

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

周期图定义

- ▶ 周期图是估计谱密度的基础。
- ▶ 对零均值平稳序列的观测 x_1, x_2, \dots, x_N ，记

$$\bar{x} = \frac{1}{N} \sum x_k,$$

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

$$\hat{\gamma}_{-k} = \hat{\gamma}_k, k = 0, 1, \dots, N-1,$$

$$\tilde{f}(\lambda) = \frac{1}{2\pi} \sum_{k=-N+1}^{N-1} \hat{\gamma}_k e^{-ik\lambda}.$$

周期图定义

- ▶ 周期图是估计谱密度的基础。
- ▶ 对零均值平稳序列的观测 x_1, x_2, \dots, x_N ，记

$$\bar{x} = \frac{1}{N} \sum x_k,$$

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

$$\hat{\gamma}_{-k} = \hat{\gamma}_k, k = 0, 1, \dots, N-1,$$

$$\tilde{f}(\lambda) = \frac{1}{2\pi} \sum_{k=-N+1}^{N-1} \hat{\gamma}_k e^{-ik\lambda}.$$

▶ 记

$$J_N(\lambda) = \frac{1}{2\pi N} \left| \sum_{k=1}^N (x_k - \bar{x}) e^{-ik\lambda} \right|^2, \quad \lambda \in [-\pi, \pi]$$

▶ 引理2.1

$$\tilde{f}(\lambda) = J_N(\lambda).$$

- ▶ 证明 记 $y_t = (x_t - \bar{x})e^{-it\lambda}$, $t = 1, 2, \dots, N$, 用 $\mathbf{1}$ 表示元素都是1的 N 维向量。

▶ 记

$$J_N(\lambda) = \frac{1}{2\pi N} \left| \sum_{k=1}^N (x_k - \bar{x}) e^{-ik\lambda} \right|^2, \quad \lambda \in [-\pi, \pi]$$

▶ 引理2.1

$$\tilde{f}(\lambda) = J_N(\lambda).$$

- ▶ 证明 记 $y_t = (x_t - \bar{x})e^{-it\lambda}$, $t = 1, 2, \dots, N$, 用 $\mathbf{1}$ 表示元素都是1的 N 维向量。

▶ 记

$$J_N(\lambda) = \frac{1}{2\pi N} \left| \sum_{k=1}^N (x_k - \bar{x}) e^{-ik\lambda} \right|^2, \quad \lambda \in [-\pi, \pi]$$

▶ 引理2.1

$$\tilde{f}(\lambda) = J_N(\lambda).$$

- ▶ **证明** 记 $y_t = (x_t - \bar{x})e^{-it\lambda}$, $t = 1, 2, \dots, N$, 用 $\mathbf{1}$ 表示元素都是1的 N 维向量。

▶ 则

$$\begin{aligned}
 J_N(\lambda) &= \frac{1}{2\pi N} \sum_{j=1}^N \sum_{k=1}^N (x_k - \bar{x})(x_j - \bar{x}) e^{-i(k-j)\lambda} \\
 &= \frac{1}{2\pi N} \sum_{j=1}^N \sum_{k=1}^N y_k \bar{y}_j \\
 &= \frac{1}{2\pi N} \mathbf{1}^T \begin{pmatrix} y_1 \bar{y}_1 & y_1 \bar{y}_2 & \cdots & y_1 \bar{y}_N \\ y_2 \bar{y}_1 & y_2 \bar{y}_2 & \cdots & y_2 \bar{y}_N \\ \vdots & \vdots & & \vdots \\ y_N \bar{y}_1 & y_N \bar{y}_2 & \cdots & y_N \bar{y}_N \end{pmatrix} \mathbf{1} \\
 &= \frac{1}{2\pi} (\hat{\gamma}_0 + \hat{\gamma}_1 e^{i\lambda} + \cdots + \hat{\gamma}_{N-1} e^{i(N-1)\lambda} \\
 &\quad + \hat{\gamma}_1 e^{-i\lambda} + \cdots + \hat{\gamma}_{N-1} e^{-i(N-1)\lambda}) \\
 &= \tilde{f}(\lambda)
 \end{aligned}$$

► Fourier频率点

$$\lambda_j = \frac{2\pi j}{N}, j = 1, 2, \dots, N-1.$$

► 记

$$I_N(\lambda) = \frac{1}{2\pi N} \left| \sum_{k=1}^N x_k e^{-ik\lambda} \right|^2,$$

► 由于

$$\sum_{k=1}^N e^{-ik\lambda} = \frac{1 - e^{-iN\lambda}}{1 - e^{-i\lambda}} e^{-i\lambda}$$

和 $e^{-iN\lambda_j} = e^{-i2\pi j} = 1$ 得 $\sum_{k=1}^N e^{-ik\lambda_j} = 0$ 。

► 所以在Fourier频率点上

$$I_N(\lambda_j) = J_N(\lambda_j), j = 1, 2, \dots, N-1.$$

► Fourier频率点

$$\lambda_j = \frac{2\pi j}{N}, j = 1, 2, \dots, N-1.$$

► 记

$$I_N(\lambda) = \frac{1}{2\pi N} \left| \sum_{k=1}^N x_k e^{-ik\lambda} \right|^2,$$

► 由于

$$\sum_{k=1}^N e^{-ik\lambda} = \frac{1 - e^{-iN\lambda}}{1 - e^{-i\lambda}} e^{-i\lambda}$$

和 $e^{-iN\lambda_j} = e^{-i2\pi j} = 1$ 得 $\sum_{k=1}^N e^{-ik\lambda_j} = 0$ 。

► 所以在Fourier频率点上

$$I_N(\lambda_j) = J_N(\lambda_j), j = 1, 2, \dots, N-1.$$

► Fourier频率点

$$\lambda_j = \frac{2\pi j}{N}, j = 1, 2, \dots, N-1.$$

► 记

$$I_N(\lambda) = \frac{1}{2\pi N} \left| \sum_{k=1}^N x_k e^{-ik\lambda} \right|^2,$$

► 由于

$$\sum_{k=1}^N e^{-ik\lambda} = \frac{1 - e^{-iN\lambda}}{1 - e^{-i\lambda}} e^{-i\lambda}$$

和 $e^{-iN\lambda_j} = e^{-i2\pi j} = 1$ 得 $\sum_{k=1}^N e^{-ik\lambda_j} = 0$ 。

► 所以在Fourier频率点上

$$I_N(\lambda_j) = J_N(\lambda_j), j = 1, 2, \dots, N-1.$$

► Fourier频率点

$$\lambda_j = \frac{2\pi j}{N}, j = 1, 2, \dots, N-1.$$

► 记

$$I_N(\lambda) = \frac{1}{2\pi N} \left| \sum_{k=1}^N x_k e^{-ik\lambda} \right|^2,$$

► 由于

$$\sum_{k=1}^N e^{-ik\lambda} = \frac{1 - e^{-iN\lambda}}{1 - e^{-i\lambda}} e^{-i\lambda}$$

和 $e^{-iN\lambda_j} = e^{-i2\pi j} = 1$ 得 $\sum_{k=1}^N e^{-ik\lambda_j} = 0$ 。

► 所以在Fourier频率点上

$$I_N(\lambda_j) = J_N(\lambda_j), j = 1, 2, \dots, N-1.$$

▶ **定义2.1** $I_N(\lambda)$ 称为观测数据的**周期图**。

▶ **定理2.1** 对于零均值时间序列的观测值 x_1, x_2, \dots, x_N ，若定义

$$\hat{\gamma}_{\pm k} = \frac{1}{N} \sum_{t=1}^{N-k} x_t x_{t+k}, \quad k = 0, 1, \dots, N-1 \quad (2.7)$$

则

$$I_N(\lambda) = \frac{1}{2\pi} \sum_{k=-N+1}^{N-1} \hat{\gamma}_k e^{-ik\lambda}, \quad \lambda \in [-\pi, \pi]. \quad (2.8)$$

- ▶ **定义2.1** $I_N(\lambda)$ 称为观测数据的**周期图**。
- ▶ **定理2.1** 对于零均值时间序列的观测值 x_1, x_2, \dots, x_N ，若定义

$$\hat{\gamma}_{\pm k} = \frac{1}{N} \sum_{t=1}^{N-k} x_t x_{t+k}, \quad k = 0, 1, \dots, N-1 \quad (2.7)$$

则

$$I_N(\lambda) = \frac{1}{2\pi} \sum_{k=-N+1}^{N-1} \hat{\gamma}_k e^{-ik\lambda}, \quad \lambda \in [-\pi, \pi]. \quad (2.8)$$

周期图的性质

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

平稳序列的周期图

加窗谱估计

加窗谱估计的比较

- ▶ **定理2.3(周期图的渐近无偏性)** 如果零均值平稳序列 $\{X_t\}$ 的自协方差函数绝对可和: $\sum_{k=1}^{\infty} |\gamma_k| < \infty$, 则 $I_N(\lambda)$ 是谱密度 $f(\lambda)$ 的渐近无偏估计:

$$EI_N(\lambda) \rightarrow f(\lambda), \quad N \rightarrow \infty.$$

► 证明

$$\begin{aligned}EI_N(\lambda) &= \frac{1}{2\pi} \sum_{k=-N+1}^{N-1} E\hat{\gamma}_k e^{-ik\lambda} \quad (\text{这里}\hat{\gamma}_k\text{按(2.7)定义)} \\ &= \frac{1}{2\pi} \sum_{k=-N+1}^{N-1} \frac{N-|k|}{N} \gamma_k e^{-ik\lambda} \\ &= \frac{1}{2\pi} \sum_{k=-N+1}^{N-1} \gamma_k e^{-ik\lambda} - \frac{1}{2\pi N} \sum_{k=-N+1}^{N-1} |k| \gamma_k e^{-ik\lambda} \\ &\rightarrow \frac{1}{2\pi} \sum_{k=-\infty}^{\infty} \gamma_k e^{-ik\lambda}\end{aligned}$$

