

中国科学技术大学

1. 平稳序列: 如果时间序列 $\{X_t\} = \{X_t: t \in \mathbb{N}\}$ 满足 (1) $\forall t \in \mathbb{N}, EX_t^2 < \infty$;

(2) $\forall t \in \mathbb{N}, EX_t = \mu$; (3) $\forall t, s \in \mathbb{N}, E[(X_t - \mu)(X_s - \mu)] = \gamma_{t-s}$, 则称 X_t 是平稳时间序列, 简称为平稳序列. 称实数列 $\{\gamma_t\}$ 为 $\{X_t\}$ 的自协方差函数, 称 $\rho_k = \frac{\gamma_k}{\gamma_0}$ 为自相关系数. EX_t 和 $\text{Var } X_t$ 均为与 t 无关的常数; $\forall s, t \in \mathbb{Z}, k \in \mathbb{Z}, \text{Cov}(X_t, X_s) = \text{Cov}(X_{t+k}, X_{s+k}) = \gamma_{s-t}$, 即协方差结构平移不变.

(ii) $\{\gamma_t\}$ 具有如下性质: (1) 对称性: $\gamma_k = \gamma_{-k} \forall k \in \mathbb{Z}$.

(2) 非负定性: $\forall n \in \mathbb{N}^+, \Gamma_n = \begin{bmatrix} \gamma_0 & \gamma_1 & \cdots & \gamma_{n-1} \\ \gamma_1 & \gamma_0 & \cdots & \gamma_{n-2} \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{n-1} & \gamma_{n-2} & \cdots & \gamma_0 \end{bmatrix}$ 是非负定阵.

(3) $|\gamma_k| \leq \gamma_0 \forall k \in \mathbb{Z}$ 成立.

2. 白噪声: 设 $\{\varepsilon_t\}$ 是一个平稳序列. 如果对任何 $s, t \in \mathbb{N}, E\varepsilon_t = \mu, \text{Cov}(\varepsilon_t, \varepsilon_s) = \begin{cases} \sigma^2, & t=s, \\ 0, & t \neq s. \end{cases}$ 就称 $\{\varepsilon_t\}$ 是一个白噪声, 记作 $\text{WN}(\mu, \sigma^2)$. 设 $\{\varepsilon_t\}$ 是 $\text{WN}(\mu, \sigma^2)$.

3. 正交平稳序列: 对于平稳序列 $\{X_t\}$ 和 $\{Y_t\}$,

(1) 若对于任何 $s, t \in \mathbb{Z}, E[X_t Y_s] = 0$, 则称 $\{X_t\}$ 和 $\{Y_t\}$ 正交;

(2) 若对于任何 $s, t \in \mathbb{Z}, \text{Cov}(X_t, Y_s) = 0$, 则称 $\{X_t\}$ 和 $\{Y_t\}$ 不相关.

对于零均值的平稳序列, 正交性和不相关性等价.



中国科学技术大学

4. 绝对可和: 若实数列 $\{a_j\}$ 满足 $\sum_{j=-\infty}^{\infty} |a_j| < \infty$, 就称 $\{a_j\}$ 绝对可和.

对于绝对可和的实数列 $\{a_j\}$, 定义零均值白噪声 $\{\varepsilon_t\}$ 的无穷滑动和 $X_t = \sum_{j=-\infty}^{\infty} a_j \varepsilon_{t-j}$, $t \in \mathbb{Z}$, 则 $\{X_t\}$ 是平稳序列.

一般线性平稳序列只要求 $\{a_j\}$ 平方可和, 即只要求 $\sum_{j=-\infty}^{\infty} a_j^2 < \infty$.

5. Hilbert 空间: 用 $L^2(X)$ 表示平稳序列 $\{X_t\}$ 中随机变量有限线性组合的全体:

$L^2(X) = \{ \sum_{j=1}^k a_j X(t_j) \mid a_j \in \mathbb{R}, t_j \in \mathbb{Z}, 1 \leq j \leq k, k \in \mathbb{N}^+ \}$. 在 $L^2(X)$ 上定义内积 $\langle X, Y \rangle = E(XY)$.

引入距离 $\|X\| = \langle Y - X, Y - X \rangle^{1/2}$, 则 $L^2(X)$ 是内积、距离空间.

用 L^2 表示二阶矩有限的随机变量的全体: $L^2 = \{X: EX^2 < \infty\}$, 则 L^2 也是内积、距离空间, $L^2(X) \subset L^2$.

均方收敛: $\forall \{f_n\} \in L^2, f_0 \in L^2$, 若 $\lim_{n \rightarrow \infty} \|f_n - f_0\| = \lim_{n \rightarrow \infty} E|f_n - f_0|^2 = 0$, 则称 f_n 在

L^2 中收敛到 f_0 . 记作 $f_n \xrightarrow{L^2} f_0$; 若当 $n, m \rightarrow \infty$ 时 $\|f_n - f_m\| \rightarrow 0$, 称 $\{f_n\}$ 是 L^2 中的基本列或 Cauchy 列.

完备的内积空间又称为 Hilbert 空间, L^2 是 Hilbert 空间.

用 $\bar{L}^2(X)$ 表示 L^2 中含 $L^2(X)$ 的最小闭子空间, 则 $\bar{L}^2(X)$ 是 Hilbert 空间, 称为由平稳序列 $\{X_t\}$ 生成的 Hilbert 空间.

(*) 验证 $Y_t = \sum_{k=-\infty}^{\infty} \varphi_k(t)$ 是平稳序列的步骤, 整体分为两大步:

(1) 证明 Y_t 的存在性 — 作为极限而存在.

(2) 证明 Y_t 的平稳性 — $EY_t = \mu$, $EY_t^2 < \infty$, $\text{cov}(Y_t, Y_s) = Y_{t-s}$.



中国科学技术大学

其中又可分为以下几步:

- (i) 构造 $L^2(X)$ 进而构造 $L^1(X)$; (ii) 根据题目已知条件 (通常在所证结论中) 构造辅助序列 $\{p_n(t)\}$, 证明 $\{p_n(t)\}$ 是 $L^1(X)$ 中的 Cauchy 列; (iii) 定义 $Y_t = \lim_{n \rightarrow \infty} p_n(t)$.

6. 谱密度: 设平稳序列 $\{x_t\}$ 有自协方差函数 $\{\gamma_k\}$.

(1) 如果有 $[-\pi, \pi]$ 上的单调不减右连续函数 $F(\lambda)$, 使得 $\gamma_k = \int_{-\pi}^{\pi} e^{ik\lambda} dF(\lambda)$, $F(-\pi) = 0$.

$k \in \mathbb{Z}$, 就称 $F(\lambda)$ 是 $\{x_t\}$ 或 $\{\gamma_k\}$ 的谱分布函数, 简称为谱函数.

(2) 如果有 $[-\pi, \pi]$ 上的非负函数 $f(\lambda)$ 使得 $\gamma_k = \int_{-\pi}^{\pi} f(\lambda) e^{ik\lambda} d\lambda$, 则称 $\gamma_k = \int_{-\pi}^{\pi} e^{ik\lambda} f(\lambda) d\lambda$, $k \in \mathbb{Z}$, 称 $f(\lambda)$ 是 $\{x_t\}$ 或 $\{\gamma_k\}$ 的谱密度函数. 谱密度.

Herglotz 定理: 平稳序列的谱唯一存在.

