

应用时间序列分析 课程介绍

主讲老师：席瑞斌

本课件基于李东风老师课件修改

2017年秋季学期

- ▶ 设 X_1, X_2, \dots, X_n, Y 为随机变量。考虑估计问题

$$L(Y|X_1, \dots, X_n) \triangleq \arg \min_{\hat{Y} = a_0 + a_1 X_1 + \dots + a_n X_n} E(Y - \hat{Y})^2$$

称 $L(Y|X_1, \dots, X_n)$ 为 Y 关于 X_1, \dots, X_n 的最优线性估计。

- ▶ $L(Y|X_1, \dots, X_n)$ 是 Y 在空间 $\mathcal{L}(1, X_1, \dots, X_n)$ 上的投影。
- ▶ 下面推导 $L(Y|X_1, \dots, X_n)$ 的公式。

本课件基于李东风
老师课件修改

平稳序列的偏相关
系数和Levinson递
推公式

最优线性预测

最小相位性

Levinson递推公式

偏相关系数

AR(p)序列举例

- ▶ 设 X_1, X_2, \dots, X_n, Y 为随机变量。考虑估计问题

$$L(Y|X_1, \dots, X_n) \triangleq \arg \min_{\hat{Y} = a_0 + a_1 X_1 + \dots + a_n X_n} E(Y - \hat{Y})^2$$

称 $L(Y|X_1, \dots, X_n)$ 为 Y 关于 X_1, \dots, X_n 的最优线性估计。

- ▶ $L(Y|X_1, \dots, X_n)$ 是 Y 在空间 $\mathcal{L}(1, X_1, \dots, X_n)$ 上的投影。
- ▶ 下面推导 $L(Y|X_1, \dots, X_n)$ 的公式。

本课件基于李东风
老师课件修改

平稳序列的偏相关
系数和Levinson递
推公式

最优线性预测

最小相位性

Levinson递推公式

偏相关系数

AR(p)序列举例

- ▶ 设 X_1, X_2, \dots, X_n, Y 为随机变量。考虑估计问题

$$L(Y|X_1, \dots, X_n) \triangleq \arg \min_{\hat{Y} = a_0 + a_1 X_1 + \dots + a_n X_n} E(Y - \hat{Y})^2$$

称 $L(Y|X_1, \dots, X_n)$ 为 Y 关于 X_1, \dots, X_n 的最优线性估计。

- ▶ $L(Y|X_1, \dots, X_n)$ 是 Y 在空间 $\mathcal{L}(1, X_1, \dots, X_n)$ 上的投影。
- ▶ 下面推导 $L(Y|X_1, \dots, X_n)$ 的公式。

本课件基于李东风
老师课件修改

平稳序列的偏相关
系数和Levinson递
推公式

最优线性预测

最小相位性

Levinson递推公式

偏相关系数

AR(p)序列举例

最优线性估计公式

记 $\mathbf{X} = (X_1, \dots, X_n)^T$, 令 $\boldsymbol{\xi} = \mathbf{X} - \mathbf{E}\mathbf{X}$, $\eta = Y - \mathbf{E}Y$ 。

设 $\Sigma_{\mathbf{X}} \triangleq \text{Var}(\mathbf{X}) = \text{Var}(\boldsymbol{\xi})$ 正定。记 $\Sigma_{\mathbf{X}, Y} = \text{Cov}(\mathbf{X}, Y)$ 。

对 $a_0, a_1, \dots, a_n \in R$, 记 $\mathbf{a} = (a_1, \dots, a_n)^T$, 有

$$\begin{aligned} & \mathbf{E}(Y - (a_0 + a_1X_1 + \dots + a_nX_n))^2 \\ &= \mathbf{E}(\eta - (a_1\xi_1 + \dots + a_n\xi_n))^2 + (\mathbf{E}Y - a_0 - \mathbf{a}^T\mathbf{E}\mathbf{X})^2 \end{aligned}$$

已知 a_1, \dots, a_n 后取 $a_0 = \mathbf{E}Y - \mathbf{a}^T\mathbf{E}\mathbf{X}$ 就可以使上式后一项为零, 所以不妨设 $\mathbf{E}\mathbf{X} = 0, \mathbf{E}Y = 0$ 。

最优线性估计公式II

这时

$$\begin{aligned} & E(Y - (a_1X_1 + \dots + a_nX_n))^2 \\ &= \text{Var}(Y) + \mathbf{a}^T \Sigma_{\mathbf{X}} \mathbf{a} - 2\mathbf{a}^T \Sigma_{\mathbf{X}, Y} \end{aligned}$$

令关于 \mathbf{a} 的导数等于零求得最小值点为

$$\mathbf{a} = \Sigma_{\mathbf{X}}^{-1} \Sigma_{\mathbf{X}, Y}$$

估计误差的最小值为

$$E(Y - \mathbf{a}\mathbf{X})^2 = \text{Var}(Y) - \Sigma_{\mathbf{X}, Y}^T \Sigma_{\mathbf{X}}^{-1} \Sigma_{\mathbf{X}, Y}$$

当 $|\Gamma_n| = 0$ 时，最优线性估计也存在(详见第5章)。

平稳序列的最优线性预测

- 设 $\{X_t\}$ 为零均值平稳列。考虑用 X_1, \dots, X_n 的线性组合预测 X_{n+1} 。设 $\Gamma_n > 0$ ，则

$$\begin{aligned}
 & L(X_{n+1}|X_n, X_{n-1}, \dots, X_1) \\
 &= \left[\text{Var} \left(\begin{pmatrix} X_n \\ \vdots \\ X_1 \end{pmatrix} \right)^{-1} \text{Cov} \left(\begin{pmatrix} X_n \\ \vdots \\ X_1 \end{pmatrix}, X_{n+1} \right) \right]^T \begin{pmatrix} X_n \\ \vdots \\ X_1 \end{pmatrix} \\
 &= (\Gamma_n^{-1} \begin{pmatrix} \gamma_1 \\ \gamma_2 \\ \dots \\ \gamma_n \end{pmatrix})^T \begin{pmatrix} X_n \\ \dots \\ X_1 \end{pmatrix} \\
 &\triangleq a_{n1}X_n + a_{n2}X_{n-1} + \dots + a_{nn}X_1 \\
 &\triangleq \mathbf{a}_n^T (X_n, X_{n-1}, \dots, X_1)^T
 \end{aligned}$$

平稳序列的最优线性预测II

- ▶ Yule-Walker方程:

$$\Gamma_n \begin{pmatrix} a_{n1} \\ \vdots \\ a_{nn} \end{pmatrix} = \begin{pmatrix} \gamma_1 \\ \vdots \\ \gamma_n \end{pmatrix}$$

简记为

$$\Gamma_n \mathbf{a}_n = \boldsymbol{\gamma}_n$$

方程的解 \mathbf{a}_n 称为 $\{X_t\}$ 或 $\{\gamma_k\}$ 的 n 阶Yuler-Walker系数。



$$L(X_{n+1}|X_n, \dots, X_1) = \mathbf{a}_n^T(X_n, \dots, X_1)^T$$

- ▶ 由平稳性

$$L(X_t|X_{t-1}, \dots, X_{t-n}) = \mathbf{a}_n^T(X_{t-1}, \dots, X_{t-n})^T$$

平稳序列的最优线性预测II

- ▶ Yule-Walker方程:

$$\Gamma_n \begin{pmatrix} a_{n1} \\ \vdots \\ a_{nn} \end{pmatrix} = \begin{pmatrix} \gamma_1 \\ \vdots \\ \gamma_n \end{pmatrix}$$