(由Kronecker引理及 $\{\gamma_k\}$ 绝对可和知后一项趋于零)

$$= f(\lambda) \quad (\text{由定理2.3.1})$$

- ▶ $I_N(\lambda)$ 不是 $f(\lambda)$ 的相合估计:
- ▶ 定理2.4 设 $\{\varepsilon_t\}$ 是独立同分布的 $WN(0, \sigma^2)$, 实数列 $\{c_j\}$ 满足 $\sum_{j=0}^{\infty} j|c_j| < \infty$, 线性平稳列

$$X_t = \sum_{j=0}^{\infty} c_j \varepsilon_{t-j} \quad (2.9)$$

$I_N(\lambda)$ 为 X_1, X_2, \dots, X_N 的周期图, $f(\lambda)$ 为 $\{X_t\}$ 的谱密度, 则

$$\limsup_{N \rightarrow \infty} \frac{1}{\ln \ln N} I_N(\lambda) = \begin{cases} f(\lambda), & \lambda \neq 0, \pi \\ 2f(\lambda), & \lambda = 0, \pi, \end{cases} \text{ a.s.}, \quad (2.10)$$

- ▶ 定理说明 $|I_N(\lambda) - f(\lambda)|$ 不趋于零。

- ▶ $I_N(\lambda)$ 不是 $f(\lambda)$ 的相合估计:
- ▶ **定理2.4** 设 $\{\varepsilon_t\}$ 是独立同分布的 $WN(0, \sigma^2)$, 实数列 $\{c_j\}$ 满足 $\sum_{j=0}^{\infty} j|c_j| < \infty$, 线性平稳列

$$X_t = \sum_{j=0}^{\infty} c_j \varepsilon_{t-j} \quad (2.9)$$

$I_N(\lambda)$ 为 X_1, X_2, \dots, X_N 的周期图, $f(\lambda)$ 为 $\{X_t\}$ 的谱密度, 则

$$\limsup_{N \rightarrow \infty} \frac{1}{\ln \ln N} I_N(\lambda) = \begin{cases} f(\lambda), & \lambda \neq 0, \pi \\ 2f(\lambda), & \lambda = 0, \pi \end{cases} \text{ a.s.}, \quad (2.10)$$

- ▶ 定理说明 $|I_N(\lambda) - f(\lambda)|$ 不趋于零。

- ▶ $I_N(\lambda)$ 不是 $f(\lambda)$ 的相合估计:
- ▶ **定理2.4** 设 $\{\varepsilon_t\}$ 是独立同分布的 $WN(0, \sigma^2)$, 实数列 $\{c_j\}$ 满足 $\sum_{j=0}^{\infty} j|c_j| < \infty$, 线性平稳列

$$X_t = \sum_{j=0}^{\infty} c_j \varepsilon_{t-j} \quad (2.9)$$

$I_N(\lambda)$ 为 X_1, X_2, \dots, X_N 的周期图, $f(\lambda)$ 为 $\{X_t\}$ 的谱密度, 则

$$\limsup_{N \rightarrow \infty} \frac{1}{\ln \ln N} I_N(\lambda) = \begin{cases} f(\lambda), & \lambda \neq 0, \pi \\ 2f(\lambda), & \lambda = 0, \pi, \end{cases} \text{ a.s.}, \quad (2.10)$$

- ▶ 定理说明 $|I_N(\lambda) - f(\lambda)|$ 不趋于零。

▶ **例2.1** $\{X_t\}$ 为标准正态白噪声。

▶ $f(\lambda) = \frac{1}{2\pi}$ 。

▶ $\frac{1}{\sqrt{N}} \sum_{j=1}^N X_j \sim N(0, 1)$ 。

▶ $I_N(0) = \frac{1}{2\pi} \left(\frac{1}{\sqrt{N}} \sum_{j=1}^N X_j \right)^2$ 为 χ_1^2 分布的 $\frac{1}{2\pi}$ 倍, 与 N 无关。

▶ 周期图一般不是谱密度的相合估计, 因为使用了所有的 $\hat{\gamma}_k$, 其中 k 接近于 $N-1$ 时 $\hat{\gamma}_k$ 估计偏差很大:

$$E\hat{\gamma}_k - \gamma_k = \frac{N-k}{N}\gamma_k - \gamma_k = -\frac{k}{N}\gamma_k.$$

- ▶ 例2.1 $\{X_t\}$ 为标准正态白噪声。
- ▶ $f(\lambda) = \frac{1}{2\pi}$ 。
- ▶ $\frac{1}{\sqrt{N}} \sum_{j=1}^N X_j \sim N(0, 1)$ 。
- ▶ $I_N(0) = \frac{1}{2\pi} \left(\frac{1}{\sqrt{N}} \sum_{j=1}^N X_j \right)^2$ 为 χ_1^2 分布的 $\frac{1}{2\pi}$ 倍, 与 N 无关。
- ▶ 周期图一般不是谱密度的相合估计, 因为使用了所有的 $\hat{\gamma}_k$, 其中 k 接近于 $N - 1$ 时 $\hat{\gamma}_k$ 估计偏差很大:

$$E\hat{\gamma}_k - \gamma_k = \frac{N - k}{N} \gamma_k - \gamma_k = -\frac{k}{N} \gamma_k.$$

- ▶ **例2.1** $\{X_t\}$ 为标准正态白噪声。
- ▶ $f(\lambda) = \frac{1}{2\pi}$ 。
- ▶ $\frac{1}{\sqrt{N}} \sum_{j=1}^N X_j \sim N(0, 1)$ 。
- ▶ $I_N(0) = \frac{1}{2\pi} \left(\frac{1}{\sqrt{N}} \sum_{j=1}^N X_j \right)^2$ 为 χ_1^2 分布的 $\frac{1}{2\pi}$ 倍, 与 N 无关。
- ▶ 周期图一般不是谱密度的相合估计, 因为使用了所有的 $\hat{\gamma}_k$, 其中 k 接近于 $N-1$ 时 $\hat{\gamma}_k$ 估计偏差很大:

$$E\hat{\gamma}_k - \gamma_k = \frac{N-k}{N}\gamma_k - \gamma_k = -\frac{k}{N}\gamma_k.$$

- ▶ **例2.1** $\{X_t\}$ 为标准正态白噪声。
- ▶ $f(\lambda) = \frac{1}{2\pi}$ 。
- ▶ $\frac{1}{\sqrt{N}} \sum_{j=1}^N X_j \sim N(0, 1)$ 。
- ▶ $I_N(0) = \frac{1}{2\pi} \left(\frac{1}{\sqrt{N}} \sum_{j=1}^N X_j \right)^2$ 为 χ_1^2 分布的 $\frac{1}{2\pi}$ 倍, 与 N 无关。
- ▶ 周期图一般不是谱密度的相合估计, 因为使用了所有的 $\hat{\gamma}_k$, 其中 k 接近于 $N-1$ 时 $\hat{\gamma}_k$ 估计偏差很大:

$$E\hat{\gamma}_k - \gamma_k = \frac{N-k}{N}\gamma_k - \gamma_k = -\frac{k}{N}\gamma_k.$$

- ▶ **例2.1** $\{X_t\}$ 为标准正态白噪声。
- ▶ $f(\lambda) = \frac{1}{2\pi}$ 。
- ▶ $\frac{1}{\sqrt{N}} \sum_{j=1}^N X_j \sim N(0, 1)$ 。
- ▶ $I_N(0) = \frac{1}{2\pi} \left(\frac{1}{\sqrt{N}} \sum_{j=1}^N X_j \right)^2$ 为 χ_1^2 分布的 $\frac{1}{2\pi}$ 倍, 与 N 无关。
- ▶ 周期图一般不是谱密度的相合估计, 因为使用了所有的 $\hat{\gamma}_k$, 其中 k 接近于 $N - 1$ 时 $\hat{\gamma}_k$ 估计偏差很大:

$$E\hat{\gamma}_k - \gamma_k = \frac{N-k}{N}\gamma_k - \gamma_k = -\frac{k}{N}\gamma_k.$$

- ▶ 减少使用的 $\hat{\gamma}_k$ 可以改善估计，称为**截断周期图**：

$$\hat{f}(\lambda) = \frac{1}{2\pi} \sum_{k=-N_1}^{N_1} \hat{\gamma}_k e^{-ik\lambda} \quad (2.11)$$

$(N_1 < N - 1)$

- ▶ 见演示：周期图例2.2(AR(2)序列的周期图和截断周期图)。

- ▶ 减少使用的 $\hat{\gamma}_k$ 可以改善估计，称为**截断周期图**：

$$\hat{f}(\lambda) = \frac{1}{2\pi} \sum_{k=-N_1}^{N_1} \hat{\gamma}_k e^{-ik\lambda} \quad (2.11)$$

