbb{E}(x_t x_{t-k}) = \phi_1 \mathbb{E}(x_{t-1} x_{t-k}) + \cdots + \phi_p \mathbb{E}(x_{t-p} x_{t-k}) + \mathbb{E}(\varepsilon_t x_{t-k}). \quad (21)$$

- 注意到 $\mathbb{E}(\varepsilon_t x_{t-k}) = 0$, 则自协方差函数的递推公式为

$$\gamma_k = \phi_1 \gamma_{k-1} + \phi_2 \gamma_{k-2} + \cdots + \phi_p \gamma_{k-p}. \quad (22)$$

自相关系数

- 自相关系数(ACF)的定义

$$\rho_k = \frac{\gamma_k}{\gamma_0}. \quad (23)$$

- AR(p) 自相关系数的递推公式

$$\rho_k = \phi_1\rho_{k-1} + \phi_2\rho_{k-2} + \cdots + \phi_p\rho_{k-p}. \quad (24)$$

自相关系数

- 自相关系数的性质
 - 拖尾性

$$\rho(k) = \sum_{i=1}^p c_i \lambda_i^k \quad c_1, c_2, \dots, c_p \text{ 不能恒等于零.}$$

- 呈复指数衰减(为什么?)

$$\rho(k) = \sum_{i=1}^p c_i \lambda_i^k \rightarrow 0.$$





考察如下 AR 模型的自相关系数

(1) $x_t = 0.8x_{t-1} + \varepsilon_t$

(2) $x_t = -0.8x_{t-1} + \varepsilon_t$

(3) $x_t = x_{t-1} - 0.5x_{t-2} + \varepsilon_t$

(4) $x_t = -x_{t-1} - 0.5x_{t-2} + \varepsilon_t$



偏自相关系数

- 假设 $\{x_t\}$ 为中心化 $\text{AR}(p)$ 平稳序列, k 偏自相关系数定义为

$$\rho_{x_t, x_{t-k} | x_{t-1}, \dots, x_{t-k+1}} = \frac{\mathbb{E} \{ [x_t - \hat{\mathbb{E}}(x_t)] [x_{t-k} - \hat{\mathbb{E}}(x_{t-k})] \}}{\mathbb{E} \{ [x_{t-k} - \hat{\mathbb{E}}(x_{t-k})]^2 \}}, \quad (25)$$

其中,

$$\hat{\mathbb{E}}(x_t) = \mathbb{E} [x_t | x_{t-1}, \dots, x_{t-k+1}]$$

$$\hat{\mathbb{E}}(x_{t-k}) = \mathbb{E} [x_{t-k} | x_{t-1}, \dots, x_{t-k+1}]$$

- k 偏自相关系数可以由如下回归方程的 OLS 估计, $\hat{\phi}_{kk}$ 得到,

$$x_t = \phi_{k1}x_{t-1} + \phi_{k2}x_{t-2} + \cdots + \phi_{kk}x_{t-k} + \varepsilon_t.$$

- 平稳 AR(p) 模型偏自相关系数 p 阶截尾

Yule-Walker 方程

- 在 $x_t = \phi_{k1}x_{t-1} + \phi_{k2}x_{t-2} + \cdots + \phi_{kk}x_{t-k} + \varepsilon_t$ 两边同时乘以 x_{t-l} 并求期望有

$$\rho_l = \phi_{k1}\rho_{l-1} + \phi_{k2}\rho_{l-2} + \cdots + \phi_{kk}\rho_{l-k}$$

- 依次取 $l = 1, \dots, k$, 有

$$\begin{pmatrix} 1 & \rho_1 & \cdots & \rho_{k-1} \\ \rho_1 & 1 & \cdots & \rho_{k-2} \\ \vdots & \vdots & & \vdots \\ \rho_{k-1} & \rho_{k-2} & \cdots & 1 \end{pmatrix} \begin{pmatrix} \phi_{k1} \\ \phi_{k2} \\ \vdots \\ \phi_{kk} \end{pmatrix} = \begin{pmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_k \end{pmatrix}$$

Yule-Walker 方程

- 根据 Cramer 法则, $\phi_{kk} = \frac{D_k}{D}$, D_k 是 D 中的第 k 个向量换成 $(\rho_1, \rho_2, \dots, \rho_k)^\top$

$$D = \begin{vmatrix} 1 & \rho_1 & \cdots & \rho_{k-1} \\ \rho_1 & 1 & \cdots & \rho_{k-2} \\ \vdots & \vdots & & \vdots \\ \rho_{k-1} & \rho_{k-2} & \cdots & 1 \end{vmatrix} \quad D_k = \begin{vmatrix} 1 & \rho_1 & \cdots & \rho_1 \\ \rho_1 & 1 & \cdots & \rho_2 \\ \vdots & \vdots & & \vdots \\ \rho_{k-1} & \rho_{k-2} & \cdots & \rho_k \end{vmatrix}$$

Yule-Walker 方程

- 对于 AR(p) 模型, 有如下 Yule-Walker 方程

$$\begin{pmatrix} 1 & \rho_1 & \cdots & \rho_{p-1} \\ \rho_1 & 1 & \cdots & \rho_{p-2} \\ \vdots & \vdots & & \vdots \\ \rho_{k-1} & \rho_{k-2} & \cdots & \rho_{k-p} \end{pmatrix} \begin{pmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_p \end{pmatrix} = \begin{pmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_k \end{pmatrix}$$