简记为

$$\Gamma_n \mathbf{a}_n = \boldsymbol{\gamma}_n$$

方程的解 \mathbf{a}_n 称为 $\{X_t\}$ 或 $\{\gamma_k\}$ 的 n 阶Yuler-Walker系数。



$$L(X_{n+1}|X_n, \dots, X_1) = \mathbf{a}_n^T(X_n, \dots, X_1)^T$$

- ▶ 由平稳性

$$L(X_t|X_{t-1}, \dots, X_{t-n}) = \mathbf{a}_n^T(X_{t-1}, \dots, X_{t-n})^T$$

平稳序列的最优线性预测II

- ▶ Yule-Walker方程:

$$\Gamma_n \begin{pmatrix} a_{n1} \\ \vdots \\ a_{nn} \end{pmatrix} = \begin{pmatrix} \gamma_1 \\ \vdots \\ \gamma_n \end{pmatrix}$$

简记为

$$\Gamma_n \mathbf{a}_n = \boldsymbol{\gamma}_n$$

方程的解 \mathbf{a}_n 称为 $\{X_t\}$ 或 $\{\gamma_k\}$ 的 n 阶Yuler-Walker系数。



$$L(X_{n+1}|X_n, \dots, X_1) = \mathbf{a}_n^T(X_n, \dots, X_1)^T$$

- ▶ 由平稳性

$$L(X_t|X_{t-1}, \dots, X_{t-n}) = \mathbf{a}_n^T(X_{t-1}, \dots, X_{t-n})^T$$

平稳序列的最优线性预测III

应用时间序列分析
课程介绍

主讲老师：席瑞斌

- ▶ 最小的线性预测方差为

$$\begin{aligned}\sigma_n^2 &\triangleq \mathbb{E}(X_{n+1} - (a_{n1}X_{n-1} + \dots + a_{nn}X_1))^2 \\ &= \text{Var}(X_{n+1}) - \gamma_n^T \Gamma_n \gamma_n \\ &= \gamma_0 - \gamma_n^T \mathbf{a}_n \\ &= \gamma_0 - a_{n1}\gamma_1 - \dots - a_{nn}\gamma_n\end{aligned}$$

- ▶ 由平稳性

$$\mathbb{E}(X_t - (a_{n1}X_{t-1} + \dots + a_{nn}X_{t-n}))^2 = \sigma_n^2$$

本课件基于李东风
老师课件修改

平稳序列的偏相关
系数和Levinson递
推公式

最优线性预测

最小相位性

Levinson递推公式

偏相关系数

AR(p)序列举例

平稳序列的最优线性预测III

应用时间序列分析
课程介绍

主讲老师：席瑞斌

- ▶ 最小的线性预测方差为

$$\begin{aligned}\sigma_n^2 &\triangleq \mathbb{E}(X_{n+1} - (a_{n1}X_{n-1} + \dots + a_{nn}X_1))^2 \\ &= \text{Var}(X_{n+1}) - \gamma_n^T \Gamma_n \gamma_n \\ &= \gamma_0 - \gamma_n^T \mathbf{a}_n \\ &= \gamma_0 - a_{n1}\gamma_1 - \dots - a_{nn}\gamma_n\end{aligned}$$

- ▶ 由平稳性

$$\mathbb{E}(X_t - (a_{n1}X_{t-1} + \dots + a_{nn}X_{t-n}))^2 = \sigma_n^2$$

本课件基于李东风
老师课件修改

平稳序列的偏相关
系数和Levinson递
推公式

最优线性预测

最小相位性

Levinson递推公式

偏相关系数

AR(p)序列举例

Yule-Walker系数的最小相位性

应用时间序列分析
课程介绍

主讲老师：席瑞斌

本课件基于李东风
老师课件修改

- ▶ 如果 $\{\gamma_k\}$ 是某AR(p)序列的自协方差函数，则 p 阶的Yule-Walker方程解出的Yule-Walker系数就是AR模型的自回归系数，所以满足最小相位性：

$$A(z) = 1 - \sum_{j=1}^p a_j z^j \neq 0, \quad \text{对}|z| \leq 1$$

平稳序列的偏相关系数和Levinson递推公式

最优线性预测

最小相位性

Levinson递推公式

偏相关系数

AR(p)序列举例

Yule-Walker系数的最小相位性II

- ▶ 对于一般的平稳列有：
- ▶ 定理4.1 如果实数列 $\gamma_k, k = 0, 1, \dots, n$ 使得

$$\Gamma_{n+1} \triangleq \begin{pmatrix} \gamma_0 & \gamma_1 & \cdots & \gamma_n \\ \gamma_1 & \gamma_0 & \cdots & \gamma_{n-1} \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_n & \gamma_{n-1} & \cdots & \gamma_0 \end{pmatrix} > 0$$

则解出的 n 阶Yule-Walker系数 \mathbf{a}_n 满足最小相位条件：

$$1 - \sum_{j=1}^n a_{nj} z^j \neq 0, \quad |z| \leq 1.$$

- ▶ 证明自学。
- ▶ 线性平稳列的自协方差列正定，所以其任意 n 阶Yule-Walker系数都满足最小相位条件。

Yule-Walker系数的最小相位性II

- ▶ 对于一般的平稳列有：
- ▶ **定理4.1** 如果实数列 $\gamma_k, k = 0, 1, \dots, n$ 使得

$$\Gamma_{n+1} \triangleq \begin{pmatrix} \gamma_0 & \gamma_1 & \cdots & \gamma_n \\ \gamma_1 & \gamma_0 & \cdots & \gamma_{n-1} \\ \vdots & \vdots & & \vdots \\ \gamma_n & \gamma_{n-1} & \cdots & \gamma_0 \end{pmatrix} > 0$$

则解出的 n 阶Yuler-Walker系数 \mathbf{a}_n 满足最小相位条件：

$$1 - \sum_{j=1}^n a_{nj} z^j \neq 0, \quad |z| \leq 1.$$

- ▶ 证明自学。
- ▶ 线性平稳列的自协方差列正定，所以其任意 n 阶Yuler-Walker系数都满足最小相位条件。

Yule-Walker系数的最小相位性II

- ▶ 对于一般的平稳列有：
- ▶ **定理4.1** 如果实数列 $\gamma_k, k = 0, 1, \dots, n$ 使得

$$\Gamma_{n+1} \triangleq \begin{pmatrix} \gamma_0 & \gamma_1 & \cdots & \gamma_n \\ \gamma_1 & \gamma_0 & \cdots & \gamma_{n-1} \\ \vdots & \vdots & & \vdots \\ \gamma_n & \gamma_{n-1} & \cdots & \gamma_0 \end{pmatrix} > 0$$

则解出的 n 阶Yule-Walker系数 \mathbf{a}_n 满足最小相位条件：

$$1 - \sum_{j=1}^n a_{nj} z^j \neq 0, \quad |z| \leq 1.$$

- ▶ 证明自学。
- ▶ 线性平稳列的自协方差列正定，所以其任意 n 阶Yule-Walker系数都满足最小相位条件。

Yule-Walker系数的最小相位性II

- ▶ 对于一般的平稳列有：
- ▶ **定理4.1** 如果实数列 $\gamma_k, k = 0, 1, \dots, n$ 使得

$$\Gamma_{n+1} \triangleq \begin{pmatrix} \gamma_0 & \gamma_1 & \cdots & \gamma_n \\ \gamma_1 & \gamma_0 & \cdots & \gamma_{n-1} \\ \vdots & \vdots & & \vdots \\ \gamma_n & \gamma_{n-1} & \cdots & \gamma_0 \end{pmatrix} > 0$$