7. 推移算子: 对任何时间序列 $\{x_t\}$ 和无穷级数 $\psi(z) = \sum_{j=-\infty}^{\infty} b_j z^j$, 只要级数

$\sum_{j=-\infty}^{\infty} b_j x_{t-j}$ 在某种意义下收敛 (a.s. 收敛、依概率收敛、均方收敛), 就定义

$\psi(B) = \sum_{j=-\infty}^{\infty} b_j B^j$, $\psi(B)x_t = \sum_{j=-\infty}^{\infty} b_j B^j x_t = \sum_{j=-\infty}^{\infty} b_j x_{t-j}$. 称 B 是时间 t 的

向后推移算子, 简称为推移算子.

8. AR(p) 模型: 若 $\{x_t\}$ 是 $WN(0, \sigma^2)$, 实数 a_1, a_2, \dots, a_p ($a_p \neq 0$) 使得

多项式 $A(z)$ 的零点都在单位圆外: $A(z) = 1 - \sum_{j=1}^p a_j z^j \neq 0, |z| \leq 1$. 就称 p 阶

差分方程 $x_t = \sum_{j=1}^p a_j x_{t-j} + \varepsilon_t$, $t \in \mathbb{Z}$ 是一个 p 阶自回归模型, 简称为 AR(p) 模型.

1101C-08 201412-2500



中国科学技术大学

满足AR(p)模型的平稳时间序列 $\{x_t\}$ 称为平稳解或AR(p)序列。AR(p)模型可改写为 $A(B)x_t = \varepsilon_t, t \in \mathbb{Z}$ 。

9. Wold系数: 设多项式 $A(z)$ 的互异根是 z_1, z_2, \dots, z_k 。则对 $1 < \rho < \min\{|z_j|\}$, $[A(z)]^{-1} = \frac{1}{A(z)}$ 是 $|z| \leq \rho$ 内的解析函数。从而有Taylor级数 $A^{-1}(z) = \sum_{j=0}^{\infty} \psi_j z^j$, $|z| \leq \rho$ 。由级数在 $z=\rho$ 的绝对收敛性得到: 当 $j \rightarrow \infty$ 时, $|\psi_j \rho^j| \rightarrow 0$ 。于是由 $\psi_j = o(\rho^{-j})$, $j \rightarrow \infty$ 知 $\{\psi_j\}$ 绝对可和。而且 $\min\{|z_j|\}$ 越大, $\psi_j \rightarrow 0$ 越快。

定义 $A^{-1}(B) = \sum_{j=0}^{\infty} \psi_j B^j$, 得 $x_t = A^{-1}(B)A(B)x_t = A^{-1}(B)\varepsilon_t, t \in \mathbb{Z}$ 。

即 $x_t = A^{-1}(B)\varepsilon_t = \sum_{j=0}^{\infty} \psi_j \varepsilon_{t-j}$, $t \in \mathbb{Z}$ 决定的平稳序列是AR(p)序列

$\{\psi_j\}$ 称为平稳序列 $\{x_t\}$ 的Wold系数。

因果形式, 具体表达式需要确定 ψ_j 的值, 参见习题

10. AR(p)序列 $\{x_t\}$ 的谱密度函数 $f(\lambda) = \frac{\sigma^2}{2\pi} \left| \sum_{j=0}^{\infty} \psi_j e^{ij\lambda} \right|^2 = \frac{\sigma^2}{2\pi |A(e^{i\lambda})|^2}$, $A(z)$

是AR(p)模型的特征多项式。另: 平稳序列 $\{x_t\}$ 的自协方差函数 $\{\gamma_k\}$ 绝对可和:

$\sum_{k=-\infty}^{\infty} |\gamma_k| < \infty$, 则 $\{x_t\}$ 有谱密度 $f(\lambda) = \frac{1}{2\pi} \sum_{k=-\infty}^{\infty} \gamma_k e^{-ik\lambda} = \frac{1}{2\pi} \sum_{k=-\infty}^{\infty} \gamma_k \cos(k\lambda) =$

$\frac{1}{2\pi} [\gamma_0 + 2 \sum_{k=1}^{\infty} \gamma_k \cos(k\lambda)]$ 。

补充: 由自回归系数 a_1, a_2, \dots, a_p 推导Wold系数 $\{\psi_k\}$ 的公式: $\psi_0 = 1, \psi_k = \sum_{j=1}^p a_j \psi_{k-j}, k \geq 1$ 。

11. Yule-Walker方程: 对 $x_t = \sum_{j=1}^p a_j x_{t-j} + \varepsilon_t, t \in \mathbb{Z}$ (p阶自回归模型的基本定义),

则 $\begin{bmatrix} x_t \\ x_{t+1} \\ \vdots \\ x_{t+m} \end{bmatrix} = \begin{bmatrix} x_{t-1} & x_{t-2} & \dots & x_{t-p} \\ x_t & x_{t-1} & \dots & x_{t-p+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_{t+m-2} & x_{t+m-3} & \dots & x_{t+m-p} \end{bmatrix} A_n + \begin{bmatrix} \varepsilon_t \\ \varepsilon_{t+1} \\ \vdots \\ \varepsilon_{t+m} \end{bmatrix}$ 其中 $A_n = (a_{n,1}, a_{n,2}, \dots, a_{n,p})^T$
 $\equiv (a_1, a_2, \dots, a_p, 0, \dots, 0)^T$ 。
 1101C-08 201412-2500



定义 $\Gamma_n = \begin{bmatrix} \gamma_0 & \gamma_1 & \cdots & \gamma_{n-1} \\ \gamma_1 & \gamma_0 & \cdots & \gamma_{n-2} \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{n-1} & \gamma_{n-2} & \cdots & \gamma_0 \end{bmatrix}$ 和 $\gamma_n = \begin{bmatrix} \gamma_1 \\ \gamma_2 \\ \vdots \\ \gamma_n \end{bmatrix}$, 则有下列 Yule-Walker 方程: Page 5

中国科学技术大学

$\gamma_n = \Gamma_n a_n; \gamma_0 = \gamma_n^T a_n + \sigma^2, n \geq 1$ 特别地, 当 $p=2$ 时, 方程简化为 $\begin{pmatrix} \gamma_0 & \gamma_1 \\ \gamma_1 & \gamma_0 \end{pmatrix} \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} = \begin{pmatrix} \gamma_1 \\ \gamma_2 \end{pmatrix}$
 化简为自相关系数形式即 $\begin{pmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{pmatrix} \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} = \begin{pmatrix} \rho_1 \\ \rho_2 \end{pmatrix}$ 得 $\begin{cases} \rho_1 = \frac{a_1}{1-a_2} \\ \rho_2 = \frac{a_1^2 + a_2(1-a_2)}{1-a_2} \end{cases}$

12. Levinson 递推公式: 若 Γ_{n+1} 正定, 对 $1 \leq k \leq n$ 有

$$\begin{cases} a_{k+1,1} = \gamma_1 / \gamma_0 \\ \sigma_k^2 = \gamma_0 \\ \sigma_k^2 = \sigma_{k-1}^2 (1 - a_{k,k}^2) \\ a_{k+1,k+1} = \frac{\gamma_{k+1} - \gamma_k a_{k,1} - \gamma_{k-1} a_{k,2} - \cdots - \gamma_1 a_{k,k}}{\gamma_0 - \gamma_1 a_{k,1} - \gamma_2 a_{k,2} - \cdots - \gamma_k a_{k,k}} \\ a_{k+1,j} = a_{k,j} - a_{k+1,k+1} a_{k,k+1-j}, 1 \leq j \leq k. \end{cases}$$

其中 $\sigma_k^2 \stackrel{\text{def}}{=} E(X_{k+1} - a_k^T X_k)^2$
 是用 X_k 预测 X_{k+1} 时的均方误差.

