

## 盲信号处理基础知识

- ◆随机矢量及其统计量
- ◆线性方程求解

## 随机矢量及其统计量

- ◆对盲信号处理中所涉及到的随机矢量及其统计量基本概念的介绍
  - 需要有概率论的基本知识
  - 强调一些盲信号处理中常用的一些概念，如相关性，独立性，非高斯性以及各阶统计量

## 概率分布函数

给定随机变量  $\xi$ ，它的取值不超过实数  $x$  的事件概率  $P(\xi \leq x)$  是  $x$  的函数，称为  $\xi$  的概率分布函数，记作

$$F_{\xi}(x) = P(\xi \leq x) \quad (-\infty < x < \infty)$$

概率分布函数的基本性质：

- 1、 $0 \leq F_{\xi}(x) \leq 1$
- 2、若  $x_1 < x_2$ ，则  $F_{\xi}(x_1) < F_{\xi}(x_2)$

## 概率密度函数

如果随机变量  $\xi$  的概率分布函数  $F_{\xi}(x)$  可以表示为：

$$F_{\xi}(x) = \int_{-\infty}^x p_{\xi}(x) dx$$

就称  $\xi$  是连续型随机变量， $p_{\xi}(x)$  是随机变量  $\xi$  的概率密度函数。

概率密度函数的基本性质：

- 1、 $p_{\xi}(x) = \frac{d}{dx} F_{\xi}(x) \geq 0$
- 2、 $\int_{-\infty}^{\infty} p_{\xi}(x) dx = 1$

## 随机变量的函数的概率分布函数

如果随机变量  $\eta$  是随机变量  $\xi$  的函数

$$\eta = f(\xi)$$

则

$$F_{\eta}(x) = \int_{f(y) \leq x} dF_{\xi}(y)$$

$$F_{\eta}(x) = \int_{f(y) \leq x} p_{\xi}(y) dy$$

## 随机矢量的联合概率分布函数

给定随机矢量  $\xi = (\xi_1, \xi_2, \dots, \xi_n)$ ，它的取值不超过实数矢量  $x = (x_1, x_2, \dots, x_n)$  的事件概率  $P(\xi \leq x)$  是  $x$  的函数，称为  $\xi$  的联合概率分布函数，记作

$$F_{\xi}(x) = P(\xi \leq x) \quad (-\infty < x < \infty)$$

## 边缘分布函数

记随机矢量  $\xi = (\xi_1, \xi_2, \dots, \xi_n)$  中任意  $m (m < n)$  个随机变量构成的随机矢量为  $\xi^c = (\xi_1, \xi_2, \dots, \xi_m)$ ，则称随机矢量  $\xi^c$  的联合概率分布函数为随机矢量  $\xi$  的边缘分布函数

$$F_{\xi^c}(x_1, x_2, \dots, x_m) = F_{\xi}(\infty, \dots, \infty, x_1, \dots, \infty, x_m, \dots, \infty)$$

## 统计独立性

随机矢量  $\xi = (\xi_1, \xi_2, \dots, \xi_n)$  的各个随机变量相互独立的条件是：

$$F_{\xi}(x) = \prod_{i=1}^n F_{\xi_i}(x_i)$$

## 随机变量的数字特征

数学期望(Expectation)

如果随机矢量  $\eta$  是随机矢量  $\xi$  的函数

$$\eta = f(\xi)$$

则  $\eta$  的数学期望定义为：

$$E\{\eta\} = \int_{-\infty}^{\infty} f(x) p_{\xi}(x) dx$$

数学期望可以由信号进行估计得到，而不需要知道其概率密度函数

## 矩 (Moment)

若  $\eta = f(\xi)$  中函数为随机矢量  $\xi$  中各个变量的乘积，则得到的  $\eta$  的数学期望被称为矩 (原点矩)

一阶矩：  $m_{\xi} = E\{\xi\} = \int_{-\infty}^{\infty} x p_{\xi}(x) dx$

相关 (Correlation, 二阶矩)