则解出的 n 阶Yule-Walker系数 \mathbf{a}_n 满足最小相位条件：

$$1 - \sum_{j=1}^n a_{nj} z^j \neq 0, \quad |z| \leq 1.$$

- ▶ 证明自学。
- ▶ 线性平稳列的自协方差列正定，所以其任意 n 阶Yule-Walker系数都满足最小相位条件。

Levinson递推公式

定理4.2 如果 Γ_{n+1} 正定,
则 $\gamma_k, k = 0, 1, \dots, n$ 的 $1, 2, \dots, n, n+1$ 阶Yuler-Walker系
数 $\{a_{ij}, i = 1, \dots, n+1, j = 1, \dots, i\}$ 和均方误差 σ_k^2 可以如
下递推计算:

$$\begin{aligned} \sigma_0^2 &= \gamma_0 \\ a_{1,1} &= \gamma_1 / \gamma_0 \\ \sigma_k^2 &= \sigma_{k-1}^2 (1 - a_{k,k}^2) \\ a_{k+1,k+1} &= \frac{\gamma_{k+1} - a_{k,1}\gamma_k - a_{k,2}\gamma_{k-1} - \dots - a_{k,k}\gamma_1}{\gamma_0 - a_{k,1}\gamma_1 - a_{k,2}\gamma_2 - \dots - a_{k,k}\gamma_k} \\ a_{k+1,j} &= a_{k,j} - a_{k+1,k+1}a_{k,k+1-j}, \quad 1 \leq j \leq k \end{aligned} \quad (4.4)$$

其中

$$\sigma_k^2 = E(X_{k+1} - (a_{k,1}X_{k-1} + \dots + a_{k,k}X_1))^2 \quad (4.5)$$

是用 X_k, X_{k-1}, \dots, X_1 预测 X_{k+1} 的均方误差。

Levinson公式的记忆方法

- ▶ 回忆§2.3中的

$$\gamma_k - \sum_{j=1}^p a_j \gamma_{k-j} = 0, \quad k \geq 1 \quad (\dagger)$$

$$\sigma^2 = \gamma_0 - \sum_{j=1}^p a_j \gamma_{0-j} \quad (\ddagger)$$

- ▶ 在 $a_{k+1,k+1}$ 的递推公式中，想象 $p = k, a_j = a_{k,j}, j = 1, \dots, p$
 - ▶ 则递推公式分子是(\dagger)的左边(用 $k+1$ 代替 k)。
 - ▶ 分母是(\ddagger)的右边。
- ▶ $a_{k+1,j}, 1 \leq j \leq k$ 的公式为

$$\begin{pmatrix} a_{k+1,1} \\ \vdots \\ a_{k+1,k} \end{pmatrix} = \begin{pmatrix} a_{k,1} \\ \vdots \\ a_{k,k} \end{pmatrix} - a_{k+1,k+1} \begin{pmatrix} a_{k,k} \\ \vdots \\ a_{k,1} \end{pmatrix}$$

Levinson公式的记忆方法

- ▶ 回忆§2.3中的

$$\gamma_k - \sum_{j=1}^p a_j \gamma_{k-j} = 0, \quad k \geq 1 \quad (\dagger)$$

$$\sigma^2 = \gamma_0 - \sum_{j=1}^p a_j \gamma_{0-j} \quad (\ddagger)$$

- ▶ 在 $a_{k+1,k+1}$ 的递推公式中，想象 $p = k, a_j = a_{k,j}, j = 1, \dots, p$
 - ▶ 则递推公式分子是(\dagger)的左边(用 $k+1$ 代替 k)。
 - ▶ 分母是(\ddagger)的右边。
- ▶ $a_{k+1,j}, 1 \leq j \leq k$ 的公式为

$$\begin{pmatrix} a_{k+1,1} \\ \vdots \\ a_{k+1,k} \end{pmatrix} = \begin{pmatrix} a_{k,1} \\ \vdots \\ a_{k,k} \end{pmatrix} - a_{k+1,k+1} \begin{pmatrix} a_{k,k} \\ \vdots \\ a_{k,1} \end{pmatrix}$$

Levinson公式的记忆方法

- ▶ 回忆§2.3中的

$$\gamma_k - \sum_{j=1}^p a_j \gamma_{k-j} = 0, \quad k \geq 1 \quad (\dagger)$$

$$\sigma^2 = \gamma_0 - \sum_{j=1}^p a_j \gamma_{0-j} \quad (\ddagger)$$

- ▶ 在 $a_{k+1,k+1}$ 的递推公式中，想象 $p = k, a_j = a_{k,j}, j = 1, \dots, p$
 - ▶ 则递推公式分子是(\dagger)的左边(用 $k+1$ 代替 k)。
 - ▶ 分母是(\ddagger)的右边。
- ▶ $a_{k+1,j}, 1 \leq j \leq k$ 的公式为

$$\begin{pmatrix} a_{k+1,1} \\ \vdots \\ a_{k+1,k} \end{pmatrix} = \begin{pmatrix} a_{k,1} \\ \vdots \\ a_{k,k} \end{pmatrix} - a_{k+1,k+1} \begin{pmatrix} a_{k,k} \\ \vdots \\ a_{k,1} \end{pmatrix}$$

Levinson公式的记忆方法

- ▶ 回忆§2.3中的

$$\gamma_k - \sum_{j=1}^p a_j \gamma_{k-j} = 0, \quad k \geq 1 \quad (\dagger)$$

$$\sigma^2 = \gamma_0 - \sum_{j=1}^p a_j \gamma_{0-j} \quad (\ddagger)$$

- ▶ 在 $a_{k+1,k+1}$ 的递推公式中，想象 $p = k, a_j = a_{k,j}, j = 1, \dots, p$
 - ▶ 则递推公式分子是(\dagger)的左边(用 $k+1$ 代替 k)。
 - ▶ 分母是(\ddagger)的右边。
- ▶ $a_{k+1,j}, 1 \leq j \leq k$ 的公式为

$$\begin{pmatrix} a_{k+1,1} \\ \vdots \\ a_{k+1,k} \end{pmatrix} = \begin{pmatrix} a_{k,1} \\ \vdots \\ a_{k,k} \end{pmatrix} - a_{k+1,k+1} \begin{pmatrix} a_{k,k} \\ \vdots \\ a_{k,1} \end{pmatrix}$$

Levinson公式的记忆方法

- ▶ 回忆§2.3中的

$$\gamma_k - \sum_{j=1}^p a_j \gamma_{k-j} = 0, \quad k \geq 1 \quad (\dagger)$$

$$\sigma^2 = \gamma_0 - \sum_{j=1}^p a_j \gamma_{0-j} \quad (\ddagger)$$

- ▶ 在 $a_{k+1,k+1}$ 的递推公式中，想象 $p = k, a_j = a_{k,j}, j = 1, \dots, p$
 - ▶ 则递推公式分子是(†)的左边(用 $k+1$ 代替 k)。
 - ▶ 分母是(‡)的右边。
- ▶ $a_{k+1,j}, 1 \leq j \leq k$ 的公式为

$$\begin{pmatrix} a_{k+1,1} \\ \vdots \\ a_{k+1,k} \end{pmatrix} = \begin{pmatrix} a_{k,1} \\ \vdots \\ a_{k,k} \end{pmatrix} - a_{k+1,k+1} \begin{pmatrix} a_{k,k} \\ \vdots \\ a_{k,1} \end{pmatrix}$$

- ▶ 关于 σ_k^2 :

$$\begin{aligned}\sigma_k^2 &= E[X_{k+1} - \mathbf{a}_k^T \mathbf{X}_k]^2 \\ &= E[(X_{k+1} - \mathbf{a}_k^T \mathbf{X}_k)X_{k+1}] - E[(X_{k+1} - \mathbf{a}_k^T \mathbf{X}_k)\mathbf{a}_k^T \mathbf{X}_k] \\ &= \gamma_0 - \mathbf{a}_k^T (\gamma_1 \ \dots \ \gamma_k)^T - 0 \\ &= \gamma_0 - a_{k,1}\gamma_1 - \dots - a_{k,k}\gamma_k\end{aligned}$$