$a_{k,j} \quad a_{k,j+1}$
 $a_{k+1,j} \quad a_{k+1,j+1}$

13. AR(1) 和 AR(2) 模型:

对 AR(1) 模型 $X_t = aX_{t-1} + \varepsilon_t, t \in \mathbb{Z}, \{\varepsilon_t\} \sim WN(0, \sigma^2)$ 有平稳解 $X_t = \sum_{j=0}^{\infty} a^j \varepsilon_{t-j}$.

自协方差函数 $\gamma_0 = \sigma^2 \sum_{j=0}^{\infty} a^{2j} = \frac{\sigma^2}{1-a^2}, \gamma_k = a\gamma_{k-1} = \cdots = a^k \gamma_0$.

自相关系数 $\rho_k = \gamma_k / \gamma_0 = a^k$

谱密度 $f(\lambda) = \frac{\sigma^2}{2\pi |1 - a \exp(i\lambda)|^2} = \frac{\sigma^2}{2\pi (1 + a^2 - 2a \cos \lambda)}, \lambda \in [-\pi, \pi]$.

AR(2) 模型 $X_t = a_1 X_{t-1} + a_2 X_{t-2} + \varepsilon_t, t \in \mathbb{Z}$. 其中 $\{\varepsilon_t\}$ 是 $WN(0, \sigma^2)$.

特征多项式 $A(z) = 1 - a_1 z - a_2 z^2$ 的根都在单位圆外的充分必要条件是 a_1, a_2

满足条件 $a_2 \pm a_1 < 1, |a_2| < 1$.



中国科学技术大学

设 z_1, z_2 是 $A(z)$ 的两个根, 则 $|z_1| > 1, |z_2| > 1$. 从 Yule-Walker 方程可得自相关系数 $p_0 = 1, p_1 = \frac{a_1}{1-a_2}, p_k = a_1 p_{k-1} + a_2 p_{k-2}, k \geq 1$.

(1) z_1, z_2 是实根 $\Leftrightarrow a_1^2 + 4a_2 \geq 0$

(2) z_1, z_2 是复根 $\Leftrightarrow a_1^2 + 4a_2 < 0$

(3) 解 Yule-Walker 方程得到 $a_1 = \frac{p_1(1-p_2)}{1-p_1^2}, a_2 = \frac{p_2-p_1^2}{1-p_1^2}$.

从上式可以反解出 $p_1 = \frac{a_1}{1-a_2}, p_2 = a_2 + \frac{a_1^2}{1-a_2}$.

当 (a_1, a_2) 在 $\mathcal{A} = \{(a_1, a_2) | a_2 \pm a_1 < 1, |a_2| < 1\}$ 内变化时, (p_1, p_2) 在 $\mathcal{C} = \{(p_1, p_2) | p_1^2 < (1+p_2)/2, |p_1| < 1, |p_2| < 1\}$ 中取值. 称 \mathcal{C} 是 $AR(2)$ 的允许域, \mathcal{A} 是 $AR(2)$ 的稳定域.

(4) $AR(2)$ 序列的谱密度是 $f(\lambda) = \frac{\sigma^2}{2\pi} \cdot \frac{1}{|1 - a_1 e^{i\lambda} - a_2 e^{2i\lambda}|^2}$.

(5) 由 Durbin-Levinson 方程组,



中国科学技术大学

14. MA(8)模型和MA(8)序列: 设 $\{\varepsilon_t\}$ 是 $WN(0, \sigma^2)$, 若实数 $b_1, b_2, \dots, b_8 (b_8 \neq 0)$ 使得 $B(z) = 1 + \sum_{j=1}^8 b_j z^j \neq 0, |z| < 1$, 就称 $X_t = \varepsilon_t + \sum_{j=1}^8 b_j \varepsilon_{t-j}, t \in \mathbb{Z}$ 是8阶滑动平均模型, 简称为MA(8)模型; 由 $X_t = \varepsilon_t + \sum_{j=1}^8 b_j \varepsilon_{t-j}$ 决定的平稳序列 $\{X_t\}$ 是滑动平均序列, 简称为MA(8)序列.

如果进一步要求多项式 $B(z)$ 在单位圆上也没有零点: $B(z) \neq 0$ 当 $|z| = 1$, 则称 $(*)$ 是可逆的MA(8)模型, 称相应的平稳序列是可逆的MA(8)序列.

15. MA(8)序列 $\{X_t\}$ 的自协方差函数 γ_k 后截尾: $\gamma_0 = \sigma^2 b_8^2, \gamma_k = 0, |k| > 8$; 这是MA(8)序列的必要条件
其谱密度 $f(\lambda) = \frac{\sigma^2}{2\pi} |B(e^{i\lambda})|^2 = \frac{\sigma^2}{2\pi} \sum_{k=-8}^8 \gamma_k e^{-ik\lambda}, \lambda \in [-\pi, \pi]$.

16. 可逆MA(1)和MA(2)模型: 设 $\{\varepsilon_t\}$ 是 $WN(0, \sigma^2)$.

对可逆MA(1)序列 $X_t = \varepsilon_t + b\varepsilon_{t-1}, \varepsilon_t \sim WN(0, \sigma^2), |b| < 1$, 自协方差函数 $\gamma_0 = \sigma^2(1+b^2), \gamma_1 = b\sigma^2$ 和 $\gamma_k = 0, |k| \geq 2$. 自相关系数 $\rho_k = \begin{cases} b/(1+b^2), & |k|=1 \\ 0, & |k| > 1 \end{cases}$.

谱密度 $f(\lambda) = \frac{\sigma^2}{2\pi} |1+be^{i\lambda}|^2 = \frac{\sigma^2}{2\pi} (1+b^2+2b\cos\lambda), \lambda \in [-\pi, \pi]$.

对可逆MA(2)模型 $X_t = \varepsilon_t + b_1\varepsilon_{t-1} + b_2\varepsilon_{t-2}, t \in \mathbb{Z}$ 的特征多项式是 $B(z) = 1 + b_1z + b_2z^2 \neq 0, |z| < 1$.

1) 可逆域是 $\{(b_1, b_2): B(z) \neq 0, |z| \leq 1\} = \{(b_1, b_2): b_2 \pm b_1 > -1, |b_2| < 1\}$ 和AR(2)的平稳域相对应.



中国科学技术大学

(2) 自协方差函数是 $\gamma_0 = \sigma^2(1+b_1^2+b_2^2)$, $\gamma_1 = \sigma^2(b_1+b_1b_2)$, $\gamma_2 = \sigma^2b_2$, $\gamma_k = 0, |k| \geq 2$.

(3) 自相关系数是 $\rho_1 = \frac{b_1+b_1b_2}{1+b_1^2+b_2^2}$, $\rho_2 = \frac{b_2}{1+b_1^2+b_2^2}$, $\rho_k = 0, |k| \geq 2$.

(4) 谱密度是 $f(\lambda) = \frac{\sigma^2}{2\pi} |1+b_1e^{i\lambda}+b_2e^{i2\lambda}|^2$.