- 当 $k > p$ 时

$$D_k = \begin{vmatrix} 1 & \rho_1 & \cdots & \rho_{p-1} & \cdots & \rho_1 \\ \rho_1 & 1 & \cdots & \rho_{p-2} & \cdots & \rho_2 \\ \vdots & \vdots & & \vdots & & \vdots \\ \rho_{k-1} & \rho_{k-2} & \cdots & \rho_{k-p} & \cdots & \rho_k \end{vmatrix} = 0$$





考察如下 AR 模型的偏自相关系数

(1) $x_t = 0.8x_{t-1} + \varepsilon_t$

(2) $x_t = -0.8x_{t-1} + \varepsilon_t$

(3) $x_t = x_{t-1} - 0.5x_{t-2} + \varepsilon_t$

(4) $x_t = -x_{t-1} - 0.5x_{t-2} + \varepsilon_t$



MA 模型的定义

- 具有如下结构的模型称为 q 阶移动平均模型, 简记为 $\text{MA}(q)$

$$\left\{ \begin{array}{l} x_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \cdots - \theta_q \varepsilon_{t-q} \quad (26) \\ \theta_q \neq 0 \quad (27) \\ \mathbb{E}(\varepsilon_t) = 0, \quad \text{Var}(\varepsilon_t) = \sigma_\varepsilon^2, \quad \mathbb{E}(\varepsilon_t \varepsilon_s) = 0, \quad s \neq t \quad (28) \end{array} \right.$$

- 特别当 $\mu = 0$ 时, 称为中心化 $\text{MA}(q)$ 模型
- 引进延迟算子后, $\text{MA}(q)$ 可简记为

$$x_t = \Theta(B) \varepsilon_t. \quad (29)$$

其中,

$$\Theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \cdots - \theta_q B^q$$

MA(q): 自协方差函数 q 阶截尾, 自相关系数 q 阶截尾

$$\begin{aligned}\gamma_k &= \mathbb{E}[(x_t - \mu)(x_{t-k} - \mu)] \\ &= \mathbb{E}[(\varepsilon_t - \theta_1\varepsilon_{t-1} - \theta_2\varepsilon_{t-2} - \cdots - \theta_q\varepsilon_{t-q}) \\ &\quad (\varepsilon_{t-k} - \theta_1\varepsilon_{t-k-1} - \theta_2\varepsilon_{t-k-2} - \cdots - \theta_q\varepsilon_{t-k-q})] \quad (30)\end{aligned}$$

$$= \begin{cases} \left(1 + \theta_1^2 + \cdots + \theta_q^2\right) \sigma_\varepsilon^2, & k = 0 \\ \left(-\theta_k + \sum_{i=1}^{q-k} \theta_i \theta_{k+i}\right) \sigma_\varepsilon^2, & 1 \leq k \leq q \\ 0, & k > q \end{cases} \quad (31)$$

MA(q): 自协方差函数 q 阶截尾, 自相关系数 q 阶截尾

$$\begin{aligned}\rho_k &= \frac{\gamma_k}{\gamma_0} \\ &= \begin{cases} 1, & k = 0 \\ \frac{-\theta_k + \sum_{i=1}^{q-k} \theta_i \theta_{k+i}}{1 + \theta_1^2 + \dots + \theta_q^2}, & 1 \leq k \leq q \\ 0, & k > q \end{cases} \end{aligned} \quad (32)$$

逆函数的递推公式

- 记

$$I(B) = \frac{1}{\Theta(B)} = \sum_{i=0}^{\infty} I_i B^i$$

与 Green 函数的递推公式完全类似, 逆函数的递推公式为

$$\begin{cases} I_0 = 1 \\ I_i = \sum_{j=1}^i I_{i-j} \theta'_j \quad i \geq 1 \end{cases} \quad (33)$$

其中,

$$\theta'_j = \begin{cases} \theta_j & , j \leq q \\ 0 & , j > q \end{cases}$$

- 可逆 $MA(q)$ 可以表示成 $AR(\infty)$, 因此 $MA(q)$ 偏自相关系数 ∞ 截尾, 即具有拖尾性

MA(q)模型的可逆性

- MA 模型的识别性
- 考虑如下 MA(1) 模型

$$(1) x_t = \varepsilon_t - 2\varepsilon_{t-1}$$

$$(2) x_t = \varepsilon_t - 0.5\varepsilon_{t-1}$$

模型(1)和模型(2)的理论自相关系数均为

$$\rho_k = \begin{cases} -0.4 & \text{if } k = 1 \\ 0 & \text{if } k \geq 2 \end{cases}$$

MA(q)模型的可逆性

- 考虑如下 MA(2) 模型

$$(3) \quad x_t = \varepsilon_t - \frac{4}{5}\varepsilon_{t-1} + \frac{16}{25}\varepsilon_{t-2}$$

$$(4) \quad x_t = \varepsilon_t - \frac{5}{4}\varepsilon_{t-1} + \frac{25}{16}\varepsilon_{t-2}$$

模型(3)和模型(4)的理论自相关系数均为

$$\rho_k = \begin{cases} -0.64012 & \text{if } k = 1 \\ 0.31256 & \text{if } k = 2 \\ 0 & \text{if } k \geq 3 \end{cases}$$

