

Tugnait^[190] 将上述代价函数推广到四阶统计量，提出使用代价函数

$$J_4(D) = E\{[x(n-D) - y(n)]^4\} - 3(E\{[x(n-D) - y(n)]^2\})^2 \quad (5.9.43)$$

所期望的时延 D_0 定义为下列优化问题的解：

(1) 若信号 $s(n)$ 的峰度

$$\gamma_{4s} = E\{s^4(n)\} - 3\sigma_s^4 \quad (5.9.44)$$

大于零，则 D_0 是使 $J_4(D)$ 最小化的解；

(2) 若峰度 γ_{4s} 小于零，则 D_0 是使 $J_4(D)$ 最大化的解。

在实际应用中，代价函数为

$$\hat{J}_4(D) = \frac{1}{N} \sum_{n=1}^N [x(n-D) - y(n)]^4 - 3 \left(\frac{1}{N} \sum_{n=1}^N [x(n-D) - y(n)]^2 \right)^2 \quad (5.9.45)$$

式中，峰度 γ_{4s} 可以用式

$$\hat{\gamma}_{4s} = \frac{1}{2}(A_x + A_y) \quad (5.9.46a)$$

估计^[190]，其中

$$A_x = \frac{1}{N} \sum_{n=1}^N x^4(n) - 3 \left[\frac{1}{N} \sum_{n=1}^N x^2(n) \right]^2 \quad (5.9.46b)$$

$$A_y = \frac{1}{N} \sum_{n=1}^N y^4(n) - 3 \left[\frac{1}{N} \sum_{n=1}^N y^2(n) \right]^2 \quad (5.9.46c)$$

时延估计还有一些比较好的方法，由于篇幅关系，这里不再赘述，读者若欲致详，可参考文献 [142] 和 [227]。

5.10 双谱在信号分类中的应用

自动信号分类与目标识别分为三个阶段：(1) 数据采集，(2) 数据表示，(3) 数据分类。在数据表示阶段，从采集的数据中，提取某些隐藏的关键信号特征。这样的表示称为特征向量。分类阶段则通过未知信号的特征与已知信号的特征库的比较，判决未知信号的属类。

由于能够提供相位信息，高阶统计量（特别是双谱）广泛应用于特征提取。双谱的直接应用导致了计算复杂的二维模板匹配，这限制了直接双谱法在实时目标识别

中的应用。为了克服这一困难，需要将双谱变成一维函数或其他有利于实时应用的特征函数。这正是本节将介绍的主要内容。

5.10.1 积分双谱

在许多重要应用（例如雷达目标识别）中，通常要求提取的信号特征应该具有时移不变性、尺度变化性、相位保持性（即相位信息不能被破坏），其理由如下：

- 飞机特别是战斗机通常在作机动飞行，如果目标飞机的特征随飞机的姿态而变化，即特征具有时移变化性，那么这无疑非常不利于雷达目标的识别。
- 不同的飞机具有不同的几何尺寸（尤其是机长和翼宽）。如果信号特征包含了飞机的尺度信息，这将有助于雷达目标识别。
- 相位信息反映了飞机对电磁波的辐射和散射特性，而这些特性直接与飞机的蒙皮和关键部位（如发动机、天线罩、出器口等）有关。

双谱恰好具备以上三种特性，因为累积量和多谱保留了信号的幅度和相位信息，并且与时间无关。此外，累积量和多谱还能够抑制任何高斯有色噪声。然而，由于双谱是二维函数，所以直接使用信号的全部双谱作为信号特征将导致二维的模板匹配，其计算量是庞大的，无法满足实时目标识别的要求。很显然，克服这一困难的解决方法之一是将二维的双谱转变为一维函数。有三种方法可实现双谱的这一转换。转换后的双谱统称积分双谱。

1. 径向积分双谱

Chandran 和 Elgar^[41]最早提出使用积分双谱的相位（phase of radially integrated bispectra, PRIB）作信号特征：

$$\text{PRIB}(a) = \arctan \left(\frac{I_r(a)}{I_i(a)} \right) \quad (5.10.1a)$$

式中

$$I(a) = I_i(a) + jI_r(a) = \int_0^{1/(1+a)} B(f_1, af_1) df_1 \quad (5.10.1b)$$

代表双谱沿双频率平面过原点的径向直线上的积分，其中 $0 < a < 1$ ，且 $j = \sqrt{-1}$ 为虚数。

式 (5.10.1b) 定义的函数 $I(a)$ 称为径向积分双谱，而 $\text{PRIB}(a)$ 则是径向积分双谱的相位。在 PRIB 方法中，需要在训练阶段对每类已知信号计算 $\text{PRIB}(a)$ 的类内均值和类内方差，还需要计算两类信号之间的类间均值和类间方差。然后，选择使

$$\text{类间可分离度} = \frac{\text{两类信号 PRIB 值的均方差}}{\text{所有类间方差之和}} \quad (5.10.2)$$