17. ARMA(p, q) 模型及其平稳解: 设 $\{\varepsilon_t\}$ 是 $WN(0, \sigma^2)$. 实系数多项式 $A(z)$ 和 $B(z)$

没有公共根, 满足 $b_0=1$, $a_p b_q \neq 0$, $A(z) = 1 - \sum_{j=1}^p a_j z^j \neq 0, |z| \leq 1$; $B(z) = \sum_{j=0}^q b_j z^j \neq 0, |z| < 1$.

就称差分方程 $X_t = \sum_{j=1}^p a_j X_{t-j} + \sum_{j=0}^q b_j \varepsilon_{t-j}$, $t \in \mathbb{Z}$ 是一个自回归滑动平均模型, 简称为

ARMA(p, q) 模型. 称满足上式的平稳序列 $\{X_t\}$ 为平稳解或 ARMA(p, q) 序列. 利用推移

算子可以改写为 $A(B)X_t = B(B)\varepsilon_t$, $t \in \mathbb{Z}$.

18. ARMA(p, q) 模型的 Wold 系数: $\exists \rho > 1$, $t \in \mathbb{Z}$ 内 $A^*(z)B(z)$ 解析, 从而有

Taylor 展开式 $\Phi(z) = A^*(z)B(z) = \sum_{j=0}^{\infty} \psi_j z^j$, $|z| \leq \rho$. 定义 $\Phi(B) = A^*(B)B(B)$

$= \sum_{j=0}^{\infty} \psi_j B^j$. 因此 $A(B)X_t = B(B)\varepsilon_t \Rightarrow X_t = A^*(B)B(B)\varepsilon_t = \sum_{j=0}^{\infty} \psi_j \varepsilon_{t-j}$, $t \in \mathbb{Z}$.

称 $\{\psi_k\}$ 为 X_t 的 Wold 系数. 上述定义的平稳序列是 ARMA(p, q) 模型 (K) 的唯一平稳解.

19. ARMA(p, q) 序列的自协方差函数可以由 Wold 系数 $\{\psi_j\}$ 表示: $\gamma_k = \sigma^2 \sum_{j=0}^{\infty} \psi_j \psi_{j+k}$, $k \geq 0$.

计算 Wold 系数的递推方法: 规定 $b_j = 0, j > q$; $\psi_j = 0, j < 0$. $\psi_j = \begin{cases} 1, j=0 \\ b_j + \sum_{k=1}^p a_k \psi_{j-k}, j=1, 2, \dots \end{cases}$



中国科学技术大学

20. ARMA序列的谱密度和可逆性

$$\{Y_k\} \text{ 绝对可和} \Rightarrow f(\lambda) = \frac{1}{2\pi} \sum_{k=-\infty}^{\infty} Y_k e^{-ik\lambda} = \frac{\sigma^2}{2\pi} \left| \sum_{j=0}^{\infty} \psi_j e^{ij\lambda} \right|^2 = \frac{\sigma^2}{2\pi} \left| \frac{B(e^{i\lambda})}{A(e^{i\lambda})} \right|^2.$$

若 $B(z) = 1 + \sum_{j=1}^q b_j z^j \neq 0, |z| \leq 1$. 则称 ARMA(p, q) 模型(*) 为可逆的 ARMA 模型.

相应的平稳解为可逆的 ARMA(p, q) 序列.

对于上述可逆的 ARMA(p, q) 模型, 由于 $B^{-1}(z)A(z)$ 在 $|z| \leq 1$ ($|z| < 1$) 内解析.

所以有 Taylor 展式 $B^{-1}(z)A(z) = \sum_{j=0}^{\infty} \psi_j z^j, |z| \leq 1$. 其中 $|\psi_j| = o(\rho^{-j})$, 当 $j \rightarrow \infty$.

因此定义 $B^{-1}(B)A(B) = \sum_{j=0}^{\infty} \psi_j B^j$. 则 $\varepsilon_t = B^{-1}(B)A(B)X_t = \sum_{j=0}^{\infty} \psi_j X_{t-j}, t \in \mathbb{Z}$.

此式为 $X_t = \sum_{j=0}^{\infty} \psi_j \varepsilon_{t-j}$ 的逆形式, 表明可逆 ARMA(p, q) 序列及其噪声序列

可以相互线性表示.

21. ARIMA(p, d, q) 模型和 SARIMA 模型.

ARIMA: 设 d 是一个整数, 如果 $Y_t = (1-B)^d X_t = \sum_{k=0}^d C_k^{(d)} (-1)^k X_{t+k}, t \in \mathbb{Z}$, 是一个 ARMA(p, q)

序列, 其模型 MA 部分的特征多项式没有等于 1 的特征根, 则称 $\{X_t\}$ 是一个求和

ARIMA(p, d, q) 序列, 简称为 ARIMA(p, d, q) 序列. 于是 ARIMA(p, d, q) 序列满足

的模型是 $A(B)(1-B)^d X_t = B(B)\varepsilon_t, t \in \mathbb{Z}$. $A(z) = 1 - \sum_{j=1}^p a_j z^j \neq 0, |z| \leq 1$;

$$B(z) = \sum_{j=0}^q b_j z^j \neq 0, |z| < 1.$$

SARIMA: 设 d 和 D 是非负整数, 若差分方程 $Y_t \triangleq (1-B)^d (1-B^s)^D X_t$ 是因果 ARMA 过程

$\phi(B)\Phi(B^s)Y_t = \theta(B)\Theta(B^s)\varepsilon_t, \{\varepsilon_t\} \sim WN(0, \sigma^2)$, 则称 $\{X_t\}$ 是周期为 s 的季节

ARIMA(p, d, q) \times (P, D, Q)_s 过程. 其中 $\phi(z) = 1 - \phi_1 z - \dots - \phi_p z^p$, $\Phi(z) = 1 - \Phi_1 z -$

$$\dots - \Phi_p z^p, \theta(z) = 1 + \theta_1 z + \dots + \theta_q z^q, \Theta(z) = 1 + \Theta_1 z + \dots + \Theta_Q z^Q.$$



中国科学技术大学

22. 白噪声检验: 为了判断一个平稳序列中是否含有信息, 是否可以继续分析, 需要对该序列进行白噪声检验. 该检验用到的统计量是 χ^2 分布, 原假设 $H_0: \{X_t\}$ 是独立白噪声.

样本自相关置信区间检验: 若 $\{X_t\}$ 为独立同分布白噪声时 $\sqrt{n}(\hat{\rho}_1, \hat{\rho}_2, \dots, \hat{\rho}_m)$ 近似服从 $N_m(0, I_m)$. 则 $Pr(\sqrt{n}|\hat{\rho}_k| > 1.96) \approx 0.05$. 若超过 5% 的 $|\hat{\rho}_j| \geq \frac{1.96}{\sqrt{n}}$, 否定 H_0 .

23. 最佳线性预测: 设 Y 和 $X_j (1 \leq j \leq n)$ 是均值为 0, 方差有限的随机变量. 记 $X = (X_1, \dots, X_n)^T$. 若 $a \in \mathbb{R}^n$, 使得对任何 $b \in \mathbb{R}^n$ 都有 $E(Y - a^T X)^2 \leq E(Y - b^T X)^2$, 则称 $a^T X$ 是用 X_1, \dots, X_n 对 Y 进行预测的最佳线性预测, 记作 \hat{Y} 或 $L(Y|X)$. 当 $Y = a^T X$ 时, $Y - \hat{Y} = Y - a^T X$ 为预测误差, $E(Y - \hat{Y})^2 = E(Y - a^T X)^2$ 是预测的均方误差. 若 $EY = b$, $EX = \mu$, 则 $L(Y|X) = L(Y - b | X - \mu) + b$.