MA(q) 模型的可逆性

- 可逆 MA 模型的定义
 - 若一个 MA 模型能够表示成收敛的 AR 模型形式, 那么 MA 模型称为可逆 MA 模型
- 可逆性的重要性
 - 依相关系数唯一识别可逆 MA 模型
- 以 MA(1) 为例

MA 表示	模型 1: $x_t = \varepsilon_t - \theta\varepsilon_{t-1}$	模型 2: $x_t = \varepsilon_t - \frac{1}{\theta}\varepsilon_{t-1}$
-------	---	---

AR 表示	模型 1: $\frac{x_t}{1-\theta B} = \varepsilon_t$	模型 2: $\frac{x_t}{1-\frac{1}{\theta}B} = \varepsilon_t$
-------	--	---

自相关系数	$\rho = \frac{-\theta}{1+\theta^2}$
-------	-------------------------------------

可逆性条件	$ \theta < 1$	$ \theta > 1$
-------	----------------	----------------

MA(q) 模型的可逆条件

- MA(q) 模型, $\frac{x_t}{\Theta(B)} = \varepsilon_t$, $\Theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q$. 假设 $\left\{ \frac{1}{\lambda_i} \right\}_{i=1}^q$ 是系数多项式 $\Theta(B)$ 的 q 个根, 则 $\Theta(B)$ 可以分解为

$$\Theta(B) = \prod_{i=1}^q (1 - \lambda_i B).$$

MA(q) 模型的可逆条件

- MA(q) 模型的可逆条件是：
 - MA(q) 模型的特征根在单位圆内

$$|\lambda_i| < 1$$

- 等价条件是移动平滑系数多项式的根都在单位圆外

$$\left| \frac{1}{\lambda_i} \right| > 1$$

ARMA 模型的定义

- 具有如下结构的模型称为自回归移动平均模型, 简记为 ARMA(p, q)

$$\left\{ \begin{array}{l} x_t = \phi_0 + \phi_1 x_{t-1} + \cdots + \phi_p x_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \cdots - \theta_q \varepsilon_{t-q} \\ \phi_p \neq 0, \theta_q \neq 0 \\ \mathbb{E}(\varepsilon_t) = 0, \quad \text{Var}(\varepsilon_t) = \sigma_\varepsilon^2, \quad \mathbb{E}(\varepsilon_t \varepsilon_s) = 0, \quad s \neq t \\ \mathbb{E}(x_s \varepsilon_t) = 0, \quad \forall s < t \end{array} \right.$$

- 引进延迟算子, 中心化 ARMA(p, q) 可简记为

$$\Phi(B)x_t = \Theta(B)\varepsilon_t \quad (34)$$

- p 阶自回归多项式

$$\Phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$$

- q 阶移动平均多项式

$$\Theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q$$

平稳条件与可逆条件

- ARMA(p, q) 的平稳条件
 - p 阶自回归系数多项式的 $\Phi(B) = 0$ 的根都在单位圆外
 - ARMA(p, q) 的平稳性完全由自回归部分的平稳性决定
- ARMA(p, q) 的可逆条件
 - q 阶移动平均系数多项式 $\Theta(B) = 0$ 的根都在单位圆外
 - ARMA(p, q) 的可逆性完全由移动平滑部分的可逆性决定

传递形式与逆转形式

- 传递形式

$$\begin{aligned}x_t &= \Phi^{-1}(B)\Theta(B)\varepsilon_t \\ &= \varepsilon_t + \sum_{i=1}^{\infty} G_i \varepsilon_{t-i}\end{aligned}$$

- 逆转形式

$$\begin{aligned}\varepsilon_t &= \Theta^{-1}(B)\Phi(B)x_t \\ &= x_t + \sum_{i=1}^{\infty} I_i x_{t-i}\end{aligned}$$

$$\left\{ \begin{array}{l} G_0 = 1 \\ G_i = \sum_{j=1}^i G_{i-j} \phi'_j - \theta'_i \quad i \geq 1 \end{array} \right. \quad \left\{ \begin{array}{l} I_0 = 1 \\ I_i = \sum_{j=1}^i I_{i-j} \theta'_j - \phi'_i \quad i \geq 1 \end{array} \right.$$

其中,

$$\phi'_j = \begin{cases} \phi_j & , j \leq p \\ 0 & , j > p \end{cases}$$

$$\theta'_i = \begin{cases} \theta_i & , i \leq q \\ 0 & , i > q \end{cases}$$

其中,

$$\phi'_i = \begin{cases} \phi_i & , i \leq p \\ 0 & , i > p \end{cases}$$

$$\theta'_j = \begin{cases} \theta_j & , j \leq q \\ 0 & , j > q \end{cases}$$

ARMA(p, q) 模型的统计性质

- 均值

$$\mathbb{E}[x_t] = \frac{\phi_0}{1 - \phi_1 - \dots - \phi_p}$$

- 协方差(中心化模型)

$$\gamma(k) = \sigma_\varepsilon^2 \sum_{i=0}^{\infty} G_i G_{i+k}$$

- 自相关系数(中心化模型)

$$\rho(k) = \frac{\gamma(k)}{\gamma(0)} = \frac{\sum_{j=0}^{\infty} G_j G_{j+k}}{\sum_{j=0}^{\infty} G_j^2}$$

ARMA模型的相关性特征

模型	自相关系数	偏自相关系数
AR(p)	拖尾	p 阶截尾
MA(q)	q 阶截尾	拖尾
ARMA(p, q)	拖尾	拖尾

单位根检验

布朗运动 (Brownian Motion)