$(N_1 < N - 1)$

- ▶ 见演示：周期图例2.2(AR(2)序列的周期图和截断周期图)。

- ▶ 克服周期图不相合性的经典方法是加窗谱估计。
- ▶ 令

$$\hat{f}(\lambda) = \frac{1}{2\pi} \sum_{k=-N+1}^{N-1} \lambda_N(k) \hat{\gamma}_k e^{-ik\lambda} \quad (3.1)$$

- ▶ 其中 $\lambda_N(k)$ 是 $|k|$ 的减函数，称为时窗，称 $\hat{f}(\lambda)$ 为加时窗谱估计，简称加窗谱估计。

- ▶ 克服周期图不相合性的经典方法是加窗谱估计。
- ▶ 令

$$\hat{f}(\lambda) = \frac{1}{2\pi} \sum_{k=-N+1}^{N-1} \lambda_N(k) \hat{\gamma}_k e^{-ik\lambda} \quad (3.1)$$

- ▶ 其中 $\lambda_N(k)$ 是 $|k|$ 的减函数，称为时窗，称 $\hat{f}(\lambda)$ 为加时窗谱估计，简称加窗谱估计。

- ▶ 克服周期图不相合性的经典方法是加窗谱估计。
- ▶ 令

$$\hat{f}(\lambda) = \frac{1}{2\pi} \sum_{k=-N+1}^{N-1} \lambda_N(k) \hat{\gamma}_k e^{-ik\lambda} \quad (3.1)$$

- ▶ 其中 $\lambda_N(k)$ 是 $|k|$ 的减函数，称为**时窗**，称 $\hat{f}(\lambda)$ 为**加时窗谱估计**，简称**加窗谱估计**。

例3.1

- ▶ 取时窗为

$$\lambda_N(k) = \begin{cases} 1, & |k| \leq \sqrt{N} \\ 0, & |k| > \sqrt{N} \end{cases}$$

- ▶ 即为截断周期图估计。

例3.1

- ▶ 取时窗为

$$\lambda_N(k) = \begin{cases} 1, & |k| \leq \sqrt{N} \\ 0, & |k| > \sqrt{N} \end{cases}$$

- ▶ 即为截断周期图估计。

例3.2

- ▶ MA(q)序列。则谱密度为

$$f(\lambda) = \frac{1}{2\pi} \sum_{k=-q}^q \gamma_k e^{-ik\lambda}.$$

- ▶ 取 $M \geq q$ ，时窗

$$\lambda_N(k) = \begin{cases} 1, & |k| \leq M \\ 0, & |k| > M \end{cases}$$

例3.2

- ▶ MA(q)序列。则谱密度为

$$f(\lambda) = \frac{1}{2\pi} \sum_{k=-q}^q \gamma_k e^{-ik\lambda}.$$

- ▶ 取 $M \geq q$ ，时窗

$$\lambda_N(k) = \begin{cases} 1, & |k| \leq M \\ 0, & |k| > M \end{cases}$$

▶ 加窗谱估计为

$$\hat{f}(\lambda) = \frac{1}{2\pi} \sum_{k=-M}^M \hat{\gamma}_k e^{-ik\lambda}.$$

▶ 如果 $\{\varepsilon_t\}$ 是独立白噪声，则 $N \rightarrow \infty$ 时 $\hat{\gamma}_k \rightarrow \gamma_k$, a.s., 有

$$\begin{aligned} \lim_{N \rightarrow \infty} \hat{f}(\lambda) &= \frac{1}{2\pi} \sum_{k=-M}^M \gamma_k e^{-ik\lambda} \\ &= \frac{1}{2\pi} \sum_{k=-q}^q \gamma_k e^{-ik\lambda} = f(\lambda), \quad \text{a.s.} \end{aligned}$$

- ▶ 加窗后 $\hat{f}(\lambda)$ 为 $f(\lambda)$ 的强相合估计。
- ▶ 见演示：例3.2（MA(2)截断窗谱估计）。

- ▶ 加窗谱估计为

$$\hat{f}(\lambda) = \frac{1}{2\pi} \sum_{k=-M}^M \hat{\gamma}_k e^{-ik\lambda}.$$

- ▶ 如果 $\{\varepsilon_t\}$ 是独立白噪声，则 $N \rightarrow \infty$ 时 $\hat{\gamma}_k \rightarrow \gamma_k$, a.s., 有

$$\begin{aligned} \lim_{N \rightarrow \infty} \hat{f}(\lambda) &= \frac{1}{2\pi} \sum_{k=-M}^M \gamma_k e^{-ik\lambda} \\ &= \frac{1}{2\pi} \sum_{k=-q}^q \gamma_k e^{-ik\lambda} = f(\lambda), \quad \text{a.s.} \end{aligned}$$

- ▶ 加窗后 $\hat{f}(\lambda)$ 为 $f(\lambda)$ 的强相合估计。
- ▶ 见演示：例3.2（MA(2)截断窗谱估计）。

- ▶ 加窗谱估计为

$$\hat{f}(\lambda) = \frac{1}{2\pi} \sum_{k=-M}^M \hat{\gamma}_k e^{-ik\lambda}.$$

- ▶ 如果 $\{\varepsilon_t\}$ 是独立白噪声，则 $N \rightarrow \infty$ 时 $\hat{\gamma}_k \rightarrow \gamma_k$, a.s., 有

$$\begin{aligned} \lim_{N \rightarrow \infty} \hat{f}(\lambda) &= \frac{1}{2\pi} \sum_{k=-M}^M \gamma_k e^{-ik\lambda} \\ &= \frac{1}{2\pi} \sum_{k=-q}^q \gamma_k e^{-ik\lambda} = f(\lambda), \quad \text{a.s.} \end{aligned}$$

- ▶ 加窗后 $\hat{f}(\lambda)$ 为 $f(\lambda)$ 的强相合估计。
- ▶ 见演示：例3.2（MA(2)截断窗谱估计）。

- ▶ 加窗谱估计为

$$\hat{f}(\lambda) = \frac{1}{2\pi} \sum_{k=-M}^M \hat{\gamma}_k e^{-ik\lambda}.$$

- ▶ 如果 $\{\varepsilon_t\}$ 是独立白噪声，则 $N \rightarrow \infty$ 时 $\hat{\gamma}_k \rightarrow \gamma_k$, a.s., 有

$$\begin{aligned} \lim_{N \rightarrow \infty} \hat{f}(\lambda) &= \frac{1}{2\pi} \sum_{k=-M}^M \gamma_k e^{-ik\lambda} \\ &= \frac{1}{2\pi} \sum_{k=-q}^q \gamma_k e^{-ik\lambda} = f(\lambda), \quad \text{a.s.} \end{aligned}$$

- ▶ 加窗后 $\hat{f}(\lambda)$ 为 $f(\lambda)$ 的强相合估计。
- ▶ 见演示：例3.2（MA(2)截断窗谱估计）。

► 由

$$\begin{aligned} I_N(\lambda) &= \frac{1}{2\pi N} \left| \sum_{k=1}^N x_k e^{-ik\lambda} \right|^2 \\ &= \frac{1}{2\pi} \sum_{k=-N+1}^{N-1} \hat{\gamma}_k e^{-ik\lambda} \end{aligned}$$

► 所以

$$\hat{\gamma}_k = \int_{-\pi}^{\pi} I_N(s) e^{iks} ds, \quad |k| \leq N-1. \quad (3.3)$$

($\hat{\gamma}_k$ 为不减去均值的计算公式)

本课件基于李东风
老师课件修改

平稳序列的周期图

加窗谱估计

加窗谱估计的比较

► 由

$$\begin{aligned} I_N(\lambda) &= \frac{1}{2\pi N} \left| \sum_{k=1}^N x_k e^{-ik\lambda} \right|^2 \\ &= \frac{1}{2\pi} \sum_{k=-N+1}^{N-1} \hat{\gamma}_k e^{-ik\lambda} \end{aligned}$$

► 所以

$$\hat{\gamma}_k = \int_{-\pi}^{\pi} I_N(s) e^{iks} ds, \quad |k| \leq N-1. \quad (3.3)$$

($\hat{\gamma}_k$ 为不减去均值的计算公式)

► 于是

$$\begin{aligned}\hat{f}(\lambda) &= \frac{1}{2\pi} \sum_{k=-N+1}^{N-1} \lambda_N(k) \hat{\gamma}_k e^{-ik\lambda} \\ &= \frac{1}{2\pi} \sum_{k=-N+1}^{N-1} \lambda_N(k) e^{-ik\lambda} \int_{-\pi}^{\pi} I_N(s) e^{iks} ds \\ &= \int_{-\pi}^{\pi} I_N(s) \frac{1}{2\pi} \sum_{k=-N+1}^{N-1} \lambda_N(k) e^{ik(\lambda-s)} ds \\ &\triangleq \int_{-\pi}^{\pi} I_N(s) W_N(\lambda - s) ds,\end{aligned}$$

其中

$$W_N(\lambda) \triangleq \frac{1}{2\pi} \sum_{k=-N+1}^{N-1} \lambda_N(k) e^{ik\lambda}$$