以下用 $L_n = \overline{SP}(X_1, \dots, X_n)$ 表示随机 r.v. X_1, X_2, \dots, X_n 的线性组合全体.

24. 决定性与非决定性平稳序列: 设 $\{X_{n+m}\}_{m=0}^{\infty}$ 是零均值平稳序列. 记 $X_{n,m} = \hat{X}_{n+m} = L(X_{n+1}, \dots, X_{n+m})$, m 表示向量维数. 定义 $\hat{X}_{n+1,m} = L(X_{n+1} | X_{n,m})$ 及 $\sigma_{1,m}^2 = E(X_{n+1} - \hat{X}_{n+1,m})^2$.

$\lim_{m \rightarrow \infty} \sigma_{1,m}^2 < \infty$. 若 $\sigma_1^2 = 0$, 称 $\{X_t\}$ 是决定性平稳序列; 若 $\sigma_1^2 > 0$, 称 $\{X_t\}$ 是非决定性平稳序列. 并且称 $\sigma_1^2 = \lim_{m \rightarrow \infty} \sigma_{1,m}^2$ 为 $\{X_t\}$ 的一步预测的均方误差.

设 $\{X_t\}$ 是非决定性的平稳序列, 如果 $\lim_{k \rightarrow \infty} \sigma_k^2 = 0$, 就称 $\{X_t\}$ 是纯非决定性的. (怎么写? 见试卷)



中国科学技术大学

25. 平稳序列的递推序列: 设 $\{X_t\}$ 是零均值平稳序列, 对任何 $n \in \mathbb{N}_+$, 自协方差矩阵 Γ_n 正定, 则最佳线性预测 $\hat{X}_{n+1} \stackrel{\text{def}}{=} L(X_{n+1} | \vec{X}_n) = \sum_{j=1}^n \theta_{n,j} Z_{n+1-j}$, $n=1, 2, \dots$. 其中 $\vec{X}_n = (X_1, X_2, \dots, X_n)^T$, $Z_n = X_n - L(X_n | \vec{X}_{n-1})$, 系数 $\{\theta_{n,j}\}$ 和预测的均方误差 $V_n = E Z_{n+1}^2$ 满足如下的递推公式

$$\begin{cases} V_0 = Y_0, \\ \theta_{n,n+k} = [Y_{n+k} - \sum_{j=0}^{k-1} \theta_{k,k-j} \theta_{n,n-j} V_j] / V_k, \quad 0 \leq k \leq n-1, \\ V_n = Y_0 - \sum_{j=0}^{n-1} \theta_{n,n-j}^2 V_j, \quad \text{其中 } \sum_{j=0}^{\infty} (\cdot) \stackrel{\text{def}}{=} 0. \end{cases}$$

递推的顺序是

$$V_0 \rightarrow \theta_{1,1} \rightarrow V_1 \rightarrow \theta_{2,2}, \theta_{2,1} \rightarrow V_2 \rightarrow \theta_{3,3}, \theta_{3,2}, \theta_{3,1} \rightarrow V_3 \rightarrow \dots$$

$Z_n = X_n - L(X_n | \vec{X}_{n-1})$ 和 \vec{X}_{n-1} 正交是不被 \vec{X}_{n-1} 包含的信息. 因此 Z_n 称为样本新息.

26. AR(p) 序列的预测: 设 $\{X_t\}$ 满足 AR(p) 序列 $X_t = a_1 X_{t-1} + \dots + a_p X_{t-p} + \varepsilon_t = \sum_{j=1}^p a_j X_{t-j} + \varepsilon_t$, $t \in \mathbb{Z}$. 其中 $\{\varepsilon_t\}$ 是白噪声. 特征多项式 $A(z) = 1 - \sum_{j=1}^p a_j z^j \neq 0, |z| \leq 1$.

(i) 用 \vec{X}_n 预测 X_{n+1} : 对于 $1 \leq n \leq p-1$, $\hat{X}_{n+1} = L(X_{n+1} | \vec{X}_n) = \vec{Y}_n^T \Gamma_n^{-1} \vec{X}_n$, Γ_n 是 $\{X_t\}$ 的 n 阶自协方差矩阵, $\vec{Y}_n = (Y_n, Y_{n-1}, \dots, Y_1)^T$. 预测的均方误差为 $E(X_{n+1} - \hat{X}_{n+1})^2 = Y_0 - \vec{Y}_n^T \Gamma_n^{-1} \vec{Y}_n$.

对于 $n \geq p$, $\hat{X}_{n+1} = L(X_{n+1} | X_n, X_{n-1}, \dots, X_{n-p+1}) = \sum_{j=1}^p a_j X_{n+1-j}$.

(ii) 用 \vec{X}_n 预测 X_{n+k} : $L(X_{n+k} | \vec{X}_n) = \sum_{j=1}^p a_j L(X_{n+k-j} | \vec{X}_n, X_{n-1}, \dots, X_{n-p+1})$.



中国科学技术大学

J 27. MA(8)序列的预测: $\{\varepsilon_t\}$ 是 $WN(0, \sigma^2)$. 实系数多项式 $B(z) = 1 + b_1 z + \dots + b_8 z^8$

在单位圆内无根: $B(z) \neq 0, |z| < 1$. $\{X_t\}$ 满足 MA(8) 模型 $X_t = B(B)\varepsilon_t, t \in \mathbb{Z}$.

$L_n = \overline{\text{sp}}\{X_1, X_2, \dots, X_n\} = \overline{\text{sp}}\{\hat{\varepsilon}_1, \hat{\varepsilon}_2, \dots, \hat{\varepsilon}_n\}$. $\hat{\varepsilon}_n = X_n - L(X_n | \bar{X}_n)$ 是 $\{X_t\}$ 的逐步预测误差, $\bar{X}_n = (X_1, \dots, X_n)^T$. 以下 $n \geq 8$.

对 X_{n+1} 的预测: $L(X_{n+1} | \bar{X}_n) = [L] \sum_{j=1}^8 \theta_{n,j} \hat{\varepsilon}_{n+1-j}$, 预测的均方误差为 $V_n = E\hat{\varepsilon}_{n+1}^2 = \gamma_0 - \sum_{j=1}^8 \theta_{n,j}^2 V_{n,j}$, $\theta_{n,j}, V_n$ 由 25 中表达式递推计算.

对 X_{n+k+1} 的预测: $L(X_{n+k+1} | \bar{X}_n) = \begin{cases} \sum_{j=k+1}^8 \theta_{n+k,j} \hat{\varepsilon}_{n+k+1-j}, & 1 \leq k \leq 7, \\ 0, & k \geq 8 \end{cases}$ 预测的

均方误差 $E[X_{n+k+1} - L(X_{n+k+1} | \bar{X}_n)]^2 = \gamma_0 - \sum_{j=k+1}^8 \theta_{n+k,j}^2 V_{n+k-j}, 1 \leq k \leq 7$. 其中 $\theta_{n+k,j}, V_{n+k-j}$ 由 25 中表达式递推得到.