- ▶ 这是 $a_{k+1,k+1}$ 的递推公式的分母，所以 $a_{k+1,k+1}$ 的递推公式也可以写成

$$a_{k+1,k+1} = \frac{\gamma_{k+1} - a_{k,1}\gamma_k - a_{k,2}\gamma_{k-1} - \dots - a_{k,k}\gamma_1}{\sigma_k^2}$$

- ▶ 注意 σ_k^2 是用 k 个预报第 $k+1$ 个的均方误差。

- ▶ 关于 σ_k^2 :

$$\begin{aligned}\sigma_k^2 &= E[X_{k+1} - \mathbf{a}_k^T \mathbf{X}_k]^2 \\ &= E[(X_{k+1} - \mathbf{a}_k^T \mathbf{X}_k)X_{k+1}] - E[(X_{k+1} - \mathbf{a}_k^T \mathbf{X}_k)\mathbf{a}_k^T \mathbf{X}_k] \\ &= \gamma_0 - \mathbf{a}_k^T (\gamma_1 \ \dots \ \gamma_k)^T - 0 \\ &= \gamma_0 - a_{k,1}\gamma_1 - \dots - a_{k,k}\gamma_k\end{aligned}$$

- ▶ 这是 $a_{k+1,k+1}$ 的递推公式的分母，所以 $a_{k+1,k+1}$ 的递推公式也可以写成

$$a_{k+1,k+1} = \frac{\gamma_{k+1} - a_{k,1}\gamma_k - a_{k,2}\gamma_{k-1} - \dots - a_{k,k}\gamma_1}{\sigma_k^2}$$

- ▶ 注意 σ_k^2 是用 k 个预报第 $k+1$ 个的均方误差。

- ▶ 关于 σ_k^2 :

$$\begin{aligned}\sigma_k^2 &= E[X_{k+1} - \mathbf{a}_k^T \mathbf{X}_k]^2 \\ &= E[(X_{k+1} - \mathbf{a}_k^T \mathbf{X}_k)X_{k+1}] - E[(X_{k+1} - \mathbf{a}_k^T \mathbf{X}_k)\mathbf{a}_k^T \mathbf{X}_k] \\ &= \gamma_0 - \mathbf{a}_k^T (\gamma_1 \ \dots \ \gamma_k)^T - 0 \\ &= \gamma_0 - a_{k,1}\gamma_1 - \dots - a_{k,k}\gamma_k\end{aligned}$$

- ▶ 这是 $a_{k+1,k+1}$ 的递推公式的分母，所以 $a_{k+1,k+1}$ 的递推公式也可以写成

$$a_{k+1,k+1} = \frac{\gamma_{k+1} - a_{k,1}\gamma_k - a_{k,2}\gamma_{k-1} - \dots - a_{k,k}\gamma_1}{\sigma_k^2}$$

- ▶ 注意 σ_k^2 是用 k 个预报第 $k+1$ 个的均方误差。

Levinson递推顺序

- ▶ 用Levinson递推公式计算各阶Yuler-Walker系数和

$$\sigma_k^2 = E[X_{k+1} - a_{k,1}X_k - a_{k,2}X_{k-1} - \cdots - a_{k,k}X_1]^2$$

次序应为

- ▶ 初值(不用历史资料预报 X_1):

$$\sigma_0^2 = E[X_1 - 0]^2 = \gamma_0$$

- ▶ $k + 1 = 1$ (用 X_1 预报 X_2):

$$a_{1,1} = \gamma_1 / \gamma_0$$

$$\begin{aligned}\sigma_1^2 &= E[X_2 - a_{1,1}X_1]^2 \\ &= \sigma_0^2(1 - a_{1,1}^2)\end{aligned}$$

Levinson递推顺序

- ▶ 用Levinson递推公式计算各阶Yuler-Walker系数和

$$\sigma_k^2 = E[X_{k+1} - a_{k,1}X_k - a_{k,2}X_{k-1} - \cdots - a_{k,k}X_1]^2$$

次序应为

- ▶ 初值(不用历史资料预报 X_1):

$$\sigma_0^2 = E[X_1 - 0]^2 = \gamma_0$$

- ▶ $k + 1 = 1$ (用 X_1 预报 X_2):

$$a_{1,1} = \gamma_1 / \gamma_0$$

$$\begin{aligned}\sigma_1^2 &= E[X_2 - a_{1,1}X_1]^2 \\ &= \sigma_0^2(1 - a_{1,1}^2)\end{aligned}$$

Levinson递推顺序

- ▶ 用Levinson递推公式计算各阶Yuler-Walker系数和

$$\sigma_k^2 = E[X_{k+1} - a_{k,1}X_k - a_{k,2}X_{k-1} - \cdots - a_{k,k}X_1]^2$$

次序应为

- ▶ 初值(不用历史资料预报 X_1):

$$\sigma_0^2 = E[X_1 - 0]^2 = \gamma_0$$

- ▶ $k + 1 = 1$ (用 X_1 预报 X_2):

$$a_{1,1} = \gamma_1 / \gamma_0$$

$$\begin{aligned}\sigma_1^2 &= E[X_2 - a_{1,1}X_1]^2 \\ &= \sigma_0^2(1 - a_{1,1}^2)\end{aligned}$$

- ▶ $k + 1 = 2$ (用 X_1, X_2 预报 X_3):

$$a_{2,2} = \frac{\gamma_2 - a_{1,1}\gamma_1}{\sigma_1^2}$$

$$a_{2,1} = a_{1,1} - a_{2,2}a_{1,1}$$

$$\begin{aligned}\sigma_2^2 &= E[X_3 - a_{2,1}X_2 - a_{2,2}X_1]^2 \\ &= \sigma_1^2(1 - a_{2,2}^2)\end{aligned}$$

- ▶ $k + 1 = 3$ (用 X_1, X_2, X_3 预报 X_4):

$$a_{3,3} = \frac{\gamma_3 - a_{2,1}\gamma_2 - a_{2,2}\gamma_1}{\sigma_2^2}$$

$$a_{3,1} = a_{2,1} - a_{3,3}a_{2,2}$$

$$a_{3,2} = a_{2,2} - a_{3,3}a_{2,1}$$

$$\begin{aligned}\sigma_3^2 &= E[X_4 - a_{3,1}X_3 - a_{3,2}X_2 - a_{3,3}X_1]^2 \\ &= \sigma_2^2(1 - a_{3,3}^2)\end{aligned}$$

- ▶ $k + 1 = 2$ (用 X_1, X_2 预报 X_3):

$$a_{2,2} = \frac{\gamma_2 - a_{1,1}\gamma_1}{\sigma_1^2}$$

$$a_{2,1} = a_{1,1} - a_{2,2}a_{1,1}$$

$$\begin{aligned}\sigma_2^2 &= E[X_3 - a_{2,1}X_2 - a_{2,2}X_1]^2 \\ &= \sigma_1^2(1 - a_{2,2}^2)\end{aligned}$$

- ▶ $k + 1 = 3$ (用 X_1, X_2, X_3 预报 X_4):

$$a_{3,3} = \frac{\gamma_3 - a_{2,1}\gamma_2 - a_{2,2}\gamma_1}{\sigma_2^2}$$

$$a_{3,1} = a_{2,1} - a_{3,3}a_{2,2}$$

$$a_{3,2} = a_{2,2} - a_{3,3}a_{2,1}$$

$$\begin{aligned}\sigma_3^2 &= E[X_4 - a_{3,1}X_3 - a_{3,2}X_2 - a_{3,3}X_1]^2 \\ &= \sigma_2^2(1 - a_{3,3}^2)\end{aligned}$$