- 标准布朗运动 $W_t(\omega)$ 是定义在完备概率空间 $(\Omega, \mathcal{F}, \mathbb{P})$ 上的连续性随机过程, 对于固定的 $\omega \in \Omega$,

$$W_t(\omega) : [0, 1] \mapsto \mathbf{R}.$$

也记为 $W(t)$ 。


布朗运动 (Brownian Motion)

- 标准布朗运动 $W_t(\omega)$ 是定义在完备概率空间 $(\Omega, \mathcal{F}, \mathbb{P})$ 上的连续性随机过程, 对于固定的 $\omega \in \Omega$,

$$W_t(\omega) : [0, 1] \mapsto \mathbf{R}.$$

也记为 $W(t)$ 。

- 标准布朗运动需满足:
 - (a) $W(0) = 0$;
 - (b) 对任意 $0 \leq t_1 < t_2 < t_3 < t_4 \leq 1$, $W(t_2) - W(t_1)$ 和 $W(t_4) - W(t_3)$ 是相互独立的正态随机变量, 均值为 0, 方差分别为 $t_2 - t_1$ 和 $t_4 - t_3$;
 - (c) $W(t)$ 在 $(\Omega, \mathcal{F}, \mathbb{P})$ 上依概率 1 连续。




泛函型中心极限定理 (The Functional Central Limit Theorem)

- 定义阶梯函数如下

$$x_T(r) = \frac{1}{T} \sum_{t=1}^{\lfloor Tr \rfloor} \varepsilon_t = \begin{cases} 0 & 0 \leq r < 1/T \\ \varepsilon_1/T & 1/T \leq r < 2/T \\ (\varepsilon_1 + \varepsilon_2)/T & 2/T \leq r < 3/T \\ \vdots & \\ (\varepsilon_1 + \varepsilon_2 + \cdots + \varepsilon_T)/T & r = 1 \end{cases}$$

- 标准化有

$$\frac{\sqrt{T}x_T(r)}{\sigma} = \frac{1}{\sigma} \frac{1}{\sqrt{T}} \sum_{t=1}^{\lfloor Tr \rfloor} \varepsilon_t$$

$x_T(r)$ 

- $\diamond x_t = \frac{\sum_{\tau=1}^t \varepsilon_\tau}{T}$
- $\frac{x_1}{T^2} + \frac{x_2}{T^2} + \cdots + \frac{x_{T-1}}{T^2} = \frac{1}{T} \sum_{t=1}^{T-1} \frac{x_t}{T} = \int_0^1 x_T(r) dr$
- $\frac{x_1}{T^{3/2}} + \frac{x_2}{T^{3/2}} + \cdots + \frac{x_{T-1}}{T^{3/2}} = \frac{1}{T} \sum_{t=1}^{T-1} \frac{x_t}{\sqrt{T}} = \int_0^1 \sqrt{T} x_T(r) dr$
- $\frac{x_1^2}{T^2} + \frac{x_2^2}{T^2} + \cdots + \frac{x_{T-1}^2}{T^2} = \frac{1}{T} \sum_{t=1}^{T-1} \left(\frac{x_t}{\sqrt{T}} \right)^2 = \int_0^1 \left(\sqrt{T} x_T(r) \right)^2 dr$

泛函型中心极限定理 (The Functional Central Limit Theorem)

- $\forall r \in [0, 1]$,

$$\frac{\sqrt{T}x_T(r)}{\sigma} = \frac{1}{\sigma} \underbrace{\frac{\sqrt{[Tr]}}{\sqrt{T}}}_{\rightarrow \sqrt{r}} \underbrace{\frac{1}{\sqrt{[Tr]}} \sum_{t=1}^{[Tr]} \varepsilon_t}_{\xrightarrow{d} \mathcal{N}(0, \sigma^2)} \xrightarrow{d} \mathcal{N}(0, r).$$







- $\sqrt{T} [x_T(r_2) - x_T(r_1)] / \sigma \xrightarrow{d} \mathcal{N}(0, r_2 - r_1)$ 与 $\sqrt{T} [x_T(r_3) - x_T(r_4)] / \sigma \xrightarrow{d} \mathcal{N}(0, r_4 - r_3)$ 相互独立只要 $[r_1, r_2]$ 和 $[r_3, r_4]$ 不重叠.

- $\sqrt{T}x_T(0)/\sigma = 0$
- 当 $T \rightarrow \infty$

$$\frac{\sqrt{T}x_T(\cdot)}{\sigma} \xrightarrow{d} W(\cdot), \quad (35)$$

其中, $W(\cdot)$ 表示维纳过程 (Weiner process), 或者布朗运动 (Brownian motion)

- $\int_0^1 \sqrt{T}x_T(r)dr \xrightarrow{d} \sigma \int_0^1 W(r)dr$
- $\int_0^1 \left(\sqrt{T}x_T(r)\right)^2 dr \xrightarrow{d} \sigma^2 \int_0^1 [W(r)]^2 dr$