随机矢量  $\xi = (\xi_1, \xi_2, \dots, \xi_n)$  中任意一对变量的互相关定义为：

$$r_{ij} = E\{\xi_i \xi_j\} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x_i x_j p_{\xi_i, \xi_j}(x_i, x_j) dx_i dx_j$$

相关矩阵 (大小为  $n \times n$ )

$$R_{\xi} = E\{\xi \xi^T\} = [r_{ij}]$$

对称的，具有非负的特征值和相互正交的特征向量。

中心矩 (Central moment)

中心矩和原点矩的定义一样，只是在求数学期望前从随机矢量中减去其均值矢量。

协方差(Covariance): 和相关  $r_{ij}$  对应的中心矩

$$c_{ij} = E\{(\xi_i - m_{\xi_i})(\xi_j - m_{\xi_j})\}$$

协方差矩阵

$$C_{\xi} = E\{(\xi - m_{\xi})(\xi - m_{\xi})^T\} = [c_{ij}]$$

对称的，具有非负的特征值和相互正交的特征向量。

$$C_{\xi} = R_{\xi} - m_{\xi} m_{\xi}^T$$

考虑单个随机变量，则一阶矩为均值，二阶原点矩为平均能量，二阶中心矩为方差。

对于两个随机矢量  $\xi, \eta$ ，他们的联合数学期望可以利用他们的联合概率密度得到。两个重要的数字特征是：

互相关矩阵 (Cross-correlation)


$$R_{\xi\eta} = E\{\xi\eta^T\}$$

互协方差矩阵 (Cross-covariance)


$$C_{\xi\eta} = E\{(\xi - m_\xi)(\eta - m_\eta)^T\}$$

度量两个随机矢量  $\xi, \eta$  之间相关性，是二阶统计量。

$x, y$   
负相关



$x, y$   
不相关



考虑离散数字信号  $x_i, i=1, \dots, N$ ，其数字特征可以由信号本身估计得到，而不需要知道其概率密度函数，如

$$m_x = E\{x\} = \frac{1}{N} \sum_{i=1}^N x_i$$


## 高阶统计量 (Higher order statistics, HOS)

基于二阶统计量有许多标准的信号处理技术。使用如下假设


- 1、 信号高斯分布
- 2、 信号是平稳的

当信号是非高斯分布时，高阶统计量携带大量有用的信息。盲反褶积，盲信号分离，独立成分分析都利用了高阶统计量。


## 春江花月夜—统计分析



## 短时谱（振幅谱）



## 直方图



## 统计结果

均值Mean	-4.54256e-005
方差Variance	0.00418846
歪斜度Skewness	0.0442806
三阶统计量	
峰度Kurtosis	5.46975
四阶统计量	

## 高阶矩(Higher order moment)

随机矢量  $\xi$  的  $j$  阶矩的定义为:

$$m_{\xi}^j = E\{\xi^j\} = \int_{-\infty}^{\infty} x^j p_{\xi}(x) dx, \quad j=1, 2, \dots$$

均值:  $j=1$

平均能量:  $j=2$

$j > 2$ : 高阶矩

### 高阶中心矩

和高阶矩定义一样，只是在求高阶矩以前，减去随机矢量  $\xi$  的均值。

零均值随机矢量的高阶中心矩和高阶矩是一致的

后面的分析假设随机矢量为零均值，高阶中心矩和高阶矩是一致的

### 偏斜度 (Skewness)

三阶中心矩被称为 Skewness,

$$m_{\xi}^3 = E\{\xi^3\}$$

可以用来度量随机变量的概率密度函数对称性。

$m_{\xi}^3 = 0$  时，对称的

## 高阶累计量 (Higher order Cumulants)

随机变量  $\xi$  的第一特征函数 (矩生成函数)

$$\Phi(\omega) = E\{\exp(j\omega\xi)\} = \int_{-\infty}^{\infty} \exp(j\omega x) p_{\xi}(x) dx$$