- ▶ $k + 1 = 2$ (用 X_1, X_2 预报 X_3):

$$a_{2,2} = \frac{\gamma_2 - a_{1,1}\gamma_1}{\sigma_1^2}$$

$$a_{2,1} = a_{1,1} - a_{2,2}a_{1,1}$$

$$\begin{aligned}\sigma_2^2 &= E[X_3 - a_{2,1}X_2 - a_{2,2}X_1]^2 \\ &= \sigma_1^2(1 - a_{2,2}^2)\end{aligned}$$

- ▶ $k + 1 = 3$ (用 X_1, X_2, X_3 预报 X_4):

$$a_{3,3} = \frac{\gamma_3 - a_{2,1}\gamma_2 - a_{2,2}\gamma_1}{\sigma_2^2}$$

$$a_{3,1} = a_{2,1} - a_{3,3}a_{2,2}$$

$$a_{3,2} = a_{2,2} - a_{3,3}a_{2,1}$$

$$\begin{aligned}\sigma_3^2 &= E[X_4 - a_{3,1}X_3 - a_{3,2}X_2 - a_{3,3}X_1]^2 \\ &= \sigma_2^2(1 - a_{3,3}^2)\end{aligned}$$

▶

计算次序为

k	$a_{k,j}$				σ_k^2
0					σ_0^2
1	$a_{1,1}$				σ_1^2
2	$a_{2,2}$	$a_{2,1}$			σ_2^2
3	$a_{3,3}$	$a_{3,1}$	$a_{3,2}$		σ_3^2
4	$a_{4,4}$	$a_{4,1}$	$a_{4,2}$	$a_{4,3}$	σ_4^2
\vdots		$\dots\dots$			\vdots

偏相关系数

- ▶ **定义4.1** 如果 Γ_n 正定, 称 $a_{n,n}$ 为 $\{X_t\}$ 或 $\{\gamma_k\}$ 的 n 阶偏(自)相关系数。



$$a_{n,n} = \text{Corr}[X_1 - L(X_1|X_2, \dots, X_n), \\ X_{n+1} - L(X_{n+1}|X_2, \dots, X_n)]$$

- ▶ 即 $a_{n,n}$ 为 X_1 和 X_{n+1} 扣除 X_2, \dots, X_n 的线性影响后的相关系数。

偏相关系数

- ▶ **定义4.1** 如果 Γ_n 正定, 称 $a_{n,n}$ 为 $\{X_t\}$ 或 $\{\gamma_k\}$ 的 n 阶偏(自)相关系数。



$$a_{n,n} = \text{Corr}[X_1 - L(X_1|X_2, \dots, X_n), \\ X_{n+1} - L(X_{n+1}|X_2, \dots, X_n)]$$

- ▶ 即 $a_{n,n}$ 为 X_1 和 X_{n+1} 扣除 X_2, \dots, X_n 的线性影响后的相关系数。

偏相关系数

- ▶ **定义4.1** 如果 Γ_n 正定, 称 $a_{n,n}$ 为 $\{X_t\}$ 或 $\{\gamma_k\}$ 的 n 阶偏(自)相关系数。



$$a_{n,n} = \text{Corr}[X_1 - L(X_1|X_2, \dots, X_n), \\ X_{n+1} - L(X_{n+1}|X_2, \dots, X_n)]$$

- ▶ 即 $a_{n,n}$ 为 X_1 和 X_{n+1} 扣除 X_2, \dots, X_n 的线性影响后的相关系数。

AR序列的偏相关系数

- ▶ 设 $\{X_t\}$ 是AR(p)序列。其自协方差函数正定。
- ▶ 由Yule-Walker方程(3.9)知其 n 阶($n \geq p$)Y-W系数为

$$\begin{aligned} \mathbf{a}_n &= (a_1, \dots, a_p, 0, \dots, 0)^T \\ &= (a_{n,1}, a_{n,2}, \dots, a_{n,n})^T, \quad n \geq p \end{aligned} \quad (4.6)$$

- ▶ 其偏相关系数满足

$$a_{n,n} = \begin{cases} a_p \neq 0, & n = p \\ 0, & n > p \end{cases} \quad (4.7)$$

称为偏相关系数 p 后截尾。

- ▶ 反之，如果一个零均值平稳列偏相关系数 p 后截尾，则它必是AR(p)序列。
- ▶ 偏相关截尾隐含要求自协方差列正定。

AR序列的偏相关系数

- ▶ 设 $\{X_t\}$ 是AR(p)序列。其自协方差函数正定。
- ▶ 由Yule-Walker方程(3.9)知其 n 阶($n \geq p$)Y-W系数为

$$\begin{aligned}\mathbf{a}_n &= (a_1, \dots, a_p, 0, \dots, 0)^T \\ &= (a_{n,1}, a_{n,2}, \dots, a_{n,n})^T, \quad n \geq p\end{aligned}\quad (4.6)$$

- ▶ 其偏相关系数满足

$$a_{n,n} = \begin{cases} a_p \neq 0, & n = p \\ 0, & n > p \end{cases}\quad (4.7)$$

称为偏相关系数 p 后截尾。

- ▶ 反之，如果一个零均值平稳列偏相关系数 p 后截尾，则它必是AR(p)序列。
- ▶ 偏相关截尾隐含要求自协方差列正定。

AR序列的偏相关系数

- ▶ 设 $\{X_t\}$ 是AR(p)序列。其自协方差函数正定。
- ▶ 由Yule-Walker方程(3.9)知其 n 阶($n \geq p$)Y-W系数为

$$\begin{aligned} \mathbf{a}_n &= (a_1, \dots, a_p, 0, \dots, 0)^T \\ &= (a_{n,1}, a_{n,2}, \dots, a_{n,n})^T, \quad n \geq p \end{aligned} \quad (4.6)$$

- ▶ 其偏相关系数满足

$$a_{n,n} = \begin{cases} a_p \neq 0, & n = p \\ 0, & n > p \end{cases} \quad (4.7)$$

称为偏相关系数 p 后截尾。

- ▶ 反之，如果一个零均值平稳列偏相关系数 p 后截尾，则它必是AR(p)序列。
- ▶ 偏相关截尾隐含要求自协方差列正定。

AR序列的偏相关系数

- ▶ 设 $\{X_t\}$ 是AR(p)序列。其自协方差函数正定。
- ▶ 由Yule-Walker方程(3.9)知其 n 阶($n \geq p$)Y-W系数为

$$\begin{aligned} \mathbf{a}_n &= (a_1, \dots, a_p, 0, \dots, 0)^T \\ &= (a_{n,1}, a_{n,2}, \dots, a_{n,n})^T, \quad n \geq p \end{aligned} \quad (4.6)$$

- ▶ 其偏相关系数满足

$$a_{n,n} = \begin{cases} a_p \neq 0, & n = p \\ 0, & n > p \end{cases} \quad (4.7)$$

称为偏相关系数 p 后截尾。

- ▶ 反之，如果一个零均值平稳列偏相关系数 p 后截尾，则它必是AR(p)序列。
- ▶ 偏相关截尾隐含要求自协方差列正定。

AR序列的偏相关系数

- ▶ 设 $\{X_t\}$ 是AR(p)序列。其自协方差函数正定。
- ▶ 由Yule-Walker方程(3.9)知其 n 阶($n \geq p$)Y-W系数为

$$\begin{aligned} \mathbf{a}_n &= (a_1, \dots, a_p, 0, \dots, 0)^T \\ &= (a_{n,1}, a_{n,2}, \dots, a_{n,n})^T, \quad n \geq p \end{aligned} \quad (4.6)$$

