

图 4.12.5 时间平均信干比 (同步 CDMA 系统, 非平稳信道)

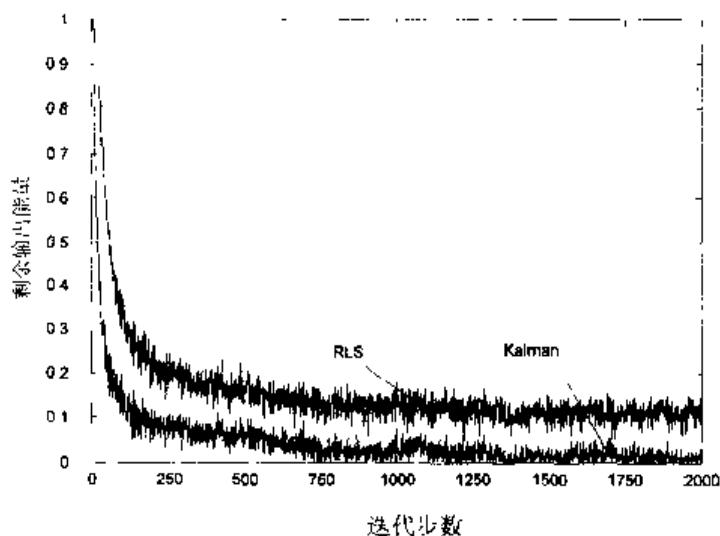


图 4.12.6 时间平均剩余输出能量的测量值 (同步 CDMA 系统, 非平稳信道)

(3) 无论是平稳信道还是非平稳信道, 当 $n > 1200$ 时, Kalman 滤波算法的实测剩余输出能量均接近于理论的零值, 而 LMS 和 RLS 算法的实测剩余输出能量则不等于零。

本 章 小 结

本章的核心内容是滤波器的优化设计及其自适应实现。首先, 从三种角度介绍了不同的滤波器:

- 从信噪比最大原则出发, 讲述了匹配滤波器;
- 从最小均方误差准则出发, 推导了 Wiener 滤波器;

• 从状态空间模型出发，介绍了 Kalman 滤波器及其自适应算法。然后，围绕 Wiener 滤波器的自适应实现，依次介绍了 LMS 和 RLS 两种自适应算法。为了克服横向滤波器收敛慢的缺点，本章介绍了具有对称结构的 LMS 型格型滤波器和具有非对称结构的 LS 格型滤波器。

最后，作为自适应滤波器的应用，分别介绍了自适应谱线增强器与陷波器、广义旁瓣对消器和盲自适应多用户检测器。

习 题

4.1 谐波信号

$$s(t) = A \cos(2\pi f_c t), \quad 0 < t < T, \quad f_c = \frac{1}{T}$$

观测样本为

$$y(t) = s(t) + w(t)$$

其中 $w(t)$ 是一高斯白噪声，其均值为 0，方差为 σ^2 。求匹配滤波器的输出以及它的均值和方差。

4.2 假定发射机轮流发射信号 $s_1(t)$ 和 $s_2(t)$ ，其中

$$\begin{aligned} s_1(t) &= A \cos(2\pi f_c t), \quad 0 < t < T, \quad f_c = \frac{1}{T} \\ s_2(t) &= A \sin(2\pi f_c t), \quad 0 < t < T \end{aligned}$$

忽略信号传输过程中的衰减，且接收机端的观测噪声为白噪声 $w(t)$ ，其均值为 0，方差为 σ^2 。现在接收端设计一匹配滤波器抽取信号 $s_1(t)$ ，求该匹配滤波器的输出。