- ▶ **定义3.1** 设 $W_N(\lambda)$ 为满足一定要求的权函数，

$$\hat{f}(\lambda) = \int_{-\pi}^{\pi} I_N(s) W_N(\lambda - s) ds \quad (3.4)$$

称为 $f(\lambda)$ 的**加谱窗谱估计**，简称为**加窗谱估计**。权函数 $W_N(\lambda)$ 称为**谱窗**。

- ▶ 加谱窗的谱估计是对周期图用一个权函数做卷积，取 $W_N(\cdot)$ 为偶函数，在0点最高的钟形曲线，则加谱窗谱估计是对周期图的局部光滑，可以克服周期图的不相合性。
- ▶ 直观想法是取小的 $\delta > 0$ 令 $W_N(\lambda) = \frac{1}{2\delta} I_{[\lambda-\delta, \lambda+\delta]}$ ， $\hat{f}(\lambda) = \frac{1}{2\delta} \int_{\lambda-\delta}^{\lambda+\delta} I_N(s) ds$ 。
- ▶ 更一般的 $W_N(\lambda)$ 是其它的局部加权平均方法。

- ▶ **定义3.1** 设 $W_N(\lambda)$ 为满足一定要求的权函数，

$$\hat{f}(\lambda) = \int_{-\pi}^{\pi} I_N(s) W_N(\lambda - s) ds \quad (3.4)$$

称为 $f(\lambda)$ 的**加谱窗谱估计**，简称为**加窗谱估计**。权函数 $W_N(\lambda)$ 称为**谱窗**。

- ▶ 加谱窗的谱估计是对周期图用一个权函数做卷积，取 $W_N(\cdot)$ 为偶函数，在0点最高的钟形曲线，则加谱窗谱估计是对周期图的局部光滑，可以克服周期图的不相合性。
- ▶ 直观想法是取小的 $\delta > 0$ 令 $W_N(\lambda) = \frac{1}{2\delta} I_{[\lambda-\delta, \lambda+\delta]}$ ， $\hat{f}(\lambda) = \frac{1}{2\delta} \int_{\lambda-\delta}^{\lambda+\delta} I_N(s) ds$ 。
- ▶ 更一般的 $W_N(\lambda)$ 是其它的局部加权平均方法。

- ▶ **定义3.1** 设 $W_N(\lambda)$ 为满足一定要求的权函数，

$$\hat{f}(\lambda) = \int_{-\pi}^{\pi} I_N(s) W_N(\lambda - s) ds \quad (3.4)$$

称为 $f(\lambda)$ 的**加谱窗谱估计**，简称为**加窗谱估计**。权函数 $W_N(\lambda)$ 称为**谱窗**。

- ▶ 加谱窗的谱估计是对周期图用一个权函数做卷积，取 $W_N(\cdot)$ 为偶函数，在0点最高的钟形曲线，则加谱窗谱估计是对周期图的局部光滑，可以克服周期图的不相合性。
- ▶ 直观想法是取小的 $\delta > 0$ 令 $W_N(\lambda) = \frac{1}{2\delta} I_{[\lambda-\delta, \lambda+\delta]}$ ， $\hat{f}(\lambda) = \frac{1}{2\delta} \int_{\lambda-\delta}^{\lambda+\delta} I_N(s) ds$ 。
- ▶ 更一般的 $W_N(\lambda)$ 是其它的局部加权平均方法。

- ▶ **定义3.1** 设 $W_N(\lambda)$ 为满足一定要求的权函数，

$$\hat{f}(\lambda) = \int_{-\pi}^{\pi} I_N(s) W_N(\lambda - s) ds \quad (3.4)$$

称为 $f(\lambda)$ 的**加谱窗谱估计**，简称为**加窗谱估计**。权函数 $W_N(\lambda)$ 称为**谱窗**。

- ▶ 加谱窗的谱估计是对周期图用一个权函数做卷积，取 $W_N(\cdot)$ 为偶函数，在0点最高的钟形曲线，则加谱窗谱估计是对周期图的局部光滑，可以克服周期图的不相合性。
- ▶ 直观想法是取小的 $\delta > 0$ 令 $W_N(\lambda) = \frac{1}{2\delta} I_{[\lambda-\delta, \lambda+\delta]}$ ， $\hat{f}(\lambda) = \frac{1}{2\delta} \int_{\lambda-\delta}^{\lambda+\delta} I_N(s) ds$ 。
- ▶ 更一般的 $W_N(\lambda)$ 是其它的局部加权平均方法。

- ▶ 时窗 $\lambda_N(k)$ 和谱窗 $W_N(\lambda)$ 的关系为

$$W_N(\lambda) = \frac{1}{2\pi} \sum_{k=-N+1}^{N-1} \lambda_N(k) e^{ik\lambda}$$

$$\lambda_N(k) = \int_{-\pi}^{\pi} W_N(s) e^{iks} ds.$$

谱窗应有的性质

- ▶ $\int_{-\pi}^{\pi} W_N(\lambda) d\lambda = 1$ (等价于 $\lambda_N(0) = 1$)。
- ▶ $\int_{-\pi}^{\pi} W_N^2(\lambda) d\lambda < \infty$;
- ▶ $\forall \varepsilon > 0, N \rightarrow \infty$ 时 $\sup_{|\lambda| > \varepsilon} W_N(\lambda) \rightarrow 0$; (即 $N \rightarrow \infty$ 时谱窗向着 $\lambda = 0$ 处集中)
- ▶ 对称性: $W_N(-\lambda) = W_N(\lambda)$;
- ▶ 对任何正数 A , 当 $N \rightarrow \infty$ 时,

$$\max_{|\mu| \leq A/N} \left| \frac{\int_{-\pi}^{\pi} W_N(\lambda) W_N(\mu + \lambda) d\lambda}{\int_{-\pi}^{\pi} W_N^2(\lambda) d\lambda} - 1 \right| \rightarrow 0.$$

(要求谱窗随 $N \rightarrow \infty$ 不要变窄太快)

谱窗应有的性质

- ▶ $\int_{-\pi}^{\pi} W_N(\lambda) d\lambda = 1$ (等价于 $\lambda_N(0) = 1$)。
- ▶ $\int_{-\pi}^{\pi} W_N^2(\lambda) d\lambda < \infty$;
- ▶ $\forall \varepsilon > 0, N \rightarrow \infty$ 时 $\sup_{|\lambda| > \varepsilon} W_N(\lambda) \rightarrow 0$; (即 $N \rightarrow \infty$ 时谱窗向着 $\lambda = 0$ 处集中)
- ▶ 对称性: $W_N(-\lambda) = W_N(\lambda)$;
- ▶ 对任何正数 A , 当 $N \rightarrow \infty$ 时,

$$\max_{|\mu| \leq A/N} \left| \frac{\int_{-\pi}^{\pi} W_N(\lambda) W_N(\mu + \lambda) d\lambda}{\int_{-\pi}^{\pi} W_N^2(\lambda) d\lambda} - 1 \right| \rightarrow 0.$$

(要求谱窗随 $N \rightarrow \infty$ 不要变窄太快)

谱窗应有的性质

- ▶ $\int_{-\pi}^{\pi} W_N(\lambda) d\lambda = 1$ (等价于 $\lambda_N(0) = 1$)。
- ▶ $\int_{-\pi}^{\pi} W_N^2(\lambda) d\lambda < \infty$;
- ▶ $\forall \varepsilon > 0, N \rightarrow \infty$ 时 $\sup_{|\lambda| > \varepsilon} W_N(\lambda) \rightarrow 0$; (即 $N \rightarrow \infty$ 时谱窗向着 $\lambda = 0$ 处集中)
- ▶ 对称性: $W_N(-\lambda) = W_N(\lambda)$;
- ▶ 对任何正数 A , 当 $N \rightarrow \infty$ 时,

$$\max_{|\mu| \leq A/N} \left| \frac{\int_{-\pi}^{\pi} W_N(\lambda) W_N(\mu + \lambda) d\lambda}{\int_{-\pi}^{\pi} W_N^2(\lambda) d\lambda} - 1 \right| \rightarrow 0.$$

(要求谱窗随 $N \rightarrow \infty$ 不要变窄太快)

谱窗应有的性质

- ▶ $\int_{-\pi}^{\pi} W_N(\lambda) d\lambda = 1$ (等价于 $\lambda_N(0) = 1$)。
- ▶ $\int_{-\pi}^{\pi} W_N^2(\lambda) d\lambda < \infty$;
- ▶ $\forall \varepsilon > 0, N \rightarrow \infty$ 时 $\sup_{|\lambda| > \varepsilon} W_N(\lambda) \rightarrow 0$; (即 $N \rightarrow \infty$ 时谱窗向着 $\lambda = 0$ 处集中)
- ▶ 对称性: $W_N(-\lambda) = W_N(\lambda)$;
- ▶ 对任何正数 A , 当 $N \rightarrow \infty$ 时,

$$\max_{|\mu| \leq A/N} \left| \frac{\int_{-\pi}^{\pi} W_N(\lambda) W_N(\mu + \lambda) d\lambda}{\int_{-\pi}^{\pi} W_N^2(\lambda) d\lambda} - 1 \right| \rightarrow 0.$$

(要求谱窗随 $N \rightarrow \infty$ 不要变窄太快)