连续映射定理和一些公式

- 连续映射定理: 如果

$$S_T(\cdot) \xrightarrow{d} S(\cdot)$$

并且 $g(\cdot)$ 是连续性泛函(比如 $g(S(\cdot)) = a + bS(\cdot)$ 或者 $g(S(\cdot)) = \int S(r)dr$), 则

$$g(S_T(\cdot)) \xrightarrow{d} g(S(\cdot)). \quad (36)$$

- 求和公式

$$- \sum_{t=1}^T t = \frac{T(T+1)}{2} \Rightarrow T^{-2} \sum_{t=1}^T t \rightarrow \frac{1}{2}$$

$$- \sum_{t=1}^T t^2 = \frac{T(T+1)(2T+1)}{6} \Rightarrow T^{-3} \sum_{t=1}^T t^2 \rightarrow \frac{1}{3}$$

$$- T^{-(v+1)} \sum_{t=1}^T t^v \rightarrow \frac{1}{v+1}$$

- 考虑如下 AR(1) 模型

$$x_t = \phi_1 x_{t-1} + \varepsilon_t, \quad \varepsilon_t \overset{i.i.d.}{\sim} (0, \sigma^2)$$

- 考虑如下 AR(1) 模型

$$x_t = \phi_1 x_{t-1} + \varepsilon_t, \quad \varepsilon_t \overset{i.i.d.}{\sim} (0, \sigma^2)$$

- OLS 估计, $\hat{\phi}_1$,

$$\hat{\phi}_1 = \frac{\sum x_t x_{t-1}}{\sum x_{t-1}^2} \quad (37)$$

- 考虑如下原假设

$$H_0 : \phi_1 = 1$$

且在 H_0 下,

$$\hat{\phi}_1 - 1 = \frac{\sum x_{t-1} \varepsilon_t}{\sum x_{t-1}^2} \quad (38)$$

单位根检验

- 考虑如下原假设

$$H_0 : \phi_1 = 1$$

且在 H_0 下,

$$\hat{\phi}_1 - 1 = \frac{\sum x_{t-1} \varepsilon_t}{\sum x_{t-1}^2} \quad (38)$$

- 假设 $x_0 = 0, \phi_1 = 1$, 则

$$x_t = x_{t-1} + \varepsilon_t = \varepsilon_1 + \varepsilon_2 + \cdots + \varepsilon_t$$

单位根检验

$$\begin{aligned}T(\hat{\phi}_1 - 1) &= \frac{(1/T) \sum x_{t-1} \varepsilon_t}{(1/T^2) \sum x_{t-1}^2} \\&= \frac{(1/T) \frac{1}{2} (x_T^2 - \sum \varepsilon_t^2)}{(1/T^2) \sum x_{t-1}^2} \\&= \frac{\frac{1}{2} \left[\left(\frac{1}{\sqrt{T}} x_T \right)^2 - \frac{1}{T} \sum \varepsilon_t^2 \right]}{\frac{1}{T} \sum \left(\frac{1}{\sqrt{T}} x_{t-1} \right)^2}\end{aligned}$$

Dickey-Fuller 统计量的分布

- 对于

$$x_t = \phi_1 x_{t-1} + \varepsilon_t, \quad \varepsilon_t \stackrel{i.i.d.}{\sim} (0, \sigma^2), \quad t = 1, \dots, T$$

且

$$\hat{\phi}_1 = \frac{\sum x_t x_{t-1}}{\sum x_{t-1}^2}$$

则在 H_0 下

$$T(\hat{\phi}_1 - 1) \xrightarrow{d} \frac{\{[W(1)]^2 - 1\}}{2 \int_0^1 [W(r)]^2 dr}. \quad (39)$$

Dickey-Fuller 统计量的分布

通常的 t -统计量不再具有 t -分布的形式。令 $\hat{\varepsilon}_t = x_t - \hat{\phi}_1 x_{t-1}$ ， $s_T^2 = \sum \hat{\varepsilon}_t^2 / T \xrightarrow{P} \sigma^2$

$$\begin{aligned} t &= \frac{\hat{\phi}_1 - 1}{\hat{\sigma}_{\hat{\phi}_1}} \\ &= \frac{\frac{1}{T} \sum x_{t-1} \varepsilon_t}{\sqrt{s_T^2 \left\{ \frac{1}{T^2} \sum x_{t-1}^2 \right\}^{1/2}}} \\ &\xrightarrow{d} \frac{\frac{\sigma^2}{2} \{ [W(1)]^2 - 1 \}}{\sigma \left\{ \sigma^2 \int_0^1 [W(r)]^2 dr \right\}^{1/2}} \\ &= \frac{\{ [W(1)]^2 - 1 \}}{2 \left\{ \int_0^1 [W(r)]^2 dr \right\}^{1/2}} \end{aligned}$$

DF 检验的类型：类型 1

- 假设检验形式

$$\begin{cases} H_0 : x_t = x_{t-1} + \varepsilon_t \\ H_1 : x_t = \phi_1 x_{t-1} + \varepsilon_t \quad \text{with } |\phi_1| < 1 \end{cases}$$

等价于

$$\begin{cases} H_0 : \Delta x_t = \varepsilon_t \\ H_1 : \Delta x_t = \beta x_{t-1} + \varepsilon_t \quad \text{with } \beta < 0 \end{cases}$$

DF 检验的类型：类型 1

- OLS 检验形式

$$\Delta x_t = \beta x_{t-1} + e_t, \quad (40)$$

- 在 H_0 下,

$$T\hat{\beta}_T \xrightarrow{d} \frac{\{\chi_{(1)}^2 - 1\}}{2 \int_0^1 [W(r)]^2 dr},$$