- ▶ 其偏相关系数满足

$$a_{n,n} = \begin{cases} a_p \neq 0, & n = p \\ 0, & n > p \end{cases} \quad (4.7)$$

称为偏相关系数 p 后截尾。

- ▶ 反之，如果一个零均值平稳列偏相关系数 p 后截尾，则它必是AR(p)序列。
- ▶ 偏相关截尾隐含要求自协方差列正定。

AR序列的充要条件

- ▶ **定理4.3** 零均值平稳列 $\{X_t\}$ 是AR(p)序列的充分必要条件是，它的偏相关系数 $\{a_{n,n}\}$ p 后截尾。
- ▶ 证明只要证明充分性。
- ▶ 记 $(a_{p,1}, \dots, a_{p,p}) = (a_1, \dots, a_p)$ ，
令 $\varepsilon_t = X_t - \sum_{j=1}^p a_j X_{t-j}$ ，只要证明 $\{\varepsilon_t\}$ 是白噪声。
- ▶ 最小相位性由定理4.1给出。

AR序列的充要条件

- ▶ **定理4.3** 零均值平稳列 $\{X_t\}$ 是AR(p)序列的充分必要条件是，它的偏相关系数 $\{a_{n,n}\}$ p 后截尾。
- ▶ 证明只要证明充分性。
- ▶ 记 $(a_{p,1}, \dots, a_{p,p}) = (a_1, \dots, a_p)$ ，
令 $\varepsilon_t = X_t - \sum_{j=1}^p a_j X_{t-j}$ ，只要证明 $\{\varepsilon_t\}$ 是白噪声。
- ▶ 最小相位性由定理4.1给出。

AR序列的充要条件

- ▶ **定理4.3** 零均值平稳列 $\{X_t\}$ 是AR(p)序列的充分必要条件是，它的偏相关系数 $\{a_{n,n}\}$ p 后截尾。
- ▶ 证明只要证明充分性。
- ▶ 记 $(a_{p,1}, \dots, a_{p,p}) = (a_1, \dots, a_p)$ ，
令 $\varepsilon_t = X_t - \sum_{j=1}^p a_j X_{t-j}$ ，只要证明 $\{\varepsilon_t\}$ 是白噪声。
- ▶ 最小相位性由定理4.1给出。

AR序列的充要条件

- ▶ **定理4.3** 零均值平稳列 $\{X_t\}$ 是AR(p)序列的充分必要条件是，它的偏相关系数 $\{a_{n,n}\}$ p 后截尾。
- ▶ 证明只要证明充分性。
- ▶ 记 $(a_{p,1}, \dots, a_{p,p}) = (a_1, \dots, a_p)$ ，
令 $\varepsilon_t = X_t - \sum_{j=1}^p a_j X_{t-j}$ ，只要证明 $\{\varepsilon_t\}$ 是白噪声。
- ▶ 最小相位性由定理4.1给出。

定理4.3证明I

证明： 记 $\mathbf{a}_p = (a_{p,1}, \dots, a_{p,p}) = (a_1, \dots, a_p)$ ，
由Levinson公式和 $a_{p+k,p+k} = 0 (k > 0)$ 得

$$a_{p+1,j} = a_{p,j} - a_{p+1,p+1}a_{p,p+1-j} = a_j, \quad 1 \leq j \leq p$$

$$a_{p+k,j} = a_{p+k-1,j} = \dots = a_{p,j} = a_j, \quad k \geq 2, 1 \leq j \leq p$$

$$a_{p+k,j} = a_{p+k-1,j} = 0 \quad p < j \leq p+k$$

即 $n \geq p$ 时

$$\mathbf{a}_n = (a_{n,1}, a_{n,2}, \dots, a_{n,n}) = (a_1, a_2, \dots, a_p, 0, \dots, 0)$$

定理4.3证明II

注意 a_n 是Y-W方程的解，即

$$\begin{pmatrix} \gamma_0 & \gamma_1 & \cdots & \gamma_{n-1} \\ \gamma_1 & \gamma_0 & \cdots & \gamma_{n-2} \\ \vdots & \vdots & & \vdots \\ \gamma_{n-1} & \gamma_{n-2} & \cdots & \gamma_0 \end{pmatrix} \begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \\ 0 \\ \vdots \\ 0 \end{pmatrix} = \begin{pmatrix} \gamma_1 \\ \gamma_2 \\ \vdots \\ \gamma_n \end{pmatrix}$$

可写成

$$\begin{aligned} \gamma_k &= a_1 \gamma_{k-1} + a_2 \gamma_{k-2} + \cdots + a_p \gamma_{k-p} \\ &= \sum_{j=1}^p a_j \gamma_{k-j}, \quad k \geq 1 \end{aligned} \quad (*)$$

定理4.3证明III

$$\begin{aligned}\gamma_k &= a_1\gamma_{k-1} + a_2\gamma_{k-2} + \cdots + a_p\gamma_{k-p} \\ &= \sum_{j=1}^p a_j\gamma_{k-j}, \quad k \geq 1\end{aligned}\quad (*)$$

由定理4.1知 $A(z) = 1 - \sum_{j=1}^p a_j z^j$ 满足最小相位条件。

令

$$\varepsilon_t = X_t - \sum_{j=1}^p a_j X_{t-j}, \quad t \in \mathbb{Z}$$

则 $\{\varepsilon_t\}$ 是平稳序列，满足 $E\varepsilon_t = 0$, $\text{Var}(\varepsilon_t) = \sigma_p^2 > 0$ 。

下面只要证明 $\{\varepsilon_t\}$ 是白噪声。

定理4.3证明IV

$\forall t > s$ 有

$$\begin{aligned} E(\varepsilon_t X_s) &= E \left[\left(X_t - \sum_{j=1}^p a_j X_{t-j} \right) X_s \right] \\ &= \gamma_{t-s} - \sum_{j=1}^p a_j \gamma_{t-s-j} \\ &= 0 \quad (\text{由}(*)) \end{aligned}$$

所以 $t > s$ 时

$$E(\varepsilon_t \varepsilon_s) = E \left[\varepsilon_t \left(X_s - \sum_{j=1}^p a_j X_{s-j} \right) \right] = 0$$

即 $\{\varepsilon_t\}$ 是 $WN(0, \sigma_p^2)$ ，且 a_1, a_2, \dots, a_p 满足最小相位条件。
证毕。

本节内容的应用意义

- ▶ 有了观测样本 x_1, x_2, \dots, x_N 可以估计样本自协方差函数:

$$\hat{\gamma}_k = \frac{1}{N} \sum_{t=1}^{N-k} (x_t - \bar{x})(x_{t+k} - \bar{x})$$

- ▶ 有了 $\{\hat{\gamma}_k\}$ 可以计算各阶偏相关系数的估计 $\{a_{k,k}\}$ 。
- ▶ 如果发现样本偏相关系数呈现截尾性则可以拟合AR模型。
- ▶ 定理4.1保证当 $\hat{\Gamma}_{p+1}$ 正定时得到的模型系数满足最小相位条件。
- ▶ 最小相位条件保证系统是稳定的，预测有意义。
- ▶ 真实模型为AR(p)时 $\hat{\Gamma}_{p+1}$ a.s.正定。

本节内容的应用意义

- ▶ 有了观测样本 x_1, x_2, \dots, x_N 可以估计样本自协方差函数:

$$\hat{\gamma}_k = \frac{1}{N} \sum_{t=1}^{N-k} (x_t - \bar{x})(x_{t+k} - \bar{x})$$

- ▶ 有了 $\{\hat{\gamma}_k\}$ 可以计算各阶偏相关系数的估计 $\{a_{k,k}\}$ 。
- ▶ 如果发现样本偏相关系数呈现截尾性则可以拟合AR模型。
- ▶ 定理4.1保证当 $\hat{\Gamma}_{p+1}$ 正定时得到的模型系数满足最小相位条件。
- ▶ 最小相位条件保证系统是稳定的，预测有意义。
- ▶ 真实模型为AR(p)时 $\hat{\Gamma}_{p+1}$ a.s.正定。