谱窗应有的性质

- ▶ $\int_{-\pi}^{\pi} W_N(\lambda) d\lambda = 1$ (等价于 $\lambda_N(0) = 1$)。
- ▶ $\int_{-\pi}^{\pi} W_N^2(\lambda) d\lambda < \infty$;
- ▶ $\forall \varepsilon > 0, N \rightarrow \infty$ 时 $\sup_{|\lambda| > \varepsilon} W_N(\lambda) \rightarrow 0$; (即 $N \rightarrow \infty$ 时谱窗向着 $\lambda = 0$ 处集中)
- ▶ 对称性: $W_N(-\lambda) = W_N(\lambda)$;
- ▶ 对任何正数 A , 当 $N \rightarrow \infty$ 时,

$$\max_{|\mu| \leq A/N} \left| \frac{\int_{-\pi}^{\pi} W_N(\lambda) W_N(\mu + \lambda) d\lambda}{\int_{-\pi}^{\pi} W_N^2(\lambda) d\lambda} - 1 \right| \rightarrow 0.$$

(要求谱窗随 $N \rightarrow \infty$ 不要变窄太快)

常用谱窗和时窗—截断窗

- ▶ 取 $M_N = o(N)$, $M_N \rightarrow \infty$, 比如 $M_N = A[\sqrt{N}]$, A 取值1到3之间。
- ▶ 截断窗:

$$\lambda_N(k) = \begin{cases} 1, & |k| \leq M_N \\ 0, & |k| > M_N. \end{cases}$$

▶

$$\hat{f}(\lambda) = \frac{1}{2\pi} \sum_{|k| \leq M_N} \hat{\gamma}_k e^{-ik\lambda}$$

▶

$$\begin{aligned} W_N(\lambda) &= \frac{1}{2\pi} \sum_{|k| \leq M_N} e^{-ik\lambda} \\ &= \frac{1}{2\pi} \frac{\sin[(2M_N + 1)\lambda/2]}{\sin(\lambda/2)} \triangleq \frac{1}{2\pi} D_{2M_N+1}(\lambda) \end{aligned}$$

$D_K(\lambda)$ 称为Dirichlet核。它有正有负。

常用谱窗和时窗—截断窗

- ▶ 取 $M_N = o(N)$, $M_N \rightarrow \infty$, 比如 $M_N = A[\sqrt{N}]$, A 取值1到3之间。
- ▶ 截断窗:

$$\lambda_N(k) = \begin{cases} 1, & |k| \leq M_N \\ 0, & |k| > M_N. \end{cases}$$

$$\hat{f}(\lambda) = \frac{1}{2\pi} \sum_{|k| \leq M_N} \hat{\gamma}_k e^{-ik\lambda}$$

$$\begin{aligned} W_N(\lambda) &= \frac{1}{2\pi} \sum_{|k| \leq M_N} e^{-ik\lambda} \\ &= \frac{1}{2\pi} \frac{\sin[(2M_N + 1)\lambda/2]}{\sin(\lambda/2)} \triangleq \frac{1}{2\pi} D_{2M_N+1}(\lambda) \end{aligned}$$

$D_K(\lambda)$ 称为Dirichlet核。它有正有负。

常用谱窗和时窗—截断窗

- ▶ 取 $M_N = o(N)$, $M_N \rightarrow \infty$, 比如 $M_N = A[\sqrt{N}]$, A 取值1到3之间。
- ▶ 截断窗:

$$\lambda_N(k) = \begin{cases} 1, & |k| \leq M_N \\ 0, & |k| > M_N. \end{cases}$$

▶

$$\hat{f}(\lambda) = \frac{1}{2\pi} \sum_{|k| \leq M_N} \hat{\gamma}_k e^{-ik\lambda}$$

▶

$$\begin{aligned} W_N(\lambda) &= \frac{1}{2\pi} \sum_{|k| \leq M_N} e^{-ik\lambda} \\ &= \frac{1}{2\pi} \frac{\sin[(2M_N + 1)\lambda/2]}{\sin(\lambda/2)} \triangleq \frac{1}{2\pi} D_{2M_N+1}(\lambda) \end{aligned}$$

$D_K(\lambda)$ 称为Dirichlet核。它有正有负。

常用谱窗和时窗—截断窗

- ▶ 取 $M_N = o(N)$, $M_N \rightarrow \infty$, 比如 $M_N = A[\sqrt{N}]$, A 取值1到3之间。
- ▶ 截断窗:

$$\lambda_N(k) = \begin{cases} 1, & |k| \leq M_N \\ 0, & |k| > M_N. \end{cases}$$

▶

$$\hat{f}(\lambda) = \frac{1}{2\pi} \sum_{|k| \leq M_N} \hat{\gamma}_k e^{-ik\lambda}$$

▶

$$\begin{aligned} W_N(\lambda) &= \frac{1}{2\pi} \sum_{|k| \leq M_N} e^{-ik\lambda} \\ &= \frac{1}{2\pi} \frac{\sin[(2M_N + 1)\lambda/2]}{\sin(\lambda/2)} \triangleq \frac{1}{2\pi} D_{2M_N+1}(\lambda) \end{aligned}$$

$D_K(\lambda)$ 称为Dirichlet核。它有正有负。

$$\lambda_N(k) = \begin{cases} 1 - \frac{|k|}{M_N}, & |k| \leq M_N \\ 0, & |k| > M_N \end{cases}$$

$$\begin{aligned} W_N(\lambda) &= \frac{1}{2\pi} \sum_{|k| \leq M_N} \left(1 - \frac{|k|}{M_N}\right) e^{-ik\lambda} \\ &= \frac{1}{2\pi M_N} \left(\frac{\sin(M_N \lambda/2)}{\sin(\lambda/2)}\right)^2 \triangleq F_{M_N}(\lambda) \end{aligned}$$

- ▶ $F_{M_N}(\lambda)$ 称为Fejer核。是全非负的。

$$\lambda_N(k) = \begin{cases} 1 - \frac{|k|}{M_N}, & |k| \leq M_N \\ 0, & |k| > M_N \end{cases}$$

$$\begin{aligned} W_N(\lambda) &= \frac{1}{2\pi} \sum_{|k| \leq M_N} \left(1 - \frac{|k|}{M_N}\right) e^{-ik\lambda} \\ &= \frac{1}{2\pi M_N} \left(\frac{\sin(M_N \lambda/2)}{\sin(\lambda/2)}\right)^2 \triangleq F_{M_N}(\lambda) \end{aligned}$$

▶ $F_{M_N}(\lambda)$ 称为Fejer核。是全非负的。

$$\lambda_N(k) = \begin{cases} 1 - \frac{|k|}{M_N}, & |k| \leq M_N \\ 0, & |k| > M_N \end{cases}$$

$$\begin{aligned} W_N(\lambda) &= \frac{1}{2\pi} \sum_{|k| \leq M_N} \left(1 - \frac{|k|}{M_N}\right) e^{-ik\lambda} \\ &= \frac{1}{2\pi M_N} \left(\frac{\sin(M_N \lambda / 2)}{\sin(\lambda / 2)} \right)^2 \triangleq F_{M_N}(\lambda) \end{aligned}$$

- ▶ $F_{M_N}(\lambda)$ 称为Fejer核。是全非负的。

$$W_N(\lambda) = \begin{cases} \frac{M_N}{2\pi}, & |\lambda| \leq \frac{\pi}{M_N}, \\ 0, & |\lambda| > \frac{\pi}{M_N}. \end{cases}$$

$$\hat{f}(\lambda) = \frac{M_N}{2\pi} \int_{\lambda - \frac{\pi}{M_N}}^{\lambda + \frac{\pi}{M_N}} I_N(s) ds$$

是 $I_N(s)$ 在 $[\lambda - \frac{\pi}{M_N}, \lambda + \frac{\pi}{M_N}]$ 的平均。

$$\lambda_N(k) = \sin \frac{k\pi}{M_N} / \frac{k\pi}{M_N}.$$

$$W_N(\lambda) = \begin{cases} \frac{M_N}{2\pi}, & |\lambda| \leq \frac{\pi}{M_N}, \\ 0, & |\lambda| > \frac{\pi}{M_N}. \end{cases}$$

$$\hat{f}(\lambda) = \frac{M_N}{2\pi} \int_{\lambda - \frac{\pi}{M_N}}^{\lambda + \frac{\pi}{M_N}} I_N(s) ds$$

是 $I_N(s)$ 在 $[\lambda - \frac{\pi}{M_N}, \lambda + \frac{\pi}{M_N}]$ 的平均。

$$\lambda_N(k) = \sin \frac{k\pi}{M_N} / \frac{k\pi}{M_N}.$$

$$W_N(\lambda) = \begin{cases} \frac{M_N}{2\pi}, & |\lambda| \leq \frac{\pi}{M_N}, \\ 0, & |\lambda| > \frac{\pi}{M_N}. \end{cases}$$

$$\hat{f}(\lambda) = \frac{M_N}{2\pi} \int_{\lambda - \frac{\pi}{M_N}}^{\lambda + \frac{\pi}{M_N}} I_N(s) ds$$

是 $I_N(s)$ 在 $[\lambda - \frac{\pi}{M_N}, \lambda + \frac{\pi}{M_N}]$ 的平均。

$$\lambda_N(k) = \sin \frac{k\pi}{M_N} / \frac{k\pi}{M_N}.$$

Tukey窗

- ▶ $a \in (0, 0.25]$. $a = 0.25$ 称为Tukey-Hanning窗, $a = 0.23$ 称为Tukey-Hamming窗。

$$\lambda_N(k) = \begin{cases} 1 - 2a + 2a \cos \frac{k\pi}{M_N}, & |k| \leq M_N, \\ 0, & |k| > M_N. \end{cases}$$