其中, $\hat{\beta}_T$ 表示 (40) 中 β 的 OLS 估计量。同时

$$\frac{\hat{\beta}_T}{\widehat{se}(\hat{\beta}_T)} \xrightarrow{d} \frac{1/2 \{\chi_{(1)}^2 - 1\}}{\left[\int_0^1 [W(r)]^2 dr \right]^{1/2}}.$$

DF 检验的类型：类型 2a

- 假设检验形式

$$\begin{cases} H_0 : \Delta x_t = \varepsilon_t \\ H_1 : \Delta x_t = \alpha + \beta x_{t-1} + \varepsilon_t \quad \text{with } \beta < 0 \end{cases}$$

DF 检验的类型：类型 2a

- OLS 检验形式

$$\Delta x_t = \alpha + \beta x_{t-1} + e_t \quad (41)$$

在 H_0 下,

$$T\hat{\beta}_T \xrightarrow{d} \frac{1/2 \left(\chi_{(1)}^2 - 1 \right) - W(1) \int_0^1 W(r) dr}{\int_0^1 W^2(r) dr - \left(\int_0^1 W(r) dr \right)^2}$$

其中, $\hat{\beta}_T$ 表示 (41) 中 β 的 OLS 估计量。同时

$$\frac{\hat{\beta}_T}{\widehat{se}(\hat{\beta}_T)} \xrightarrow{d} \frac{1/2 \left(\chi_{(1)}^2 - 1 \right) - W(1) \int_0^1 W(r) dr}{\left(\int_0^1 W^2(r) dr - \left(\int_0^1 W(r) dr \right)^2 \right)^{1/2}}$$

DF 检验的类型：类型 3

- 假设检验形式

$$\begin{cases} H_0 : \Delta x_t = \varepsilon_t \\ H_1 : \Delta x_t = \alpha + \beta x_{t-1} + \delta t + \varepsilon_t \quad \text{with } \beta < 0 \end{cases}$$

或者

$$\begin{cases} H_0 : \Delta x_t = \alpha + \varepsilon_t \\ H_1 : \Delta x_t = \alpha + \beta x_{t-1} + \delta t + \varepsilon_t \quad \text{with } \beta < 0 \end{cases}$$

DF 检验的类型：类型 3

- OLS 检验形式

$$x_t = \alpha + \phi x_{t-1} + \delta t + e_t \quad (42)$$

或者

$$\Delta x_t = \alpha + \beta x_{t-1} + \delta t + e_t$$

Augmented DF (ADF) 检验

- 考虑如下 AR(p) 模型 ($p \geq 2$)

$$x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \cdots + \phi_p x_{t-p} + \varepsilon_t$$

可以等价表示为

$$\Delta x_t = \rho x_{t-1} - \beta_1 \Delta x_{t-1} - \cdots - \beta_{p-2} \Delta x_{t-p+2} - \beta_{p-1} \Delta x_{t-p+1} + \varepsilon_t$$

其中,

$$\rho = \phi_1 + \phi_2 + \cdots + \phi_p - 1$$

$$\beta_j = \phi_{j+1} + \phi_{j+2} + \cdots + \phi_p, \quad j = 1, 2, \cdots, p-1$$

- 假设检验形式

$$\begin{cases} H_0 : \rho = 0 \\ H_1 : \rho \neq 0 \end{cases}$$

ADF 的 OLS 检验形式

- 类型 1

$$\Delta x_t = \rho x_{t-1} + \beta_1 \Delta x_{t-1} + \cdots + \beta_{p-1} \Delta x_{t-p+1} + \varepsilon_t \quad \varepsilon_t \overset{i.i.d.}{\sim} (0, \sigma^2)$$

- 类型 2

$$\Delta x_t = \alpha + \rho x_{t-1} + \beta_1 \Delta x_{t-1} + \cdots + \beta_{p-1} \Delta x_{t-p+1} + \varepsilon_t \quad \varepsilon_t \overset{i.i.d.}{\sim} (0, \sigma^2)$$

ADF 的 OLS 检验形式

- 类型 3


$$\Delta x_t = \alpha + \delta t + \rho x_{t-1} + \beta_1 \Delta x_{t-1} + \dots + \beta_{p-1} \Delta x_{t-p+1} + \varepsilon_t \quad \varepsilon_t \stackrel{i.i.d.}{\sim} (0, \sigma^2)$$

- 检验统计量

$$\frac{\hat{\rho}}{\widehat{se}(\hat{\rho})} \sim \text{DF } t \text{ statistic}$$

平稳序列建模

建模步骤



样本相关系数

- 样本自相关系数

$$\hat{\rho}_k = \frac{\sum_{t=1}^{n-k} (x_t - \bar{x})(x_{t+k} - \bar{x})}{\sum_{t=1}^n (x_t - \bar{x})^2}, \forall 0 < k < n \quad (43)$$

样本偏自相关系数

- 样本偏自相关系数

$$\hat{\phi}_{kk} = \frac{\hat{D}_k}{\hat{D}}, \forall 0 < k < n, \quad (44)$$

其中,

$$\hat{D} = \begin{vmatrix} 1 & \hat{\rho}_1 & \cdots & \hat{\rho}_{k-1} \\ \hat{\rho}_1 & 1 & \cdots & \hat{\rho}_{k-2} \\ \vdots & \vdots & & \vdots \\ \hat{\rho}_{k-1} & \hat{\rho}_{k-2} & \cdots & 1 \end{vmatrix} \quad \hat{D}_k = \begin{vmatrix} 1 & \hat{\rho}_1 & \cdots & \hat{\rho}_1 \\ \hat{\rho}_1 & 1 & \cdots & \hat{\rho}_2 \\ \vdots & \vdots & & \vdots \\ \hat{\rho}_{k-1} & \hat{\rho}_{k-2} & \cdots & \hat{\rho}_k \end{vmatrix}$$