4.3 令信号为

$$s(t) = \begin{cases} e^{-t}, & t > 0 \\ 0, & t \leq 0 \end{cases}$$

并且加性噪声 $n(t)$ 是一白噪声，其均值为 0，方差为 1。求匹配滤波器的冲激响应 $h_0(t)$ 。

4.4 已知信号 $s(t)$ 的自相关函数

$$R_{ss}(\tau) = A \frac{\sin^2(\alpha\tau)}{\tau^2}$$

加性噪声的自相关函数

$$R_{vv}(\tau) = N\delta(\tau)$$

并且信号与噪声不相关，即 $R_{sv} = E\{s(t)v(t-\tau)\} = 0, \forall \tau$ 。分别求出用观测数据 $x(t) = s(t) + v(t)$ 估计 $s(t)$ 的非因果 Wiener 滤波器 $H(\omega)$ 。

4.5 令 $s(t)$ 是一平稳的随机过程，并且

$$R_{ss}(\tau) = E\{s(t)s(t-\tau)\} = \frac{1}{2}e^{-|\tau|}$$

$$R_{nn}(\tau) = E\{n(t)n(t-\tau)\} = \begin{cases} 1, & \tau = 0 \\ 0, & \tau \neq 0 \end{cases}$$

同时，信号与噪声不相关，即

$$E\{s(t)n(t-\tau)\} = 0, \quad \forall \tau$$

试求因果 Wiener 滤波器的传递函数表达式。

4.6 令 $y(t) = s(t) + n(t)$ 。已知

$$P_{ss}(\omega) = \frac{N_0}{\alpha^2 + \omega^2}$$

$$P_{nn}(\omega) = N \quad \text{和} \quad P_{sn}(\omega) = 0$$

式中 $\alpha > 0$ 。求因果 Wiener 滤波器的传递函数。

4.7 Wiener 滤波器设计 [151]。

(1) 观测数据

$$x(n) = d(n) + v(n)$$

式中，期望信号的相关函数 $R_d(k) = 0.8^{|k|}$ ，并且 $v(n)$ 是一个均值为 0，方差为 1 的白噪声；

(2) 期望信号是一个 AR(1) 过程：

$$d(n) = 0.8d(n-1) + w(n)$$

式中 $w(n)$ 是一白噪声，其均值为 0，方差为 $\sigma_w^2 = 0.36$ 。期望信号 $d(n)$ 与噪声 $v(n)$ 不相关，噪声 $v(n)$ 与 $w(n)$ 不相关，并且观测数据 $x(n)$ 为实信号。

用 Wiener 滤波器对 $x(n)$ 进行滤波，滤波器输出作为期望信号 $d(n)$ 的估计 $\hat{d}(n)$ ，求 $\hat{d}(n)$ 的表达式。

4.8 离散时间信号 $s(n)$ 是一个一阶的 AR 过程，其相关函数 $R_s(k) = \alpha^{|k|}$, $0 < \alpha < 1$ 。令观测数据为 $x(n) = s(n) + v(n)$ ，其中 $s(n)$ 和 $v(n)$ 不相关，且 $v(n)$ 是一个均值为 0，方差为 σ_v^2 的白噪声。设计 Wiener 滤波器 $H(z)$ 。

4.9 令 $H(e^{j\omega})$ 是一无限冲激响应 (IIR) Wiener 滤波器, 其冲激响应系数为 $h(i)$, $s(n)$ 为期望信号, $v(n)$ 为加性噪声, 它与期望信号不相关。求 Wiener 滤波器的最小均方误差 J_{\min} 。

4.10 假定对观测数据 $y(t) = x(t) + v(t)$ 进行直接滤波的滤波器具有传递函数

$$a(t, u) = \frac{m(1+u)^{m-1}}{(1+u^2)}, \quad 0 \leq u \leq t, \quad m > 0$$

求 $y(t)$ 的新息过程, 并设计一作用于新息的滤波器 $b(t, s)$ 。

4.11 假设一观测信号 $y(t) = s(t) + v(t)$ 的功率谱为

$$P_{yy}(\omega) = \frac{\omega^2 + 25}{(\omega^2 + 1)(\omega^2 + 4)}$$

求新息过程 $w(t)$ 和信号 $s(t)$ 的线性均方估计 $\hat{s}(t)$ 的表达式。

4.12 令 $x(t)$ 是一个时不变的标量随机变量, 它在加性白噪声 $v(t)$ 中被观测, 即 $y(t) = x(t) + v(t)$ 为观测数据。若用 Kalman 滤波器自适应估计 $x(t)$, 试设计 Kalman 滤波器:

- (1) 构造离散时间的状态空间方程。
- (2) 求出状态变量 $x(k)$ 的更新公式。

4.13 考虑题 4.12 的两种特殊:

- (1) 加性白噪声 $v(t)$ 的方差无穷大;
- (2) 状态变量 $x(t)$ 的方差无穷大。

讨论在这两种特殊情况下状态变量估计 $\hat{x}(k)$ 的状况。

4.14 AR(1) 过程的 Kalman 滤波估计。状态变量服从 AR(1) 模型:

$$x(n) = 0.8x(n-1) + w(n)$$

式中 $w(n)$ 为白噪声, 其均值为 0, 方差 $\sigma_w^2 = 0.36$ 。观测方程为

$$y(n) = x(n) + v(n)$$

其中 $v(n)$ 是一个与 $w(n)$ 不相关的白噪声, 其均值为 0, 方差 $\sigma_v^2 = 1$ 。用 Kalman 滤波器估计状态变量, 求 $\hat{x}(n)$ 的具体表达式。

4.15 一时变系统的状态转移方程和观测方程分别为

$$\mathbf{x}(n+1) = \begin{bmatrix} 1/2 & 1/8 \\ 1/8 & 1/2 \end{bmatrix} \mathbf{x}(n) + \mathbf{v}_1(n)$$

和

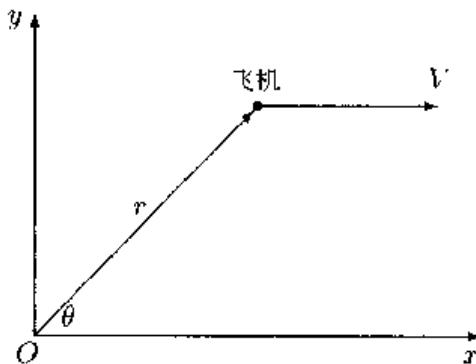
$$y(n) = \mathbf{x}(n) + \mathbf{v}_2(n)$$

式中

$$\begin{aligned} \mathbb{E}\{v_1(n)\} &= \mathbf{0} \\ \mathbb{E}\{v_1(n)v_1^T(k)\} &= \begin{cases} \sigma_1^2 I, & n = k \\ \mathbf{O}, & n \neq k \end{cases} \\ \mathbb{E}\{v_2(n)v_2^T(k)\} &= \begin{cases} \sigma_2^2 I, & n = k \\ \mathbf{O}, & n \neq k \end{cases} \\ \mathbb{E}\{v_1(n)v_2^T(k)\} &= \mathbf{O}, \quad \forall n, k \\ \mathbb{E}\{\mathbf{x}(1)\mathbf{x}^T(1)\} &= I \end{aligned}$$

式中 \mathbf{O} 和 I 分别为零矩阵和单位矩阵。求 $\mathbf{x}(n)$ 的更新公式。

4.16 图题 4.16 是二维雷达跟踪的示意图^[113]。图中，目标飞机以恒速度 V 在 x 方向上飞行，雷达位于原点 O ，飞机到雷达的距离为 r ，方位角为 θ 。为了使雷达跟踪飞机，现在拟使用 Kalman 滤波器对飞机的距离 r 、飞机在雷达视线上的速度 \dot{r} 、方位角 θ 和角速度 $\dot{\theta}$ 进行自适应估计。试针对二维雷达跟踪问题，构造离散时间的状态空间方程。