▶

$$W_N(\lambda) = aD\left(\lambda - \frac{\pi}{M_N}\right) + (1 - 2a)D(\lambda) + aD\left(\lambda + \frac{\pi}{M_N}\right),$$
$$D(\lambda) \triangleq \frac{\sin[(2M_N + 1)\lambda/2]}{2\pi \sin(\lambda/2)}$$

- ▶ 谱窗有负值。

Tukey窗

- ▶ $a \in (0, 0.25]$. $a = 0.25$ 称为Tukey-Hanning窗, $a = 0.23$ 称为Tukey-Hamming窗。

$$\lambda_N(k) = \begin{cases} 1 - 2a + 2a \cos \frac{k\pi}{M_N}, & |k| \leq M_N, \\ 0, & |k| > M_N. \end{cases}$$



$$W_N(\lambda) = aD\left(\lambda - \frac{\pi}{M_N}\right) + (1 - 2a)D(\lambda) + aD\left(\lambda + \frac{\pi}{M_N}\right),$$
$$D(\lambda) \triangleq \frac{\sin[(2M_N + 1)\lambda/2]}{2\pi \sin(\lambda/2)}$$

- ▶ 谱窗有负值。

Tukey窗

- ▶ $a \in (0, 0.25]$. $a = 0.25$ 称为Tukey-Hanning窗, $a = 0.23$ 称为Tukey-Hamming窗。

$$\lambda_N(k) = \begin{cases} 1 - 2a + 2a \cos \frac{k\pi}{M_N}, & |k| \leq M_N, \\ 0, & |k| > M_N. \end{cases}$$

▶

$$W_N(\lambda) = aD\left(\lambda - \frac{\pi}{M_N}\right) + (1 - 2a)D(\lambda) + aD\left(\lambda + \frac{\pi}{M_N}\right),$$
$$D(\lambda) \triangleq \frac{\sin[(2M_N + 1)\lambda/2]}{2\pi \sin(\lambda/2)}$$

- ▶ 谱窗有负值。



$$\lambda_N(k) = \begin{cases} 1 - 6(k/M_N)^2 + 6(|k|/M_N)^3, & |k| \leq M_N/2, \\ 2(1 - |k|/M_N)^3, & M_N/2 < k \leq M_N, \\ 0, & |k| > M_N. \end{cases}$$



$$W_N(\lambda) = \frac{3}{8\pi M_N^3} \left(\frac{\sin(M_N \lambda/4)}{\sin(\lambda/2)/2} \right)^4 \left(1 - \frac{2}{3} \sin^2 \frac{\lambda}{2} \right).$$

- ▶ 谱窗非负。
- ▶ Parzen窗在这几个加窗谱估计中估计方差最小。



$$\lambda_N(k) = \begin{cases} 1 - 6(k/M_N)^2 + 6(|k|/M_N)^3, & |k| \leq M_N/2, \\ 2(1 - |k|/M_N)^3, & M_N/2 < k \leq M_N, \\ 0, & |k| > M_N. \end{cases}$$



$$W_N(\lambda) = \frac{3}{8\pi M_N^3} \left(\frac{\sin(M_N\lambda/4)}{\sin(\lambda/2)/2} \right)^4 \left(1 - \frac{2}{3} \sin^2 \frac{\lambda}{2} \right).$$

- ▶ 谱窗非负。
- ▶ Parzen窗在这几个加窗谱估计中估计方差最小。



$$\lambda_N(k) = \begin{cases} 1 - 6(k/M_N)^2 + 6(|k|/M_N)^3, & |k| \leq M_N/2, \\ 2(1 - |k|/M_N)^3, & M_N/2 < k \leq M_N, \\ 0, & |k| > M_N. \end{cases}$$



$$W_N(\lambda) = \frac{3}{8\pi M_N^3} \left(\frac{\sin(M_N\lambda/4)}{\sin(\lambda/2)/2} \right)^4 \left(1 - \frac{2}{3} \sin^2 \frac{\lambda}{2} \right).$$

- ▶ 谱窗非负。
- ▶ Parzen窗在这几个加窗谱估计中估计方差最小。



$$\lambda_N(k) = \begin{cases} 1 - 6(k/M_N)^2 + 6(|k|/M_N)^3, & |k| \leq M_N/2, \\ 2(1 - |k|/M_N)^3, & M_N/2 < k \leq M_N, \\ 0, & |k| > M_N. \end{cases}$$



$$W_N(\lambda) = \frac{3}{8\pi M_N^3} \left(\frac{\sin(M_N\lambda/4)}{\sin(\lambda/2)/2} \right)^4 \left(1 - \frac{2}{3} \sin^2 \frac{\lambda}{2} \right).$$

- ▶ 谱窗非负。
- ▶ Parzen窗在这几个加窗谱估计中估计方差最小。

Bartlett-Priestley窗



$$W_N(\lambda) = \begin{cases} \frac{3M_N}{4\pi} [1 - (M_N\lambda/\pi)^2], & |\lambda| \leq \pi/M_N \\ 0, & |\lambda| > \pi/M_N \end{cases}$$

是二次函数。



$$\lambda_N(k) = \begin{cases} \frac{3M_N^2}{(\pi k)^2} \left[\frac{\sin(\pi k/M_N)}{\pi k/M_N} - \cos(\pi k/M_N) \right], & 0 < |k| \leq M_N, \\ 1, & k = 0, \\ 0, & |k| > M_N \end{cases}$$



$$W_N(\lambda) = \begin{cases} \frac{3M_N}{4\pi} [1 - (M_N\lambda/\pi)^2], & |\lambda| \leq \pi/M_N \\ 0, & |\lambda| > \pi/M_N \end{cases}$$

是二次函数。



$$\lambda_N(k) = \begin{cases} \frac{3M_N^2}{(\pi k)^2} \left[\frac{\sin(\pi k/M_N)}{\pi k/M_N} - \cos(\pi k/M_N) \right], & 0 < |k| \leq M_N, \\ 1, & k = 0, \\ 0, & |k| > M_N \end{cases}$$

方差的比较

- **定理4.1** 设 $\{X_t\}$ 是平稳正态序列，有连续可微的谱密度 $f(\lambda)$ ，谱窗函数 $W_N(\lambda)$ 满足§8.3中的条件(1)—(5)。加窗谱估计 $\hat{f}(\lambda)$ 由(3.4)定义。则有如下结果：

- (1) $\hat{f}(\lambda)$ 是 $f(\lambda)$ 的渐近无偏估计。
- (2) $\hat{f}(\lambda)$ 是 $f(\lambda)$ 的均方相合估计。
- (3) 当 N 充分大后，有

$$\text{Var}(\hat{f}(\lambda)) \approx \begin{cases} \frac{M_N}{N} f(\lambda)^2 K^2, & \lambda \neq 0, \pm\pi, \\ 2 \frac{M_N}{N} f(\lambda)^2 K^2, & \lambda = 0, \pm\pi, \end{cases}$$
$$K^2 = \frac{2\pi}{M_N} \int_{-\pi}^{\pi} W_N^2(\lambda) d\lambda.$$

- 虽然减小 M_N 会减小方差，但是可能增加偏差，降低分辨率。

方差的比较

- ▶ **定理4.1** 设 $\{X_t\}$ 是平稳正态序列，有连续可微的谱密度 $f(\lambda)$ ，谱窗函数 $W_N(\lambda)$ 满足§8.3中的条件(1)—(5)。加窗谱估计 $\hat{f}(\lambda)$ 由(3.4)定义。则有如下结果：
- (1) $\hat{f}(\lambda)$ 是 $f(\lambda)$ 的渐近无偏估计。
 - (2) $\hat{f}(\lambda)$ 是 $f(\lambda)$ 的均方相合估计。
 - (3) 当 N 充分大后，有

$$\text{Var}(\hat{f}(\lambda)) \approx \begin{cases} \frac{M_N}{N} f(\lambda)^2 K^2, & \lambda \neq 0, \pm\pi, \\ 2 \frac{M_N}{N} f(\lambda)^2 K^2, & \lambda = 0, \pm\pi, \end{cases}$$
$$K^2 = \frac{2\pi}{M_N} \int_{-\pi}^{\pi} W_N^2(\lambda) d\lambda.$$

- ▶ 虽然减小 M_N 会减小方差，但是可能增加偏差，降低分辨率。

方差的比较

- **定理4.1** 设 $\{X_t\}$ 是平稳正态序列，有连续可微的谱密度 $f(\lambda)$ ，谱窗函数 $W_N(\lambda)$ 满足§8.3中的条件(1)—(5)。加窗谱估计 $\hat{f}(\lambda)$ 由(3.4)定义。则有如下结果：
- (1) $\hat{f}(\lambda)$ 是 $f(\lambda)$ 的渐近无偏估计。
 - (2) $\hat{f}(\lambda)$ 是 $f(\lambda)$ 的均方相合估计。
 - (3) 当 N 充分大后，有

$$\text{Var}(\hat{f}(\lambda)) \approx \begin{cases} \frac{M_N}{N} f(\lambda)^2 K^2, & \lambda \neq 0, \pm\pi, \\ 2 \frac{M_N}{N} f(\lambda)^2 K^2, & \lambda = 0, \pm\pi, \end{cases}$$
$$K^2 = \frac{2\pi}{M_N} \int_{-\pi}^{\pi} W_N^2(\lambda) d\lambda.$$