样本相关系数的的渐进分布

- Bartlett

$$\hat{\rho}_k \sim \mathcal{N}\left(0, \frac{1}{n}\right), n \rightarrow \infty$$

- Quenouille

$$\hat{\phi}_{kk} \sim \mathcal{N}\left(0, \frac{1}{n}\right), n \rightarrow \infty$$

模型定阶的经验方法

- 95% 的置信区间

$$\Pr\left(-\frac{2}{\sqrt{n}} \leq \hat{\rho}_k \leq \frac{2}{\sqrt{n}}\right) \geq 0.95$$

$$\Pr\left(-\frac{2}{\sqrt{n}} \leq \hat{\phi}_{kk} \leq \frac{2}{\sqrt{n}}\right) \geq 0.95$$

- 模型定阶的经验方法
 - 如果样本(偏)自相关系数在最初的 d 阶明显大于两倍标准差范围,而之后几乎 95% 的自相关系数都落在 2 倍标准差的范围内,且由非零(偏)自相关系数衰减为小值波动的过程非常突然。这时,通常视为(偏)自相关系数截尾,截尾阶数为 d 。

模型识别

$\hat{\rho}_k$	$\hat{\phi}_{kk}$	选择模型
拖尾	p 阶截尾	AR(p)
q 阶截尾	拖尾	MA(q)
拖尾	拖尾	ARMA(p, q)

参数估计

- 考虑非中心化 ARMA(p, q) 模型 $x_t = \mu + \frac{\Theta_q(B)}{\Phi_p(B)} \varepsilon_t$, 其中

$$\varepsilon_t \sim (0, \sigma_\varepsilon^2)$$

$$\Theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$$

$$\Phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$$

- 待估参数

- $p + q + 2$ 个未知参数:

$$\phi_1, \dots, \phi_p, \theta_1, \dots, \theta_q, \mu, \sigma_\varepsilon^2$$

- 矩估计、极大似然估计、最小二乘估计

模型检验

- 模型的显著性检验
 - 整个模型对信息的提取是否充分
- 参数的显著性检验
 - 模型结构是否最简

模型的显著性检验

- 假设条件
 - 原假设: 残差序列为白噪声序列

$$H_0: \rho_1 = \rho_2 = \cdots = \rho_m = 0, \forall m \geq 1$$

- 备择假设: 残差序列为非白噪声序列

$$H_1: \text{至少存在某个 } \rho_k \neq 0, \forall m \geq 1, k \leq m$$

- LB(Ljung-Box) 检验统计量

$$LB = n(n+2) \sum_{k=1}^m \left(\frac{\hat{\rho}_k^2}{n-k} \right) \sim \chi^2(m) \quad (45)$$

其中, $\hat{\rho}_k$ 表示 k 阶样本自相关系数, 通过 (43) 计算。

模型选择: AIC 和 BIC

- AIC : $T \ln \hat{\sigma}_\varepsilon^2 + 2(p + q + 2)$
- BIC : $T \ln \hat{\sigma}_\varepsilon^2 + (\ln T) (p + q + 2)$

模型选择: AIC 和 BIC

- AIC : $T \ln \hat{\sigma}_\varepsilon^2 + 2(p + q + 2)$
- BIC : $T \ln \hat{\sigma}_\varepsilon^2 + (\ln T) (p + q + 2)$
- 相对最小的 AIC 和 BIC 对应于相对最最优的模型

序列预测

- 因为平稳 ARMA 模型具有 AR(∞) 表示结构,

$$\sum_{j=0}^{\infty} I_j x_{t-j} = \varepsilon_t$$

所以可以通过递推法,基于现有序列的观察值 $x_t, x_{t-1}, x_{t-2}, \dots$, 预测未来时刻的序列值

$$\hat{x}_{t+1} = -I_1 x_t - I_2 x_{t-1} - I_3 x_{t-2} - \dots$$

$$\hat{x}_{t+2} = -I_1 \hat{x}_{t+1} - I_2 x_t - I_3 x_{t-1} - \dots$$

$$\hat{x}_{t+3} = -I_1 \hat{x}_{t+2} - I_2 \hat{x}_{t+1} - I_3 x_t - \dots$$

⋮

序列分解

- 根据 $\text{ARMA}(p, q)$ 的 $\text{MA}(\infty)$ 表示, 未来时刻的序列值 x_{t+l} 可以分解为

$$x_{t+l} = \underbrace{(\varepsilon_{t+l} + G_1\varepsilon_{t+l-1} + \cdots + G_{l-1}\varepsilon_{t+1})}_{:= e_t(l)} + \underbrace{(G_l\varepsilon_t + G_{l+1}\varepsilon_{t-1} + \cdots)}_{:= \hat{x}_t(l)}.$$