图题 4.16 雷达跟踪的几何示意图

4.17 一时变的实 ARMA 过程由差分方程

$$y(n) + \sum_{i=1}^p a_i(n)y(n-i) = \sum_{i=1}^q a_{p+i}v(n-i) + v(n)$$

描述，式中 $a_1(n), \dots, a_p(n), a_{p+1}(n), \dots, a_{p+q}(n)$ 为 ARMA 模型参数，过程 $v(n)$ 为输入，而 $y(n)$ 为输出。假定输入过程 $v(n)$ 是一高斯白噪声，方差为 σ^2 。ARMA 模型参数服从一随机扰动模型：

$$a_k(n+1) = a_k(n) + w_k(n), \quad k = 1, \dots, p, p+1, \dots, p+q$$

式中 $w_k(n)$ 是一零均值的高斯白噪声过程，并且与 $w_j(n), j \neq k$ 相互独立，也与 $v(n)$

独立。定义 $(p+q) \times 1$ 维状态向量

$$\boldsymbol{x}(n) = [a_1(n), \dots, a_p(n), a_{p+1}(n), \dots, a_{p+q}(n)]^T$$

并定义测量矩阵 (这里实质为行向量)

$$\boldsymbol{C}(n) = [-y(n-1), \dots, -y(n-p), v(n-1), \dots, v(n-q)]$$

试根据以上条件, 求下列问题的解:

- (1) 建立时变 ARMA 过程的状态空间方程;
- (2) 求更新状态向量 $\boldsymbol{x}(n+1)$ 的 Kalman 自适应滤波算法;
- (3) 如何设定初始值?

4.18 在平稳系统的情况下, 若状态转移矩阵 $\boldsymbol{F}(n+1, n)$ 为单位矩阵, 且状态噪声向量为零。证明预测状态误差相关矩阵 $\boldsymbol{K}(n+1, n)$ 与滤波的状态误差相关矩阵 $\boldsymbol{K}(n)$ 相等。

4.19 在无线通信中, 无线信道常用冲激响应已知的 FIR 滤波器作为模型。若信道输出即接收机接收的信号 $y(n)$ 由

$$y(n) = \boldsymbol{h}^T \boldsymbol{x}(n) + w(n)$$

给出, 式中 \boldsymbol{h} 是一 $M \times 1$ 向量, 表示信道冲激响应, $\boldsymbol{x}(n)$ 为一 $M \times 1$ 向量, 表示信道输入的当前值和 $M-1$ 个以前的发射值; $w(n)$ 为高斯白噪声, 均值为零、方差为 σ_w^2 。在时刻 n , 信道输入 $u(n)$ 由二进制编码 $\{-1, +1\}$ 组成, 与 $w(n)$ 统计独立。因此, 状态方程可写成^[110]

$$\boldsymbol{x}(n+1) = \boldsymbol{A}\boldsymbol{x}(n) + \boldsymbol{e}_1 v(n)$$

式中 $v(n)$ 是均值为零、方差为 σ_v^2 的高斯白噪声, 它与 $w(n)$ 独立。矩阵 \boldsymbol{A} 是一个 $M \times M$ 矩阵, 其元素

$$a_{ij} = \begin{cases} 1, & i = j + 1 \\ 0, & \text{其他} \end{cases}$$

向量 \boldsymbol{e}_1 是一个 $M \times 1$ 向量, 其元素定义为

$$e_i = \begin{cases} 1, & i = 1 \\ 0, & \text{其他} \end{cases}$$

在已知信道模型和含噪声的观测值 $y(n)$ 的情况下, 使用 Kalman 滤波构造一均衡器,

它能够在某个延迟时间 $(n+D)$ 给出信道输入 $v(n)$ 的一估计值, 其中 $0 < D \leq M-1$, 证明: 所构造的均衡器是一个无限冲激响应滤波器, 其系数由两组不同的参数决定:

- (a) $M \times 1$ 信道冲激响应向量;
- (b) Kalman 增益向量 (它是一个 M 维的列向量)。

4.20 考虑一码分多址 (CDMA) 系统, 它共有 K 个用户。假定用户 1 为期望用户, 其特征波形向量 s_1 为已知, 并满足单位能量条件 $\langle s_1, s_1 \rangle = s_1^T s_1 = 1$ 。现有一接收机的观测数据向量为 $y(n)$, 它包含了 K 个用户信号的线性混合。为了检测期望用户的信号, 我们希望设计一多用户检测器 c_1 , 使检测器的输出能量最小化。若多用户检测器服从约束条件 $c_1 = s_1 + U_i w$, 其中 U_i 称为干扰子空间, 意即它的列张成干扰子空间。

- (1) 求线性检测器 c_1 的 LMS 自适应算法。
- (2) 如何计算干扰子空间 U_i ?

4.21 证明下列关系为真:

$$\mathbf{X}_{1,k}(n) = \begin{bmatrix} \mathbf{0}_k^T \\ \mathbf{X}_{1,k-1}(n-1) \end{bmatrix}$$

和

$$\mathbf{P}_{1,k}(n) = \begin{bmatrix} 0 & \mathbf{0}_{k-1}^T \\ \mathbf{0}_{k-1} & \mathbf{P}_{0,k-1}(n-1) \end{bmatrix}$$

式中 $\mathbf{0}_k$ 为 $k \times 1$ 维零向量。

4.22 如果 j 阶最小二乘后向预测误差向量由

$$\mathbf{P}_{0,j-1}^\perp(n) z^{-j} \mathbf{x}(n) = \mathbf{e}_j^b(n)$$

给出, 证明

$$\mathbf{P}_{1,j}^\perp(n) z^{-j-1} \mathbf{x}(n) = z^{-1} \mathbf{e}_j^b(n)$$

4.23 给定一时间信号 $v(n) = [v(1), v(2), v(3), \dots, v(n)]^T = [4, 2, 4, \dots]^T$ 。计算

- (1) 数据向量 $v(2)$ 和 $v(3)$ 。
- (2) 向量 $z^{-1}v(2)$ 和 $z^{-2}v(2)$ 。
- (3) 向量 $z^{-1}v(3)$ 和 $z^{-2}v(3)$ 。

若令 $u = z^{-1}v(n)$, 再计算

- (4) 投影矩阵 $\mathbf{P}_u(2)$ 和 $\mathbf{P}_u(3)$ 。
- (5) 利用 $u(n)$ 求 $v(n)$ 的最小二乘预测。这一预测称为 $v(n)$ 的一步前向预测。
- (6) 前向预测误差向量 $e_1^f(2)$ 和 $e_1^f(3)$ 。

4.24 已知前向和后向预测残差分别为

$$\begin{aligned}\epsilon_m^f(n) &= \langle \mathbf{x}(n), \mathbf{P}_{1,m}^\perp(n) \mathbf{x}(n) \rangle \\ \epsilon_m^b(n) &= \langle z^{-m} \mathbf{x}(n), \mathbf{P}_{1,m}^\perp(n) z^{-m} \mathbf{x}(n) \rangle\end{aligned}$$

和偏相关系数 $\Delta_{m+1}(n) = \langle \mathbf{e}_m^f(n), z^{-1} \mathbf{e}_m^b(n) \rangle$ 。证明

$$\begin{aligned}\epsilon_{m+1}^f(n) &= \epsilon_m^f(n) - \frac{\Delta_{m+1}^2(n)}{\epsilon_m^b(n-1)} \\ \epsilon_{m+1}^b(n) &= \epsilon_m^b(n-1) - \frac{\Delta_{m+1}^2(n)}{\epsilon_m^f(n)}\end{aligned}$$