本节内容的应用意义

- ▶ 有了观测样本 x_1, x_2, \dots, x_N 可以估计样本自协方差函数:

$$\hat{\gamma}_k = \frac{1}{N} \sum_{t=1}^{N-k} (x_t - \bar{x})(x_{t+k} - \bar{x})$$

- ▶ 有了 $\{\hat{\gamma}_k\}$ 可以计算各阶偏相关系数的估计 $\{a_{k,k}\}$ 。
- ▶ 如果发现样本偏相关系数呈现截尾性则可以拟合AR模型。
- ▶ 定理4.1保证当 $\hat{\Gamma}_{p+1}$ 正定时得到的模型系数满足最小相位条件。
- ▶ 最小相位条件保证系统是稳定的，预测有意义。
- ▶ 真实模型为AR(p)时 $\hat{\Gamma}_{p+1}$ a.s.正定。

本节内容的应用意义

- ▶ 有了观测样本 x_1, x_2, \dots, x_N 可以估计样本自协方差函数:

$$\hat{\gamma}_k = \frac{1}{N} \sum_{t=1}^{N-k} (x_t - \bar{x})(x_{t+k} - \bar{x})$$

- ▶ 有了 $\{\hat{\gamma}_k\}$ 可以计算各阶偏相关系数的估计 $\{a_{k,k}\}$ 。
- ▶ 如果发现样本偏相关系数呈现截尾性则可以拟合AR模型。
- ▶ 定理4.1保证当 $\hat{\Gamma}_{p+1}$ 正定时得到的模型系数满足最小相位条件。
- ▶ 最小相位条件保证系统是稳定的，预测有意义。
- ▶ 真实模型为AR(p)时 $\hat{\Gamma}_{p+1}$ a.s.正定。

本节内容的应用意义

- ▶ 有了观测样本 x_1, x_2, \dots, x_N 可以估计样本自协方差函数:

$$\hat{\gamma}_k = \frac{1}{N} \sum_{t=1}^{N-k} (x_t - \bar{x})(x_{t+k} - \bar{x})$$

- ▶ 有了 $\{\hat{\gamma}_k\}$ 可以计算各阶偏相关系数的估计 $\{a_{k,k}\}$ 。
- ▶ 如果发现样本偏相关系数呈现截尾性则可以拟合AR模型。
- ▶ 定理4.1保证当 $\hat{\Gamma}_{p+1}$ 正定时得到的模型系数满足最小相位条件。
- ▶ 最小相位条件保证系统是稳定的，预测有意义。
- ▶ 真实模型为AR(p)时 $\hat{\Gamma}_{p+1}$ a.s.正定。

本节内容的应用意义

- ▶ 有了观测样本 x_1, x_2, \dots, x_N 可以估计样本自协方差函数:

$$\hat{\gamma}_k = \frac{1}{N} \sum_{t=1}^{N-k} (x_t - \bar{x})(x_{t+k} - \bar{x})$$

- ▶ 有了 $\{\hat{\gamma}_k\}$ 可以计算各阶偏相关系数的估计 $\{a_{k,k}\}$ 。
- ▶ 如果发现样本偏相关系数呈现截尾性则可以拟合AR模型。
- ▶ 定理4.1保证当 $\hat{\Gamma}_{p+1}$ 正定时得到的模型系数满足最小相位条件。
- ▶ 最小相位条件保证系统是稳定的，预测有意义。
- ▶ 真实模型为AR(p)时 $\hat{\Gamma}_{p+1}$ a.s.正定。

例5.1

$|a| < 1$, AR(1)模型

$$X_t = aX_{t-1} + \varepsilon_t, \quad t \in \mathbb{Z}$$
$$\{\varepsilon_t\} \sim \text{WN}(0, \sigma^2)$$

有平稳解

$$X_t = \sum_{j=0}^{\infty} a^j \varepsilon_{t-j}$$

自协方差函数

$$\gamma_0 = \sigma^2 \sum_{j=0}^{\infty} a^{2j} = \frac{\sigma^2}{1 - a^2}$$
$$\gamma_k = a\gamma_{k-1} = \cdots = a^k \gamma_0, \quad k \geq 1 \quad (5.2)$$

例5.1 II

自相关系数

$$\rho_k = \frac{\gamma_k}{\gamma_0} = a^k \quad (1)$$

谱密度

$$f(\lambda) = \frac{\sigma^2}{2\pi} \frac{1}{|1 - ae^{i\lambda}|^2} \quad (2)$$

$$= \frac{\sigma^2}{2\pi} [1 + a^2 - 2a \cos \lambda]^{-2}, \quad \lambda \in [-\pi, \pi] \quad (3)$$

例5.1 演示

演示： $a = \pm 0.85$ 时序列的演示。

比较：

$a = 0.85$

(1) 数据表现出趋势性，相邻的数据差别不大；

(2) (1)中的现象在 $\{\rho_k\}$ 得到体现：相邻随机变量正相关

(3) ρ_k 单调减少趋于0

(4) 谱密度的能量集中在低频， $f(\lambda) < f(0), \lambda \in (0, \pi]$ ，数据无周期现象，周期 $T = \frac{2\pi}{0} = \infty$

(5) 偏相关系数 $a_{1,1} = 0.85, a_{k,k} = 0, \text{当} k > 1$

(6) 随 a 接近于0，以更快的速度收敛到0

$a = -0.85$

(1) 数据上下摆动，趋势性不明显；

(2) (1)中的现象在 $\{\rho_k\}$ 得到体现：相邻随机变量负相关

(3) ρ_k 正负交替趋于0

(4) 谱密度能量集中在高频， $f(\lambda) < f(\pi), \lambda \in [0, \pi)$ ，数据有周期现象，周期 $T = \frac{2\pi}{\pi} = 2$

(5) 偏相关系数 $a_{1,1} = -0.85, a_{k,k} = 0, \text{当} k > 1$

(6) 上述性质随 a 接近-1变得更明显，随 a 接近0变得不明显


AR(2): 稳定性条件

$$X_t = a_1 X_{t-1} + a_2 X_{t-2} + \varepsilon_t, \quad \varepsilon_t \sim \text{WN}(0, \sigma^2)$$

$$A(z) = 1 - a_1 z - a_2 z^2 \neq 0, |z| \leq 1$$

稳定性条件为：

$$a_2 \pm a_1 < 1, \quad |a_2| < 1$$



(蓝色：实根；红色：复根)