J 28. ARMA(p, 8)序列的预测: 对 ARMA(p, 8) 序列 $\{X_t\}$, X_t 满足 $A(B)X_t = B(B)\varepsilon_t$,

$A(z) = 1 - a_1 z - \dots - a_p z^p$, $B(z) = 1 + b_1 z + \dots + b_8 z^8$. 定义 $\{X_t\}$ 的逐步预测误差

$z_t = X_t - L(X_t | X_{t-1}), z_1 = X_1$. 则

$\hat{X}_{n+1} = \begin{cases} \sum_{j=1}^n \theta_{n,j} z_{n+1-j}, & 1 \leq n \leq m \\ \sum_{j=1}^p a_j X_{n+1-j} + \sum_{j=1}^8 \theta_{n,j} z_{n+1-j}, & n \geq m \end{cases}$, 预测的均方误差 $Ez_{n+1}^2 = \sigma^2 V_n$.



$$\sqrt{N}(\hat{a}_1 - a_1, \dots, \hat{a}_p - a_p)^T \xrightarrow{P} N(0, \sigma^2 \Gamma_p^{-1})$$

中国科学技术大学

29. AR(p)模型的Yule-Walker估计: AR(p)模型 $X_t = \sum_{j=1}^p a_j X_{t-j} + \varepsilon_t, t \geq 0$, $\varepsilon_t^2 = E\varepsilon_t^2$.
已知, 考虑回归系数 $\vec{a} = (a_1, a_2, \dots, a_p)^T$ 和零均值白噪声 $\{\varepsilon_t\}$ 的方差估计问题.

由观测样本 x_1, x_2, \dots, x_N 可以构造出样本自协方差函数的估计: $\hat{\gamma}_k = \frac{1}{N} \sum_{t=k}^N y_t y_{t-k}$, $k=0, 1, 2, \dots, p$. 其中 $y_t = x_t - \bar{x}_N, t=1, 2, \dots, N, \bar{x}_N = \frac{1}{N} \sum_{j=1}^N x_j$. 因此AR(p)的自回归系数和白噪声方差的矩估计 $(\hat{a}_1, \hat{a}_2, \dots, \hat{a}_p)^T, \hat{\sigma}^2$ 由样本Yule-Walker方程

$$\begin{bmatrix} \hat{\gamma}_1 \\ \hat{\gamma}_2 \\ \vdots \\ \hat{\gamma}_p \end{bmatrix} = \begin{bmatrix} \hat{\gamma}_0 & \hat{\gamma}_1 & \dots & \hat{\gamma}_{p-1} \\ \hat{\gamma}_1 & \hat{\gamma}_0 & \dots & \hat{\gamma}_{p-2} \\ \vdots & \vdots & \ddots & \vdots \\ \hat{\gamma}_{p-1} & \hat{\gamma}_{p-2} & \dots & \hat{\gamma}_0 \end{bmatrix} \begin{bmatrix} \hat{a}_1 \\ \hat{a}_2 \\ \vdots \\ \hat{a}_p \end{bmatrix} \text{ 和 } \hat{\sigma}^2 = \hat{\gamma}_0 - (\hat{a}_1 \hat{\gamma}_1 + \dots + \hat{a}_p \hat{\gamma}_p) \text{ 决定.}$$

另外, 还可以采用 Levinson递推方法:

$$\begin{cases} \hat{\sigma}_0^2 = \hat{\gamma}_0 \\ \hat{a}_{k+1,1} = \hat{\gamma}_1 / \hat{\sigma}_k^2 \\ \hat{\sigma}_{k+1}^2 = \hat{\sigma}_k^2 (1 - \hat{a}_{k+1,k}^2) \\ \hat{a}_{k+1,k+1} = \frac{\hat{\gamma}_{k+1} - \hat{\gamma}_k \hat{a}_{k,1} - \hat{\gamma}_{k-1} \hat{a}_{k,2} - \dots - \hat{\gamma}_1 \hat{a}_{k,k}}{\hat{\gamma}_0 - \hat{\gamma}_1 \hat{a}_{k,1} - \hat{\gamma}_2 \hat{a}_{k,2} - \dots - \hat{\gamma}_k \hat{a}_{k,k}} \\ \hat{a}_{k+1,j} = \hat{a}_{k,j} - \hat{a}_{k+1,k+1} \hat{a}_{k,k+1-j}, 1 \leq j \leq k, k \leq p. \end{cases}$$

递推最后得到矩估计 $(\hat{a}_1, \hat{a}_2, \dots, \hat{a}_p) = (\hat{a}_{p,1}, \hat{a}_{p,2}, \dots, \hat{a}_{p,p}), \hat{\sigma}^2 = \hat{\sigma}_p^2$.

上述矩估计又被称为 Yule-Walker 估计.

以下写出带「」标号部分的简化形式 (即 n, p 取 1, 2 等较小数值的情形)



中国科学技术大学

12.J: Levinson 递推公式: 当 n 取 2 时, 对 $1 \leq k \leq 2$ 有

$$\begin{cases} a_{1,1} = y_1/y_0 \\ \sigma_0^2 = y_0 \\ \sigma_1^2 = \sigma_0^2(1 - a_{1,1}^2) = \frac{(y_0 - y_1)^2}{y_0} \end{cases}$$

其他具体推导如下. $a_{2,2} = \frac{y_2 - y_1 a_{1,1}}{y_0 - y_1 a_{1,1}} = \frac{y_2 y_0 - y_1^2}{y_0^2 - y_1^2}$, $a_{2,1} = a_{1,1} - a_{2,2} \cdot a_{1,1} =$
 $y_1/y_0 - \frac{y_2 y_0 - y_1^2}{y_0^2 - y_1^2} \cdot \frac{y_1}{y_0} = \frac{y_1}{y_0} \cdot \frac{y_0^2 - y_2 y_0}{y_0^2 - y_1^2} = \frac{y_1(y_0 - y_2)}{y_0 - y_1}$, $\sigma_2^2 = \sigma_1^2(1 - a_{2,2}^2) = \frac{(y_0 - y_1)^2}{y_0}$.

$$\left[1 - \frac{(y_1^2 - y_2 y_0)^2}{(y_0^2 - y_1^2)^2} \right] = \frac{y_0 - y_2}{y_0 - y_1} \cdot \frac{y_0^2 - y_1^2 + y_2 y_0 - y_1^2}{y_0 + y_1}, \quad a_{3,3} = \frac{y_3 - y_2 a_{2,1} - y_1 a_{2,2}}{y_0 - y_1 a_{2,1} - y_2 a_{2,2}}$$

$$= \frac{y_3 - y_2 \cdot \frac{y_1(y_0 - y_2)}{y_0 - y_1} - y_1 \cdot \frac{y_2 y_0 - y_1^2}{y_0 - y_1}}{y_0 - y_1 \cdot \frac{y_1(y_0 - y_2)}{y_0 - y_1} - y_2 \cdot \frac{y_2 y_0 - y_1^2}{y_0 - y_1}} = \frac{y_0(y_3 - 2y_1 y_2) + y_1(y_1^2 + y_2^2 - y_3)}{y_0(y_0 - y_1 - y_2^2 - y_1^2) + 2y_1^2 y_2}$$

$$a_{3,2} = a_{2,2} - a_{3,3} \cdot a_{2,1} = \frac{y_2 y_0 - y_1^2}{y_0^2 - y_1^2} - \frac{y_0(y_3 - 2y_1 y_2) + y_1(y_1^2 + y_2^2 - y_3)}{y_0(y_0 - y_1 - y_2^2 - y_1^2) + 2y_1^2 y_2} \cdot \frac{y_1(y_0 - y_2)}{y_0 - y_1}$$

$$a_{3,1} = a_{2,1} - a_{3,3} \cdot a_{3,2} \quad (\text{下略}).$$

19. ARMA(p, q) 序列: $X_t - a_1 X_{t-1} - a_2 X_{t-2} - \dots - a_p X_{t-p} = b_0 \varepsilon_t + b_1 \varepsilon_{t-1} + b_2 \varepsilon_{t-2} + \dots + b_q \varepsilon_{t-q}$

是一个滑动自回归平均 model, 简称为 ARMA(p, q) 模型. 称满足上式的平稳序列

$\{X_t\}$ 为 ARMA(p, q) 序列.