写成 Laplace 算子形式:  $\Phi(s) = E\{e^{s\xi}\}$

对上式求  $k$  阶导数, 得到:  $\Phi^{(k)}(s) = E\{\xi^k e^{s\xi}\}$

则:  $\Phi^{(k)}(0) = E\{\xi^k\} = m_{\xi}^k$

随机变量的第二特征函数 (累计量生成函数)

$$\Psi(s) = \ln(\Phi(s))$$

随机变量  $\xi$  的  $k$  阶累计量定义为上式的  $k$  阶导数在原点的取值

$$c_{\xi}^k = \left. \frac{d^k(\Psi(s))}{ds^k} \right|_{s=0}$$

对于零均值随机变量

$$c_{\xi}^1 = 0 = m_{\xi}^1$$

$$c_{\xi}^2 = m_{\xi}^2$$

$$c_{\xi}^3 = m_{\xi}^3$$

$$c_{\xi}^4 = m_{\xi}^4 - 3(m_{\xi}^2)^2$$

高阶累计量和高阶矩一样, 可以推广到随机矢量。即可以得到互高阶累计量和互高阶矩。

峰度 (Kurtosis)

$$kurt(\xi) = c_{\xi}^4 = m_{\xi}^4 - 3(m_{\xi}^2)^2 \quad \text{四阶累计量}$$

归一化峰度 (Normalized kurtosis)

$$k(\xi) = m_{\xi}^4 / (m_{\xi}^2)^2 - 3$$

具有如下性质:

$$kurt(x+y) = kurt(x) + kurt(y)$$

$$kurt(\alpha x) = \alpha^4 kurt(x)$$

Kurtosis: 一个最简单的非高斯性度量

如果随机变量  $\xi$  是高斯分布的, 则

$$kurt(\xi) = 0, \quad k(\xi) = 0$$

四阶矩没有以上的性质, 这是 Kurtosis 比四阶矩应用广泛的原因。


广义高斯密度函数

$$p_x(x) = \beta e^{\left\{ -\frac{|x|^{\gamma}}{\gamma E\{|x|^{\gamma}\}} \right\}}$$

$\gamma = 2$ , 标准高斯分布

$\gamma > 2$ , SubGaussian, 例如: 均匀分布,  $\gamma \rightarrow \infty$ 。  $kurt(\xi) < 0$

$\gamma < 2$ , SupperGaussian, 例如: Laplace 分布时,  $\gamma = 1$ 。  $kurt(\xi) > 0$



实线: Laplace分布; 虚线: Gaussian分布

高阶统计量的优点:

对非高斯信号, 提供更多的信息

如盲信道估计, 高阶统计量可以提供相位信息。而二阶统计量只提供振幅信息。


对加性高斯噪声不敏感, 时延估计。

高阶统计量的缺点:

1、估计需要大样本。

2、对大野值敏感。

## 时延估计



## 不相关性、独立性和非高斯性 Uncorrelatedness, Independence and NonGaussianity

两个随机矢量  $x, y$  的互协方差矩阵为零, 即  $C_{xy} = 0$ , 则  $x, y$  不相关。

等价于:  $R_{xy} = E\{xy^T\} = E\{x\}E\{y^T\} = m_x m_y^T$

一个随机矢量  $x$  的协方差矩阵为对角阵, 即  $C_{xx} = D$ , 则  $x$  的各个成分变量不相关。

统计独立性:

两个随机变量  $x, y$ , 如果知道  $y$  值, 不能给  $x$  的取值提供任何信息, 则  $x, y$  是独立的, 他们具有如下性质:

$$p_{x,y}(x, y) = p_x(x)p_y(y)$$

$$E\{g(x)h(y)\} = E\{g(x)\}E\{h(y)\}$$

其中,  $g(), h()$  是任意函数。可以看到, 不相关性是  $g(), h()$  为线性函数时的特例。

在 ICA 中, 非高斯性=独立性

中心极限定理:

如果相互独立的具有相同分布的随机变量  $\xi_1, \xi_2, \dots, \xi_n$  的均值和方差均存在, 则他们的和比单个随机变量更趋向高斯分布。