并且根据 $\text{ARMA}(p, q)$ 的线性特征, $\hat{x}_t(l)$ 同样可以表示成已知历史信息的线性函数

$$\hat{x}_t(l) = \sum_{i=0}^{\infty} D_i x_{t-i}.$$

$\hat{x}_t(l)$ 也称为基于历史信息的未来 l 步预测值

- 条件均值和方差

$$\mathbb{E}(x_{t+l} \mid x_t, x_{t-1}, \dots) = \hat{x}_t(l)$$

$$\begin{aligned}\text{Var}(x_{t+l} \mid x_t, x_{t-1}, \dots) &= \text{Var}[e_t(l)] \\ &= \sum_{i=0}^{l-1} G_i^2 \sigma_\varepsilon^2\end{aligned}$$

AR(p) 序列预测

预测值

$$\begin{aligned}\widehat{x}_t(l) &= \mathbb{E}(x_{t+l} \mid x_t, x_{t-1}, \dots) \\ &= \mathbb{E}(\phi_1 x_{t+l-1} + \dots + \phi_p x_{t+l-p} + \varepsilon_{t+l} \mid x_t, x_{t-1}, \dots) \\ &= \phi_1 \widehat{x}_t(l-1) + \dots + \phi_p \widehat{x}_t(l-p)\end{aligned}$$

其中,

$$\widehat{x}_t(k) = \begin{cases} \widehat{x}_t(k) & , k \geq 1 \\ x_{t+k} & , k \leq 0 \end{cases}$$

MA(q) 序列预测

- 当 $l \leq q$ (预测步长小于或等于 MA(q) 模型阶数) 时,

$$\begin{aligned}x_{t+l} &= \mu + \varepsilon_{t+l} - \theta_1 \varepsilon_{t+l-1} - \cdots - \theta_q \varepsilon_{t+l-q} \\ &= (\varepsilon_{t+l} - \theta_1 \varepsilon_{t+l-1} - \cdots - \theta_{l-1} \varepsilon_{t+1}) + (\mu - \theta_l \varepsilon_t - \cdots - \theta_q \varepsilon_{t+l-q})\end{aligned}$$

- 当 $l > q$ (预测步长大于 MA(q) 模型阶数) 时,

$$\begin{aligned}x_{t+l} &= \mu + \varepsilon_{t+l} - \theta_1 \varepsilon_{t+l-1} - \cdots - \theta_q \varepsilon_{t+l-q} \\ &= (\varepsilon_{t+l} - \theta_1 \varepsilon_{t+l-1} - \cdots - \theta_q \varepsilon_{t+l-q}) + \mu\end{aligned}$$

预测值为

$$\hat{x}_t(l) = \begin{cases} \mu - \sum_{i=l}^q \theta_i \varepsilon_{t+l-i} & , \quad l \leq q \\ \mu & , \quad l > q \end{cases}$$

预测方差

$$\text{Var} [e_t(l)] = \begin{cases} \left(1 + \theta_1^2 + \cdots + \theta_{l-1}^2\right) \sigma_\varepsilon^2 & , \quad l \leq q \\ \left(1 + \theta_1^2 + \cdots + \theta_q^2\right) \sigma_\varepsilon^2 & , \quad l > q \end{cases}$$

ARMA(p, q) 序列预测

预测值

$$\begin{aligned} &= \mathbb{E} (\phi_1 x_{t+l-1} + \cdots + \phi_p x_{t+l-p} + \varepsilon_{t+l} - \theta_1 \varepsilon_{t+l-1} - \cdots - \theta_q \varepsilon_{t+l-q} \\ &\quad | x_t, x_{t-1}, \cdots) \\ &= \begin{cases} \phi_1 \widehat{x}_t(l-1) + \cdots + \phi_p \widehat{x}_t(l-p) - \sum_{i=1}^q \theta_i \varepsilon_{t+l-i} & l \leq q \\ \phi_1 \widehat{x}_t(l-1) + \cdots + \phi_p \widehat{x}_t(l-p) & l > q \end{cases} \end{aligned}$$

其中,

$$\widehat{x}_t(k) = \begin{cases} \widehat{x}_t(k) & , k \geq 1 \\ x_{t+k} & , k \leq 0 \end{cases}$$

修正预测原理

- 在旧的信息 x_t, x_{t-1}, \dots 的基础上, x_{t+l} 的预测值为

$$\hat{x}_t(l) = G_l \varepsilon_t + G_{l+1} \varepsilon_{t-1} + \dots$$

- 假设获得一个新的观测值 x_{t+1}
 - x_{t+l} 的修正预测为

$$\hat{x}_{t+1}(l-1) = G_{l-1} \varepsilon_{t+1} + G_l \varepsilon_t + G_{l+1} \varepsilon_{t-1} + \dots = G_{l-1} \varepsilon_{t+1} + \hat{x}_t(l)$$

其中, $\varepsilon_{t+1} = x_{t+1} - \hat{x}_t(1)$

- 修正预测误差为

$$e_{t+1}(l-1) = G_0 \varepsilon_{t+l} + \cdots + G_{l-2} \varepsilon_{t+2}$$

- 预测方差为

$$\text{Var} [e_{t+1}(l-1)] = \left(G_0^2 + \cdots + G_{l-2}^2 \right) \sigma_\varepsilon^2$$

总结

- 差分运算、延迟算子、线性差分方程
- ARMA 模型
 - 模型的基本定义和性质
 - 平稳性的判别、检验
 - 泛函型中心极限定理、单位根检验
- 平稳序列建模
 - 模型识别
 - 参数估计: 矩估计 (和 Yule-Walker 方程的联系), 极大似然估计, 最小二乘估计
 - 模型检验
 - ARMA 模型预测