- 虽然减小 M_N 会减小方差，但是可能增加偏差，降低分辨率。

方差的比较

- **定理4.1** 设 $\{X_t\}$ 是平稳正态序列，有连续可微的谱密度 $f(\lambda)$ ，谱窗函数 $W_N(\lambda)$ 满足§8.3中的条件(1)—(5)。加窗谱估计 $\hat{f}(\lambda)$ 由(3.4)定义。则有如下结果：
- (1) $\hat{f}(\lambda)$ 是 $f(\lambda)$ 的渐近无偏估计。
 - (2) $\hat{f}(\lambda)$ 是 $f(\lambda)$ 的均方相合估计。
 - (3) 当 N 充分大后，有

$$\text{Var}(\hat{f}(\lambda)) \approx \begin{cases} \frac{M_N}{N} f(\lambda)^2 K^2, & \lambda \neq 0, \pm\pi, \\ 2 \frac{M_N}{N} f(\lambda)^2 K^2, & \lambda = 0, \pm\pi, \end{cases}$$
$$K^2 = \frac{2\pi}{M_N} \int_{-\pi}^{\pi} W_N^2(\lambda) d\lambda.$$

- 虽然减小 M_N 会减小方差，但是可能增加偏差，降低分辨率。

方差的比较

- **定理4.1** 设 $\{X_t\}$ 是平稳正态序列，有连续可微的谱密度 $f(\lambda)$ ，谱窗函数 $W_N(\lambda)$ 满足§8.3中的条件(1)—(5)。加窗谱估计 $\hat{f}(\lambda)$ 由(3.4)定义。则有如下结果：
- (1) $\hat{f}(\lambda)$ 是 $f(\lambda)$ 的渐近无偏估计。
 - (2) $\hat{f}(\lambda)$ 是 $f(\lambda)$ 的均方相合估计。
 - (3) 当 N 充分大后，有

$$\text{Var}(\hat{f}(\lambda)) \approx \begin{cases} \frac{M_N}{N} f(\lambda)^2 K^2, & \lambda \neq 0, \pm\pi, \\ 2 \frac{M_N}{N} f(\lambda)^2 K^2, & \lambda = 0, \pm\pi, \end{cases}$$
$$K^2 = \frac{2\pi}{M_N} \int_{-\pi}^{\pi} W_N^2(\lambda) d\lambda.$$

- 虽然减小 M_N 会减小方差，但是可能增加偏差，降低分辨率。

各谱窗方差比较

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

平稳序列的周期图

加窗谱估计

加窗谱估计的比较

窗名	K^2
截断窗	2.0000
Bartlett	0.6667
Daniell	1.0000
Tukey-Hamming	0.7948
Parzen	0.5392
Bartlett-Priestley	1.2000

分辨率的比较

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

平稳序列的周期图

加窗谱估计

加窗谱估计的比较

- ▶ 谱估计对峰的个数、位置很感兴趣。
- ▶ 两个相邻的峰需要能分开，不被混在一起。
- ▶ 只有谱窗宽度比两个峰距离更短时才有可能分开。

分辨率的比较

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

平稳序列的周期图

加窗谱估计

加窗谱估计的比较

- ▶ 谱估计对峰的个数、位置很感兴趣。
- ▶ 两个相邻的峰需要能分开，不被混在一起。
- ▶ 只有谱窗宽度比两个峰距离更短时才有可能分开。

分辨率的比较

- ▶ 谱估计对峰的个数、位置很感兴趣。
- ▶ 两个相邻的峰需要能分开，不被混在一起。
- ▶ 只有谱窗宽度比两个峰距离更短时才有可能分开。

例4.1(分辨率)

- ▶ 例4.1 考虑AR(4)模型

$$X_t = a_1 X_{t-1} + a_2 X_{t-2} + a_3 X_{t-3} + a_4 X_{t-4} + \varepsilon, \quad t \in \mathbb{Z}$$

其中

$$\{\varepsilon_t\} \sim \text{WN}(0, 4),$$

$$\mathbf{a} = (-0.9337, -1.4599, -0.7528, -0.6355)^T$$

- ▶ 特征多项式有两对共轭复根

$$1.115e^{\pm 1.5i}, \quad 1.125e^{\pm 2.2i}$$

- ▶ 谱密度 $f(\lambda)$ 在 $\lambda = 1.5, 2.2$ 处有明显峰值，距离为 $2.2 - 1.5 = 0.7$ 。(见演示图形)

例4.1(分辨率)

- ▶ 例4.1 考虑AR(4)模型

$$X_t = a_1 X_{t-1} + a_2 X_{t-2} + a_3 X_{t-3} + a_4 X_{t-4} + \varepsilon, \quad t \in \mathbb{Z}$$

其中

$$\{\varepsilon_t\} \sim \text{WN}(0, 4),$$

$$\mathbf{a} = (-0.9337, -1.4599, -0.7528, -0.6355)^T$$

- ▶ 特征多项式有两对共轭复根

$$1.115e^{\pm 1.5i}, \quad 1.125e^{\pm 2.2i}$$

- ▶ 谱密度 $f(\lambda)$ 在 $\lambda = 1.5, 2.2$ 处有明显峰值，距离为 $2.2 - 1.5 = 0.7$ 。(见演示图形)

例4.1(分辨率)

- ▶ 例4.1 考虑AR(4)模型

$$X_t = a_1 X_{t-1} + a_2 X_{t-2} + a_3 X_{t-3} + a_4 X_{t-4} + \varepsilon, \quad t \in \mathbb{Z}$$

其中

$$\{\varepsilon_t\} \sim \text{WN}(0, 4),$$

$$\mathbf{a} = (-0.9337, -1.4599, -0.7528, -0.6355)^T$$

- ▶ 特征多项式有两对共轭复根

$$1.115e^{\pm 1.5i}, \quad 1.125e^{\pm 2.2i}$$

- ▶ 谱密度 $f(\lambda)$ 在 $\lambda = 1.5, 2.2$ 处有明显峰值，距离为 $2.2 - 1.5 = 0.7$ 。(见演示图形)

- ▶ 考虑用Daniell谱窗做谱估计：

$$W_N(\lambda) = \begin{cases} M_N/(2\pi) & |\lambda| \leq \pi/M_N \\ 0 & |\lambda| > \pi/M_N \end{cases}$$

M_N 越大，谱窗越窄。

- ▶ 加窗谱估计为

$$\hat{f}(\lambda) = \frac{M_N}{2\pi} \int_{\lambda - \pi/M_N}^{\lambda + \pi/M_N} I_N(s) ds$$

- ▶ 由周期图的渐近无偏性

$$E\hat{f}(\lambda) \approx \frac{M_N}{2\pi} \int_{\lambda - \pi/M_N}^{\lambda + \pi/M_N} f(s) ds$$

- ▶ 所以 $E\hat{f}(\lambda)$ 是 $f(s)$ 在 λ 的小邻域 $[\lambda - \pi/M_N, \lambda + \pi/M_N]$ 上的近似平均。如果这个小邻域太宽(M_N 太小)，就会把两个峰混在一起。

- ▶ 考虑用Daniell谱窗做谱估计：

$$W_N(\lambda) = \begin{cases} M_N/(2\pi) & |\lambda| \leq \pi/M_N \\ 0 & |\lambda| > \pi/M_N \end{cases}$$

M_N 越大，谱窗越窄。

- ▶ 加窗谱估计为

$$\hat{f}(\lambda) = \frac{M_N}{2\pi} \int_{\lambda - \pi/M_N}^{\lambda + \pi/M_N} I_N(s) ds$$

- ▶ 由周期图的渐近无偏性

$$E\hat{f}(\lambda) \approx \frac{M_N}{2\pi} \int_{\lambda - \pi/M_N}^{\lambda + \pi/M_N} f(s) ds$$

- ▶ 所以 $E\hat{f}(\lambda)$ 是 $f(s)$ 在 λ 的小邻域
 $[\lambda - \pi/M_N, \lambda + \pi/M_N]$ 上的近似平均。如果这个小邻域太宽(M_N 太小)，就会把两个峰混在一起。

- ▶ 考虑用Daniell谱窗做谱估计：

$$W_N(\lambda) = \begin{cases} M_N/(2\pi) & |\lambda| \leq \pi/M_N \\ 0 & |\lambda| > \pi/M_N \end{cases}$$

M_N 越大，谱窗越窄。

- ▶ 加窗谱估计为

$$\hat{f}(\lambda) = \frac{M_N}{2\pi} \int_{\lambda - \pi/M_N}^{\lambda + \pi/M_N} I_N(s) ds$$

- ▶ 由周期图的渐近无偏性

$$E\hat{f}(\lambda) \approx \frac{M_N}{2\pi} \int_{\lambda - \pi/M_N}^{\lambda + \pi/M_N} f(s) ds$$

- ▶ 所以 $E\hat{f}(\lambda)$ 是 $f(s)$ 在 λ 的小邻域
 $[\lambda - \pi/M_N, \lambda + \pi/M_N]$ 上的近似平均。如果这个小邻域太宽(M_N 太小)，就会把两个峰混在一起。