4.25 构造一格型 IIR 滤波器，使其传递函数为

$$H(z) = \frac{z^2 + 2z + 1}{z^2 - 1.89z + 0.89}$$

4.26 已知信号向量为 $s(n) = [\text{sgn}(\cos(2\pi 155n)), \sin(2\pi 800n), \sin(2\pi 300n + 6 \times \cos(2\pi 60n)), \sin(2\pi 90n), v(n)]^T$ ，其中 $v(n)$ 是在 $[-1, 1]$ 内均匀分布的噪声； $\text{sgn}(x) = +1$ (若 $x > 0$) 或 -1 (若 $x < 0$) 为符号函数。矩阵 \mathbf{A} 为信号混合矩阵，固定为

$$\mathbf{A} = \begin{bmatrix} 1.000 & 0.9966 & 0.9988 & 0.9982 & 0.9985 \\ 0.9966 & 1.0000 & 0.9963 & 0.9995 & 0.9889 \\ 0.9988 & 0.9963 & 1.0000 & 0.9972 & 0.9968 \\ 0.9982 & 0.9995 & 0.9972 & 1.0000 & 0.9996 \\ 0.9985 & 0.9989 & 0.9968 & 0.9996 & 1.0000 \end{bmatrix}$$

令 $\mathbf{x}(n) = \mathbf{As}(n)$ 为观测数据向量，采样频率取 10 kHz。现在希望根据观测数据自适应调制一分离矩阵 \mathbf{W} 得到分离的信号 $\mathbf{x}(n) = \mathbf{W}(n)\mathbf{x}(n)$ ，这一问题称为盲信号分离。试用 LMS 算法

$$\mathbf{W}(n+1) = \mathbf{W}(n) + \mu [\mathbf{g}(\mathbf{y}(n)) \mathbf{y}^T(n) - \mathbf{y}(n) \mathbf{g}(\mathbf{y}^T(n))] \mathbf{W}(n)$$

实现盲信号分离，其中 $\mathbf{g}(n) = [g_1(y_1(n)), \dots, g_5(y_5(n))]^T$ 是一非线性变换矩阵。取 $g_i(y_i(n)) = y_i^3(n)$ 和自适应步长 $\mu = 60 \times 10^{-4}$ 。

在盲信号分离中，常使用串音误差

$$E = \sum_{i=1}^5 \left(\sum_{j=1}^5 \frac{|c_{ij}|}{\max_k |c_{ik}|} - 1 \right) + \sum_{j=1}^5 \left(\sum_{i=1}^5 \frac{|c_{ij}|}{\max_k |c_{kj}|} - 1 \right)$$

作为衡量信号分离的性能指标，式中 c_{ij} 是矩阵 $\mathbf{W}(n)\mathbf{A}$ 的第 (i, j) 个元素。总样本个数取作 4000，画出 200 次独立仿真实验的串音误差随样本个数变化的均值曲线图。

第 5 章 高阶统计分析

在前面几章里，我们使用的信号处理方法是以二阶统计量（时域为相关函数、频域为功率谱）作为数学分析工具的。相关函数和功率谱存在一些缺点，例如它们具有等价性，不能辨识非最小相位系统；又如，它们对加性噪声敏感，一般只能处理加性白噪声的观测数据。为了克服这些缺点，就必须使用三阶或更高阶数的统计量，它们统称高阶统计量。基于高阶统计量的信号分析称为信号的高阶统计分析，也称非高斯信号处理。现在，高阶统计量已成为信号处理的一种有力数学工具。

早在 20 世纪 60 年代，高阶统计量就已被数学家们所研究，但由于当时没有找到应用对象，这一研究并没有获得比较大的发展。只是到了 20 世纪 80 年代后期，信号处理的专家们才使这一研究点燃了燎原之火，并迅速发展成为现代信号处理的一个重要分支。在本章中，我们将系统地介绍信号高阶统计分析的理论、方法及一些典型应用。