AR(2): 自相关系数

- ▶ 设 $A(z)$ 的根为 $z_1 = b_1 e^{i\lambda_1}$, $z_2 = b_2 e^{i\lambda_2}$ 。
- ▶ 由Y-W方程

$$\rho_0 = 1,$$

$$\rho_1 = \frac{a_1}{1 - a_2}$$

$$\rho_k = a_1 \rho_{k-1} + a_2 \rho_{k-2}, \quad k \geq 1$$

- ▶ $a_{1,1} = \rho_1$, $a_{2,2} = a_2$, $a_{k,k} = 0 (k \geq 3)$ 。

AR(2): 自相关系数

- ▶ 设 $A(z)$ 的根为 $z_1 = b_1 e^{i\lambda_1}$, $z_2 = b_2 e^{i\lambda_2}$ 。
- ▶ 由Y-W方程

$$\rho_0 = 1,$$

$$\rho_1 = \frac{a_1}{1 - a_2}$$

$$\rho_k = a_1 \rho_{k-1} + a_2 \rho_{k-2}, \quad k \geq 1$$

- ▶ $a_{1,1} = \rho_1$, $a_{2,2} = a_2$, $a_{k,k} = 0 (k \geq 3)$ 。

AR(2): 自相关系数

- ▶ 设 $A(z)$ 的根为 $z_1 = b_1 e^{i\lambda_1}$, $z_2 = b_2 e^{i\lambda_2}$ 。
- ▶ 由Y-W方程

$$\rho_0 = 1,$$

$$\rho_1 = \frac{a_1}{1 - a_2}$$

$$\rho_k = a_1 \rho_{k-1} + a_2 \rho_{k-2}, \quad k \geq 1$$

- ▶ $a_{11} = \rho_1$, $a_{2,2} = a_2$, $a_{k,k} = 0 (k \geq 3)$ 。

AR(2)例子: 稳定域和允许域



$$\mathcal{A} = \{(a_1, a_2) : a_2 \pm a_1 < 1, |a_2| < 1\}$$

称为AR(2)的稳定域。

- ▶ 从Y-W方程可以用 ρ_1, ρ_2 表示 a_1, a_2 :

$$a_1 = \frac{\rho_1(1 - \rho_2)}{1 - \rho_1^2}, \quad a_2 = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2}$$

- ▶ 反之有

$$\rho_1 = \frac{a_1}{1 - a_2}, \quad \rho_2 = a_2 + \frac{a_1^2}{1 - a_2}$$

- ▶ $(a_1, a_2) \in \mathcal{A} \iff (\rho_1, \rho_2) \in$

$$\mathcal{C} = \{(\rho_1, \rho_2) : \rho_1^2 < (1 + \rho_2)/2, |\rho_1| < 1, |\rho_2| < 1\}$$

- ▶ \mathcal{C} 称为AR(2)的允许域。

AR(2)例子: 稳定域和允许域



$$\mathcal{A} = \{(a_1, a_2) : a_2 \pm a_1 < 1, |a_2| < 1\}$$

称为AR(2)的稳定域。

- ▶ 从Y-W方程可以用 ρ_1, ρ_2 表示 a_1, a_2 :

$$a_1 = \frac{\rho_1(1 - \rho_2)}{1 - \rho_1^2}, \quad a_2 = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2}$$

- ▶ 反之有

$$\rho_1 = \frac{a_1}{1 - a_2}, \quad \rho_2 = a_2 + \frac{a_1^2}{1 - a_2}$$

- ▶ $(a_1, a_2) \in \mathcal{A} \iff (\rho_1, \rho_2) \in$

$$\mathcal{C} = \{(\rho_1, \rho_2) : \rho_1^2 < (1 + \rho_2)/2, |\rho_1| < 1, |\rho_2| < 1\}$$

- ▶ \mathcal{C} 称为AR(2)的允许域。

AR(2)例子: 稳定域和允许域



$$\mathcal{A} = \{(a_1, a_2) : a_2 \pm a_1 < 1, |a_2| < 1\}$$

称为AR(2)的稳定域。

- ▶ 从Y-W方程可以用 ρ_1, ρ_2 表示 a_1, a_2 :

$$a_1 = \frac{\rho_1(1 - \rho_2)}{1 - \rho_1^2}, \quad a_2 = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2}$$

- ▶ 反之有

$$\rho_1 = \frac{a_1}{1 - a_2}, \quad \rho_2 = a_2 + \frac{a_1^2}{1 - a_2}$$

- ▶ $(a_1, a_2) \in \mathcal{A} \iff (\rho_1, \rho_2) \in$

$$\mathcal{C} = \{(\rho_1, \rho_2) : \rho_1^2 < (1 + \rho_2)/2, |\rho_1| < 1, |\rho_2| < 1\}$$

- ▶ \mathcal{C} 称为AR(2)的允许域。

AR(2)例子: 稳定域和允许域



$$\mathcal{A} = \{(a_1, a_2) : a_2 \pm a_1 < 1, |a_2| < 1\}$$

称为AR(2)的稳定域。

- ▶ 从Y-W方程可以用 ρ_1, ρ_2 表示 a_1, a_2 :

$$a_1 = \frac{\rho_1(1 - \rho_2)}{1 - \rho_1^2}, \quad a_2 = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2}$$

- ▶ 反之有

$$\rho_1 = \frac{a_1}{1 - a_2}, \quad \rho_2 = a_2 + \frac{a_1^2}{1 - a_2}$$

- ▶ $(a_1, a_2) \in \mathcal{A} \iff (\rho_1, \rho_2) \in$

$$\mathcal{C} = \{(\rho_1, \rho_2) : \rho_1^2 < (1 + \rho_2)/2, |\rho_1| < 1, |\rho_2| < 1\}$$

- ▶ \mathcal{C} 称为AR(2)的允许域。

AR(2)例子: 稳定域和允许域



$$\mathcal{A} = \{(a_1, a_2) : a_2 \pm a_1 < 1, |a_2| < 1\}$$

称为AR(2)的稳定域。

- ▶ 从Y-W方程可以用 ρ_1, ρ_2 表示 a_1, a_2 :

$$a_1 = \frac{\rho_1(1 - \rho_2)}{1 - \rho_1^2}, \quad a_2 = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2}$$

- ▶ 反之有

$$\rho_1 = \frac{a_1}{1 - a_2}, \quad \rho_2 = a_2 + \frac{a_1^2}{1 - a_2}$$

- ▶ $(a_1, a_2) \in \mathcal{A} \iff (\rho_1, \rho_2) \in$

$$\mathcal{C} = \{(\rho_1, \rho_2) : \rho_1^2 < (1 + \rho_2)/2, |\rho_1| < 1, |\rho_2| < 1\}$$

- ▶ \mathcal{C} 称为AR(2)的允许域。

AR(2)的谱密度与特征根

- ▶ 特征根与系数有如下关系

$$1 - a_1 z - a_2 z^2 = \left(1 - \frac{z}{z_1}\right) \left(1 - \frac{z}{z_2}\right)$$

$$a_1 = \frac{1}{z_1} + \frac{1}{z_2}, \quad a_2 = -\frac{1}{z_1} \frac{1}{z_2}$$

$$z_1 z_2 = \frac{1}{(-a_2)}, \quad z_1 + z_2 = \frac{a_1}{(-a_2)}$$

本课件基于李东风
老师课件修改

平稳序列的偏相关
系数和Levinson递
推公式

最优线性预测

最小相位性

Levinson递推公式

偏相关系数

AR(p)序列举例

▶

$$f(\lambda) = \frac{\sigma^2}{2\pi} \frac{1}{|a_2| |e^{i\lambda} - b_1 e^{i\lambda_1}|^2 \cdot |e^{i\lambda} - b_2 e^{i\lambda_2}|^2}$$

AR(2)的谱密度与特征根

- ▶ 特征根与系数有如下关系

$$1 - a_1 z - a_2 z^2 = \left(1 - \frac{z}{z_1}\right) \left(1 - \frac{z}{z_2}\right)$$

$$a_1 = \frac{1}{z_1} + \frac{1}{z_2}, \quad a_2 = -\frac{1}{z_1} \frac{1}{z_2}$$

$$z_1 z_2 = \frac{1}{(-a_2)}, \quad z_1 + z_2 = \frac{a_1}{(-a_2)}$$



$$f(\lambda) = \frac{\sigma^2}{2\pi} \frac{1}{|a_2| |e^{i\lambda} - b_1 e^{i\lambda_1}|^2 \cdot |e^{i\lambda} - b_2 e^{i\lambda_2}|^2}$$

本课件基于李东风
老师课件修改

平稳序列的偏相关
系数和Levinson递
推公式

最优线性预测

最小相位性

Levinson递推公式

偏相关系数

AR(p)序列举例