在盲信号处理时, 最大化输出信号的非高斯性等价于最大化输出信号的独立性

## 线性方程组求解

信号处理中的许多问题与线性方程组求解有关

- 1、反褶积问题
- 2、信号分离问题
- 3、盲反褶积问题
- 4、盲信号分离问题

## 问题描述

$$Ax = b$$

其中： $A$  是  $m \times n$  维矩阵， $x$  是  $n \times 1$  向量， $b$  是  $m \times 1$  向量。 $A$  和  $b$  已知。  
很多信号处理问题中， $m > n$ ，称为超定方程组。  
 $m < n$ ，称为欠定方程组。

$\text{Rank}(A) < n$  时，上述方程组是病态的，需要增加别的约束条件，得到唯一解。

## 本节内容：

◆ 从信号处理角度，分别介绍超定方程组的如下解法的特点：

1. 最小二乘解
2. 加权最小二乘解
3. 总体最小二乘解
4. 最小1-范数解
5. 最小 $\infty$ -范数解

## 目标函数（能量函数）

$$E = \|Ax - b\|_p$$

方程组求解是通过最小化上述目标函数实现的。

使用一个假设：噪声只存在于观测信号  $b$  中， $A$  是不含噪声的

$$e = b - Ax$$

选用不同阶范数来构造目标函数，得到不同的解。

## 最小二乘解 (Least-Squares, LS)

$$\text{目标函数：} E = \|Ax - b\|_2$$

$$p = 2$$

最小二乘解为：

$$x_* = (A^T A)^{-1} A^T b$$

最小二乘解为最优解的条件为：

当观测信号  $b$  中的噪声是高斯分布

## 最小1-范数解

$$\text{目标函数：} E = \|Ax - b\|_1$$

$$p = 1$$

当观测信号  $b$  中的噪声是超高斯分布，最小1-范数解优于最小二乘解。

换一句话来说，当观测信号中只有一小部分信号被大的噪声污染，最小1-范数解更合理。

最小1-范数准则被用于稀疏信号表达中。

## 最小1-范数解

最小化  $E = \|Ax - b\|_1$  问题，可以利用多阶 LS 来求解

- 1、求解最小二乘解：  $x_* = (A^T A)^{-1} A^T b$
- 2、计算每个方程对应的偏差：  $e(b) = |b - Ax_*|$   
并判断是否满足终止条件，如不满足，到第3步
- 3、去掉偏差大的方程，利用剩下的  $r$  个方程构成新的方程组：

$$A_r x = b_r$$

返回第1步。

## 最小 $\infty$ -范数解

目标函数：  $E = \|Ax - b\|_\infty$

$$p = \infty$$

当观测信号  $b$  中的噪声是亚高斯分布，最小  $\infty$ -范数解可能优于最小二乘解。

最小  $\infty$ -范数解又被称为最小最大解，即使误差信号  $e$  的绝对最大值最小。

## 加权最小二乘解

不同方程在求解方程组时所起的作用不同，需要采用加权最小二乘技术。  
目标函数：

$$E(x) = (b - Ax)^T \Sigma_e (b - Ax)$$

式中， $\Sigma_e$  是一个正的  $m \times m$  的对角阵

$$\Sigma_e = \text{diag}\{\sigma_1, \sigma_2, \dots, \sigma_m\}$$

$\sigma_i$  越大，对应的方程所带来的误差在目标函数中所起的作用就越大，即该方程越重要。

## 加权最小二乘解

$$x_* = x_{wls} = (A^T \Sigma_e A)^{-1} A^T \Sigma_e b$$

当噪声  $e$  是零均值，其协方差矩阵  $R_e$  是正定的， $\Sigma_e$  用噪声  $e$  的协方差矩阵  $R_e^{-1}$  代替，可以得到最优线性无偏估计 (Best Linear Unbiased Estimator, BLUE)：