$\exists p > 1, B^{-1}(z) B(z)$ 在 $|z| \leq p$ 内解析. 从而有 Taylor 展式由 $\sum_{j=0}^{\infty} \psi_j z^j, |z| \leq p$.

ψ_j 称为 $\{X_t\}$ 的 Wold 系数.



中国科学技术大学

$$\rightarrow X_t = a_1 X_{t-1} + a_2 X_{t-2} + b_0 \varepsilon_t + b_1 \varepsilon_{t-1} + b_2 \varepsilon_{t-2}$$

19. 计算 Wold 系数的递推方法: 对 ARMA(2,2) 模型, 即 $p=2, q=2$.

$$\text{则 } \psi_j = 1, j=0. \quad j=1 \text{ 时, } \psi_j = b_j + \sum_{k=1}^p a_k \psi_{j-k} = b_1 + \sum_{k=1}^2 a_k \psi_{j-k} = b_1 + a_1 \psi_0 = b_1 + a_1.$$

$$j=2 \text{ 时, } \psi_j = b_2 + \sum_{k=1}^2 a_k \psi_{j-k} = b_2 + a_1 \psi_1 + a_2 \psi_0 = b_2 + a_1(b_1 + a_1) + a_2 = a_1(a_1 + b_1) + a_2 + b_2.$$

$$\text{若 } j \geq 3, \text{ 则 } \psi_j = a_1 \psi_{j-1} + a_2 \psi_{j-2}.$$

对更简单的 ARMA(2,1) 模型, $p=2, q=1$. $\psi_j = 1, j=0$. $\psi_1 = b_1 + a_1 \psi_0 = a_1 + b_1$.

$$\text{对 } j \geq 2, \psi_2 = b_2 + \sum_{k=1}^2 a_k \psi_{2-k} = a_1 \psi_1 + a_2 \psi_0. \text{ 而对 } j \geq 3, \psi_j = a_1 \psi_{j-1} + a_2 \psi_{j-2}.$$

最简单的 ARMA(1,1) 模型, $p=1, q=1$. $\psi_0 = 1$. $\psi_1 = b_1 + a_1 \psi_0 = b_1 + a_1$.

$$\psi_j = a_1 \psi_{j-1} = \dots = a_1^{j-1} \psi_1 = a_1^{j-1} (a_1 + b_1), \quad j=2, 3, 4, \dots$$

25. 对 $n=2$ 的情形: $\hat{X}_2 \stackrel{\text{def}}{=} L(X_3 | \vec{X}_2) = L(X_3 | X_1, X_2) = \sum_{j=1}^2 \theta_{n,j} Z_{3-j}$, $Z_2 = X_2 - L(X_2 | X_1)$. $\{\theta_{n,j}\}$, $\nu_n = E Z_{n+1}^2$ 满足如下公式:

$$\begin{aligned} \nu_0 &= \gamma_0, \quad \theta_{1,1} = \gamma_1 / \nu_0 = \gamma_1 / \gamma_0, \quad \nu_1 = \gamma_0 - \theta_{1,1}^2 \nu_0 = \gamma_0 - \gamma_1^2 / \gamma_0, \quad \theta_{2,1} = \\ &= (\gamma_1 - \theta_{1,1} \theta_{2,2} \nu_0) / \nu_1 = \gamma_1 (\gamma_0 - \gamma_2) / (\gamma_0^2 - \gamma_1^2), \quad \nu_2 = \gamma_0 - \sum_{j=0}^1 \theta_{2,2-j}^2 \nu_j = \gamma_0 - (\theta_{2,2}^2 \nu_0 + \theta_{2,1}^2 \nu_1) \\ &= \gamma_0 - \frac{\gamma_2^2}{\gamma_0} + \frac{\gamma_1^2 (\gamma_0 - \gamma_2)^2}{(\gamma_0^2 - \gamma_1^2) \gamma_0}. \end{aligned}$$

26. AR(p) 模型的预测: 以下讨论 $p=1$ 和 $p=2$ 两种特殊情况.

(1) AR(1) 模型: $X_t - a_1 X_{t-1} = \varepsilon_t$, $|a_1| < 1$, $\varepsilon_t \sim WN(0, \sigma^2)$, $\gamma_0 = \frac{\sigma^2}{1-a_1^2}$, $\gamma_k = a_1^k \gamma_0$.

$$\rho_k = \frac{\gamma_k}{\gamma_0} = a_1^k.$$

1101C-08 201412-2500



中国科学技术大学

(何书元书方法废弃, 改用李东风《金融时间讲义》)

AR(p) 模型: $X_t = \phi_0 + \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + \varepsilon_t$. 在时刻 h , 用截止到 h 时刻的信息 (即 X_1, \dots, X_h 已知) 预测 X_{h+l} . 得到的最佳预测记为 $\hat{X}_h(l)$.

对 $l=1$. 因为 $X_{h+1} = \phi_0 + \phi_1 X_h + \dots + \phi_p X_{h+1-p} + \varepsilon_{h+1}$; 以及 $E(\varepsilon_{h+1} | X_1, \dots, X_h) = 0$. 因此有 $\hat{X}_h(1) = E(X_{h+1} | X_1, \dots, X_h) = \phi_0 + \phi_1 X_h + \dots + \phi_p X_{h+1-p}$. 一步预测误差为 $e_h(1) = X_{h+1} - \hat{X}_h(1) = \varepsilon_{h+1}$. $\text{Var}(e_h(1)) = \sigma^2$. 若 ε_t 服从正态分布, 则 X_{h+1} 的超前一步预测的 95% 预测区间为 $\hat{X}_h(1) \pm 1.96\sigma$.

对 $l=2$. 注意到 $X_{h+2} = \phi_0 + \phi_1 X_{h+1} + \dots + \phi_p X_{h+2-p} + \varepsilon_{h+2}$. 因此 $\hat{X}_h(2) = E(X_{h+2} | X_1, \dots, X_h) = \phi_0 + \phi_1 E(X_{h+1} | X_1, \dots, X_h) + \phi_2 X_h + \dots + \phi_p X_{h+2-p} = \phi_0 + \phi_1 \hat{X}_h(1) + \phi_2 X_h + \dots + \phi_p X_{h+2-p}$. 预测误差为 $e_h(2) = X_{h+2} - \hat{X}_h(2) = \phi_1 e_h(1) + \varepsilon_{h+2}$. 预测均方误差为 $E(e_h(2))^2 = \text{Var}(e_h(2)) = \sigma^2(1 + \phi_1^2)$ ($\varepsilon_{h+2} \perp e_h(1) = X_{h+1} - \hat{X}_h(1)$).