5.1 矩与累积量

最常用的高阶统计量是高阶累积量及高阶谱。本节给出高阶矩和高阶累积量的定义。

5.1.1 高阶矩与高阶累积量的定义

特征函数方法是概率论与数理统计的主要分析工具之一。利用特征函数，很容易引出高阶矩和高阶累积量的定义。

考查一连续的随机变量 x 。若它的概率密度函数为 $f(x)$ ，而 $g(x)$ 是一任意函数，则 $g(x)$ 的数学期望定义为

$$E\{g(x)\} \stackrel{\text{def}}{=} \int_{-\infty}^{\infty} f(x)g(x)dx \quad (5.1.1)$$

特别地，当 $g(x) = e^{j\omega x}$ 时，则有

$$\Phi(\omega) \stackrel{\text{def}}{=} E\{e^{j\omega x}\} = \int_{-\infty}^{\infty} f(x)e^{j\omega x}dx \quad (5.1.2)$$

并称之为第一特征函数。换言之，第一特征函数是概率密度函数 $f(x)$ 的 Fourier 反变换。由于概率密度函数 $f(x) > 0$ ，所以第一特征函数 $\Phi(\omega)$ 在原点有最大值，即

$$|\Phi(\omega)| \leq \Phi(0) = 1 \quad (5.1.3)$$

求第一特征函数的 k 阶导数，得

$$\Phi^k(\omega) = \frac{d^k \Phi(\omega)}{d\omega^k} = j^k E\{x^k e^{j\omega x}\} \quad (5.1.4)$$

随机变量 x 的 k 阶（原点）矩 m_k 和中心矩 μ_k 分别定义为

$$m_k \stackrel{\text{def}}{=} E\{x^k\} = \int_{-\infty}^{\infty} x^k f(x) dx \quad (5.1.5a)$$

$$\mu_k \stackrel{\text{def}}{=} E\{(x - \eta)^k\} = \int_{-\infty}^{\infty} (x - \eta)^k f(x) dx \quad (5.1.5b)$$

式中 $\eta = E\{x\}$ 代表随机变量 x 的一阶矩即均值。对于零均值的随机变量 x ，其 k 阶原点矩 m_k 和中心矩 μ_k 等价。在下面的讨论中，均令随机变量和随机信号的均值为零。

显然，在式 (5.1.4) 中令 $\omega = 0$ ，即可求出 x 的 k 阶矩为

$$m_k = E\{x^k\} = (-j)^k \left. \frac{d^k \Phi(\omega)}{d\omega^k} \right|_{\omega=0} = (-j)^k \Phi^{(k)}(0) \quad (5.1.6)$$

由于随机变量 x 的 k 阶矩 $E\{x^k\}$ 可以由第一特征函数生成，故常将第一特征函数 $\Phi(\omega)$ 称为矩生成函数。

第一特征函数的自然对数称为第二特征函数，记作

$$\Psi(\omega) \stackrel{\text{def}}{=} \ln \Phi(\omega) \quad (5.1.7)$$

与 k 阶矩的定义式 (5.1.6) 相类似，也可以定义随机变量 x 的 k 阶累积量为

$$c_{kx} = (-j)^k \left. \frac{d^k \ln \Phi(\omega)}{d\omega^k} \right|_{\omega=0} = (-j)^k \Psi^{(k)}(0) \quad (5.1.8)$$

鉴于此，第二特征函数又称累积量生成函数。

关于单个随机变量 x 的上述讨论很容易推广到多个随机变量。令 x_1, \dots, x_k 是 k 个连续随机变量，它们的联合概率密度函数为 $f(x_1, \dots, x_k)$ ，则这 k 个随机变量的第一联合特征函数定义为

$$\begin{aligned} \Phi(\omega_1, \dots, \omega_k) &\stackrel{\text{def}}{=} E\left\{e^{j(\omega_1 x_1 + \dots + \omega_k x_k)}\right\} \\ &= \int_{-\infty}^{\infty} \cdots \int_{-\infty}^{\infty} f(x_1, \dots, x_k) e^{j(\omega_1 x_1 + \omega_k x_k)} dx_1 \cdots dx_k \end{aligned} \quad (5.1.9)$$