$$x_* = x_{BLUE} = (A^T R_e^{-1} A)^{-1} A^T R_e^{-1} b$$

## 总体最小二乘解 (Total least-squares, TLS)

前面分析的方程组的解在实际信号处理中得到广泛的应用，但请记住他们的隐含条件：

噪声只存在于观测信号  $b$  中， $A$  是不含噪声的或者其噪声可以忽略不计。  
考虑噪声不只存在于观测信号  $b$  中，而且存在在  $A$  中，导出 TLS

$$(A + N)x = b + e$$

式中， $N$  是数据矩阵  $A$  中的噪声

## 总体最小二乘解

$$(A + N)x_{TLS} = b + e$$

TLS 试图估计噪声矩阵  $N$  和噪声向量  $e$ ，满足以上的方程组， $x_{TLS}$  是精确解。一般情况下，存在许多噪声矩阵  $N$  和噪声向量  $e$ ，满足以上的方程组。利用以下准则进行选择：

$$\| [N, -e] \|_F^2 = \sum_{i=1}^m e_i^2 + \sum_{i=1}^m \sum_{j=1}^n n_{ij}^2$$



## 总体最小二乘解

重写

$$(A+N)x_{TLS} = b + e$$

为

$$(B+D)z = 0$$

$$\text{式中: } B = [-b \mid A], D = [-e \mid N], z = \begin{bmatrix} 1 \\ x_{TLS} \end{bmatrix}$$

需要估计  $D$ , 使  $B+D$  非满秩。

利用奇异值分解:

$$B = \sum_{i=1}^{n+1} \sigma_i u_i v_i^T$$

其秩为  $n$  的近似矩阵为:  $\tilde{B} = \sum_{i=1}^n \sigma_i u_i v_i^T$

$$\text{则使 } \tilde{B}z = 0 \text{ 的解为: } z = \frac{v_{n+1}}{v_{n+1,1}} = \begin{bmatrix} 1 \\ x_{TLS} \end{bmatrix}$$

## 数据最小二乘解 (data least-squares, DLS)

$e = 0$  时, TLS 被称为 DLS

## 一个简单的直线拟合例子



利用五个点:

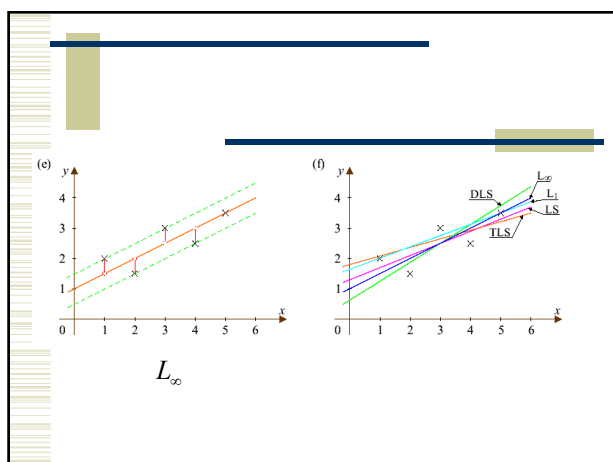
$$(x_k, y_k) = (1, 2), (2, 1.5), (3, 3), (4, 2.5), (5, 3.5)$$

决定一条最优直线:  $y = mx + c$

写成方程组:  $Ax = b$

$$\text{其中: } A = \begin{bmatrix} 1 & 2 & 3 & 4 & 5 \\ 1 & 1 & 1 & 1 & 1 \end{bmatrix}^T, x = [m, c]^T, b = [2 \quad 1.5 \quad 3 \quad 2.5 \quad 3.5]^T$$





## 资料来源和进一步阅读文献

- ♦ Profs. Juha Karhunen and Erkki Oja at the Helsinki University of Technology  
<http://www.cis.hut.fi/projects/ica/book/>
- ♦ Andrzej Cichocki, and Shun-ichi Amari, Adaptive blind signal and image processing: learning algorithms and applications, John Wiley & Sons, Ltd. 2002. 第二章
- ♦ 数学手册，高等教育出版社，1979，概率统计部分