对一般的 $l \in \mathbb{N}^+$, 有 $\hat{X}_h(l) = \phi_0 + \sum_{j=1}^p \phi_j \hat{X}_h(l-j)$, 其中 $\hat{X}_h(i) = \begin{cases} X_{h+i}, & i \leq 0 \\ \hat{X}_h(i), & i > 0 \end{cases}$.

为计算 $\hat{X}_h(l)$, 只要递推计算 $\hat{X}_h(1), \dots, \hat{X}_h(l-1)$, 再按上面的公式得到 $\hat{X}_h(l)$. 超前 l 步的预测误差为 $e_h(l) = X_{h+l} - \hat{X}_h(l)$. 对平稳 AR(p) 模型, 当超前步数 $l \rightarrow +\infty$ 时, $\hat{X}_h(l) \rightarrow \mu$. 这种收敛性质称为均值回转.

对 AR(1) 模型的零均值平稳解 $\{X_t\}$, $\hat{X}_h(l) = \phi_1^l X_h$.

1101C-08 201412-2500



扫描全能王 创建

中国科学技术大学

MA(8)模型, $X_t = \theta_0 + \varepsilon_t + \sum_{k=1}^8 \theta_k \varepsilon_{t-k}$. 由于MA(8)序列在间隔超过8步后独立, 因此超前多步预测, 只能预测到8步, 从8+1步开始就只能用 θ_0 预测.

例1: 对MA(1)模型 $X_t = \theta_0 + \varepsilon_t + \theta_1 \varepsilon_{t-1}$, $\{\varepsilon_t\} \sim WN(0, \sigma^2)$.

对 $l=1$, $\hat{X}_h(1) = E(X_{h+1} | x_1, \dots, x_h) = \theta_0 + \theta_1 \varepsilon_h$, 这里利用 $E(\varepsilon_{h+1} | x_1, \dots, x_h) = 0$.

$$e_h(1) = X_{h+1} - \hat{X}_h(1) = \varepsilon_{h+1}, \text{var}(e_h(1)) = \sigma^2.$$

对 $l=2$, $\hat{X}_h(2) = E(\theta_0 + \varepsilon_{h+2} + \theta_1 \varepsilon_{h+1} | x_1, \dots, x_h) = \theta_0$. 从两步开始的超前多步预测

就变成 $E X_t = \theta_0$. 因此对 $k \geq 2$, $e_h(k) = X_{h+k} - \hat{X}_h(k) = \varepsilon_{h+k} + \theta_1 \varepsilon_{h+k-1}$, $\text{var}(e_h(k)) = (1 + \theta_1^2) \sigma^2$.

eg2: 对MA(2)模型 $X_t = \theta_0 + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2}$, $\hat{X}_h(1) = \theta_0 + \theta_1 \varepsilon_h + \theta_2 \varepsilon_{h-1}$ ($E(\varepsilon_{h+1} | x_1, \dots, x_h) = 0$).

$\hat{X}_h(2) = \theta_0 + \theta_2 \varepsilon_h$ ($E(\varepsilon_{h+2} | x_1, \dots, x_h) = E(\varepsilon_{h+2} | x_h, \dots, x_1) = 0$). 对 $l \geq 3$, $\hat{X}_h(l) = \theta_0 = E X_t$.

因此 $e_h(1) = X_{h+1} - \hat{X}_h(1) = \varepsilon_{h+1}$, $E(X_{h+1} - \hat{X}_h(1))^2 = \text{var}(e_h(1)) = \sigma^2$;

$e_h(2) = X_{h+2} - \hat{X}_h(2) = \varepsilon_{h+2} + \theta_1 \varepsilon_{h+1}$, $E(X_{h+2} - \hat{X}_h(2))^2 = \text{var}(e_h(2)) = (1 + \theta_1^2) \sigma^2$.

对 $l \geq 3$, $e_h(l) = X_{h+l} - \hat{X}_h(l) = \varepsilon_{h+l} + \theta_1 \varepsilon_{h+l-1} + \theta_2 \varepsilon_{h+l-2}$, $E(X_{h+l} - \hat{X}_h(l))^2 =$

$$\text{var}(e_h(l)) = (1 + \theta_1^2 + \theta_2^2) \sigma^2.$$

对MA(8)模型 $X_t = \theta_0 + \varepsilon_t + \sum_{k=1}^8 \theta_k \varepsilon_{t-k}$, 可由归纳法得到如下结论:

(i) 对 $1 \leq l \leq 8$, $\hat{X}_h(l) = \theta_0 + \sum_{k=l}^8 \theta_k \varepsilon_{h+l-k}$; 对 $l > 8$, $\hat{X}_h(l) = \theta_0$;

(ii) $e_h(l) = X_{h+l} - \hat{X}_h(l) = X_{h+l} - \hat{X}_h(l)$. 因此对 $1 \leq l \leq 8$, $e_h(l) = \varepsilon_{h+l} + \sum_{k=1}^{l-1} \theta_k \varepsilon_{h+l-k}$ (定 $\sum_{k=1}^8 \theta_k \neq 0$); 对 $l > 8$, $e_h(l) = \varepsilon_{h+l} + \sum_{k=1}^8 \theta_k \varepsilon_{h+l-k}$;



中国科学技术大学

(iii) $E(X_{h+l} - \hat{X}_{h+l})^2 = \text{var}(e_h(l))$. 因此对 $1 \leq l \leq q$, $\text{var}(e_h(l)) = \text{var}(\xi_{h+l} + \sum_{k=1}^{l-1} \theta_k \xi_{h+l-k})$
 $= \sigma^2(1 + \sum_{k=1}^{l-1} \theta_k^2)$ (定义 $\sum_{k=1}^{-1} (-) = 0$, 当 $l < 1$ 时); 对 $l > q$, $\text{var}(e_h(l)) = \text{var}(\xi_{h+l} + \sum_{k=1}^q \theta_k \xi_{h+l-k})$
 $= \sigma^2(1 + \sum_{k=1}^q \theta_k^2)$. (2018~2019, 第-学期, 第四题).

ARMA(p, q)模型: ARMA(p, q)的预测都有关系. 对AR部分仍是递推地向前预测, 对MA部分需估计新息 ε_t 的值.

对ARMA模型 $X_t - \sum_{k=1}^p a_k X_{t-k} = \varepsilon_t + \sum_{j=1}^q b_j \varepsilon_{t-j}$, $\{\varepsilon_j\} \sim WN(0, \sigma^2)$. $(A(B)X_t = B(B)\varepsilon_t, A(z) = 1 - \sum_{k=1}^p a_k z^k, B(z) = 1 + \sum_{j=1}^q b_j z^j$

(i) 超前一步预测: $\hat{X}_h(1) = \phi_0 + \sum_{j=1}^p \phi_j \hat{X}_{h+1-j} + \sum_{j=1}^q \theta_j \hat{\varepsilon}_{h+1-j}$, 其中 $\hat{\varepsilon}_i = E(\varepsilon_i | X_1, \dots, X_h)$

(ii) 对超前 k 步预测: $\hat{X}_h(k) = \phi_0 + \sum_{j=1}^p \phi_j \hat{X}_{h+k-j} + \sum_{j=1}^q \theta_j \hat{\varepsilon}_{h+k-j}$, 其中 $h+k-j \leq h$ 时 $\hat{X}_{h+k-j} = X_{h+k-j}$, $h+k-j > h$ 时 $\hat{\varepsilon}_{h+k-j} = 0$. 预测误差为 $e_h(k) = X_{h+k} - \hat{X}_{h+k}$.