- ▶ 考虑用Daniell谱窗做谱估计：

$$W_N(\lambda) = \begin{cases} M_N/(2\pi) & |\lambda| \leq \pi/M_N \\ 0 & |\lambda| > \pi/M_N \end{cases}$$

M_N 越大，谱窗越窄。

- ▶ 加窗谱估计为

$$\hat{f}(\lambda) = \frac{M_N}{2\pi} \int_{\lambda - \pi/M_N}^{\lambda + \pi/M_N} I_N(s) ds$$

- ▶ 由周期图的渐近无偏性

$$E\hat{f}(\lambda) \approx \frac{M_N}{2\pi} \int_{\lambda - \pi/M_N}^{\lambda + \pi/M_N} f(s) ds$$

- ▶ 所以 $E\hat{f}(\lambda)$ 是 $f(s)$ 在 λ 的小邻域
 $[\lambda - \pi/M_N, \lambda + \pi/M_N]$ 上的近似平均。如果这个小邻域太宽(M_N 太小)，就会把两个峰混在一起。

谱窗宽度的选择

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

平稳序列的周期图

加窗谱估计

加窗谱估计的比较

- ▶ 只有谱窗宽度比两个峰距离小很多时才有可能分开。
- ▶ 但是，谱窗太窄(M_N 太大)，估计方差会变大，估计的结果变得很不光滑，出现许多虚假的峰。
- ▶ 谱密度和谱窗的宽度用带宽来描述。

谱窗宽度的选择

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

平稳序列的周期图

加窗谱估计

加窗谱估计的比较

- ▶ 只有谱窗宽度比两个峰距离小很多时才有可能分开。
- ▶ 但是，谱窗太窄(M_N 太大)，估计方差会变大，估计的结果变得很不光滑，出现许多虚假的峰。
- ▶ 谱密度和谱窗的宽度用带宽来描述。

谱窗宽度的选择

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

平稳序列的周期图

加窗谱估计

加窗谱估计的比较

- ▶ 只有谱窗宽度比两个峰距离小很多时才有可能分开。
- ▶ 但是，谱窗太窄(M_N 太大)，估计方差会变大，估计的结果变得很不光滑，出现许多虚假的峰。
- ▶ 谱密度和谱窗的宽度用带宽来描述。

- ▶ **带宽**：设谱密度 $f(\lambda)$ 连续，在 λ_0 处有一个明显的峰值，如果有 $\omega_1 < \lambda_0 < \omega_2$ 使得

$$f(\omega_1) = f(\omega_2) = \frac{1}{2}f(\lambda_0), \quad (4.3)$$

$$f(\lambda) > \frac{1}{2}f(\lambda_0), \quad \text{当 } \lambda \in (\omega_1, \omega_2),$$

则称 $\omega_2 - \omega_1$ 为 $f(\lambda)$ 在 λ_0 处的带宽。

- ▶ 若 $f(\lambda)$ 在 λ_0 处有一个明显的低谷，如果有 $\omega_1 < \lambda_0 < \omega_2$ 使得

$$f(\omega_1) = f(\omega_2) = 2f(\lambda_0),$$

$$f(\lambda) < 2f(\lambda_0), \quad \text{当 } \lambda \in (\omega_1, \omega_2),$$

则称 $\omega_2 - \omega_1$ 为 $f(\lambda)$ 在 λ_0 处的带宽。

- ▶ **带宽**：设谱密度 $f(\lambda)$ 连续，在 λ_0 处有一个明显的峰值，如果有 $\omega_1 < \lambda_0 < \omega_2$ 使得

$$f(\omega_1) = f(\omega_2) = \frac{1}{2}f(\lambda_0), \quad (4.3)$$

$$f(\lambda) > \frac{1}{2}f(\lambda_0), \quad \text{当 } \lambda \in (\omega_1, \omega_2),$$

则称 $\omega_2 - \omega_1$ 为 $f(\lambda)$ 在 λ_0 处的带宽。

- ▶ 若 $f(\lambda)$ 在 λ_0 处有一个明显的低谷，如果有 $\omega_1 < \lambda_0 < \omega_2$ 使得

$$f(\omega_1) = f(\omega_2) = 2f(\lambda_0),$$

$$f(\lambda) < 2f(\lambda_0), \quad \text{当 } \lambda \in (\omega_1, \omega_2),$$

则称 $\omega_2 - \omega_1$ 为 $f(\lambda)$ 在 λ_0 处的带宽。

谱窗的带宽

- ▶ 加窗谱估计要求谱窗的带宽比谱密度的带宽小很多，才能分辨出谱密度的峰值情况。
- ▶ 半功率带宽 $B_{HP} = 2\theta_1$ ， θ_1 由

$$W_N(\theta_1) = \frac{1}{2} W_N(0).$$

这种谱窗带宽定义与(4.3)的谱密度带宽定义是一致的。

- ▶ **Parzen**带宽 $B_P = 1/W_N(0)$.
- ▶ **Jenkin**带宽

$$B_J = \frac{2\pi}{\sum_{|k| \leq N-1} \lambda_N^2(k)}.$$

- ▶ 增加 M_N 可以减小谱窗的窗宽从而提高分辨率，但是会增大方差。
- ▶ 例4.3 Daniell窗不同窗宽时的分辨率演示。

谱窗的带宽

- ▶ 加窗谱估计要求谱窗的带宽比谱密度的带宽小很多，才能分辨出谱密度的峰值情况。
- ▶ 半功率带宽 $B_{HP} = 2\theta_1$ ， θ_1 由

$$W_N(\theta_1) = \frac{1}{2} W_N(0).$$

这种谱窗带宽定义与(4.3)的谱密度带宽定义是一致的。

- ▶ Parzen带宽 $B_P = 1/W_N(0)$.
- ▶ Jenkin带宽

$$B_J = \frac{2\pi}{\sum_{|k| \leq N-1} \lambda_N^2(k)}.$$

- ▶ 增加 M_N 可以减小谱窗的窗宽从而提高分辨率，但是会增大方差。
- ▶ 例4.3 Daniell窗不同窗宽时的分辨率演示。

谱窗的带宽

- ▶ 加窗谱估计要求谱窗的带宽比谱密度的带宽小很多，才能分辨出谱密度的峰值情况。
- ▶ 半功率带宽 $B_{HP} = 2\theta_1$ ， θ_1 由

$$W_N(\theta_1) = \frac{1}{2} W_N(0).$$

这种谱窗带宽定义与(4.3)的谱密度带宽定义是一致的。

- ▶ **Parzen带宽** $B_P = 1/W_N(0)$.
- ▶ **Jenkin带宽**

$$B_J = \frac{2\pi}{\sum_{|k| \leq N-1} \lambda_N^2(k)}.$$

- ▶ 增加 M_N 可以减小谱窗的窗宽从而提高分辨率，但是会增大方差。
- ▶ 例4.3 Daniell窗不同窗宽时的分辨率演示。

谱窗的带宽

- ▶ 加窗谱估计要求谱窗的带宽比谱密度的带宽小很多，才能分辨出谱密度的峰值情况。
- ▶ 半功率带宽 $B_{HP} = 2\theta_1$ ， θ_1 由

$$W_N(\theta_1) = \frac{1}{2} W_N(0).$$

这种谱窗带宽定义与(4.3)的谱密度带宽定义是一致的。

- ▶ **Parzen带宽** $B_P = 1/W_N(0)$.
- ▶ **Jenkin带宽**

$$B_J = \frac{2\pi}{\sum_{|k| \leq N-1} \lambda_N^2(k)}.$$

- ▶ 增加 M_N 可以减小谱窗的窗宽从而提高分辨率，但是会增大方差。
- ▶ 例4.3 Daniell窗不同窗宽时的分辨率演示。

谱窗的带宽

- ▶ 加窗谱估计要求谱窗的带宽比谱密度的带宽小很多，才能分辨出谱密度的峰值情况。
- ▶ 半功率带宽 $B_{HP} = 2\theta_1$ ， θ_1 由

$$W_N(\theta_1) = \frac{1}{2} W_N(0).$$

这种谱窗带宽定义与(4.3)的谱密度带宽定义是一致的。

- ▶ **Parzen带宽** $B_P = 1/W_N(0)$.
- ▶ **Jenkin带宽**

$$B_J = \frac{2\pi}{\sum_{|k| \leq N-1} \lambda_N^2(k)}.$$

- ▶ 增加 M_N 可以减小谱窗的窗宽从而提高分辨率，但是会增大方差。
- ▶ 例4.3 Daniell窗不同窗宽时的分辨率演示。

谱窗的带宽

- ▶ 加窗谱估计要求谱窗的带宽比谱密度的带宽小很多，才能分辨出谱密度的峰值情况。
- ▶ 半功率带宽 $B_{HP} = 2\theta_1$ ， θ_1 由

$$W_N(\theta_1) = \frac{1}{2} W_N(0).$$

这种谱窗带宽定义与(4.3)的谱密度带宽定义是一致的。

- ▶ **Parzen带宽** $B_P = 1/W_N(0)$.
- ▶ **Jenkin带宽**

$$B_J = \frac{2\pi}{\sum_{|k| \leq N-1} \lambda_N^2(k)}.$$

- ▶ 增加 M_N 可以减小谱窗的窗宽从而提高分辨率，但是会增大方差。
- ▶ 例4.3 Daniell窗不同窗宽时的分辨率演示。