最大的 K 组 PRIB(a) 作为特征参数组合 $P(1), \dots, P(K)$ 。这些被选择出来的积分路径 a 和对应的积分双谱相位 PRIB(a) 作为信号的特征参数被存储，用作模板。在测试阶段，则对测试样本计算这些积分路径上的 PRIB(a)，并与模板上各类信号的 PRIB(a) 值相比较。最后，选择相似度最大的已知信号类作为测试样本的类别判决结果。

由于只取径向积分双谱的相位，所以丢失了双谱的幅值信息，即 PRIB(a) 没有尺度变化性。显然，如果直接取径向积分双谱

$$RIB(a) = I(a) = \int_0^{1/(1+a)} B(f_1, af_1) df_1 \quad (5.10.3)$$

本身作特征参数，则 RIB(a) 将同时具有时移不变性、尺度变化性和相位保持性。

2. 轴向积分双谱

另一种积分双谱由 Tugnait 提出^[191]，其积分路径与 ω_1 轴或 ω_2 轴平行。

令 $B(\omega_1, \omega_2)$ 表示信号 $x(t)$ 的双谱，并记

$$y(t) \stackrel{\text{def}}{=} x^2(t) - E\{x^2(t)\} \quad \text{和} \quad \tilde{y}(t) \stackrel{\text{def}}{=} x^2(t) \quad (5.10.4)$$

则轴向积分双谱 (axially integrated bispectra, AIB) 定义为

$$\begin{aligned} AIB(\omega) &= P_{\tilde{y}x}(\omega) = \frac{1}{2\pi} \int_{-\infty}^{\infty} B(\omega, \omega_2) d\omega_2 \\ &= \frac{1}{2\pi} \int_{-\infty}^{\infty} B(\omega_1, \omega) d\omega_1 \end{aligned} \quad (5.10.5)$$

式中

$$P_{\tilde{y}x}(\omega) \stackrel{\text{def}}{=} \int_{-\infty}^{\infty} E\{\tilde{y}(t)x(t+\tau)e^{-j\omega\tau}\} d\tau \quad (5.10.6)$$

AIB(ω) 的估计方差与功率谱的估计方差相等，因而比双谱的估计方差小得多。另外，AIB(ω) 保留了双谱的幅值信息，从而具有尺度变化性。但是，AIB 方法存在一个缺点：丢失了双谱的大部分相位信息。其解释如下：从式 (5.10.5) 和式 (5.10.6) 容易看出，由于 $E\{\tilde{y}(t)x(t)\} = E\{x(t)x(t)x(t+\tau)\} = c_{3x}(0, \tau)$ ，所以

$$AIB(\omega) = \int_{-\infty}^{\infty} c_{3x}(0, \tau) e^{-j\omega\tau} d\tau \quad (5.10.7)$$

即 AIB(ω) 只是累积量切片 $c_{3x}(0, \tau)$ 的 Fourier 变换，而其他切片 $c_{3x}(m, \tau), m \neq 0$ 相对应的双谱相位信息被丢失了。

3. 圆周积分双谱

第三种积分双谱为圆周积分双谱 (circularly integrated bispectra, CIB)，是 Liao 和 Bao 提出的 [116]。与径向积分双谱和轴向积分双谱不同，圆周积分双谱的积分路径是以原点为中心的圆周，即

$$\text{CIB}(a) = \int B_p(a, \theta) d\theta \quad (5.10.8)$$

式中 $B_p(a, \theta)$ 是双谱 $B(\omega_1, \omega_2)$ 的极坐标表示，即 $B_p(a, \theta) = B(\omega_1, \omega_2)$ ，其中 $\omega_1 = a \cos \theta$ 和 $\omega_2 = a \sin \theta$ 。

由于当 k 为整数时，双谱 $B_p(a, k\pi/2)$ 不提供任何相位信息，而 k 接近 2π 时， $B_p(a, k/2)$ 只提供很少的相位信息，这些双谱不应该被积分。因此，需要使用加权圆周积分双谱 (WCIB) 代替 CIB：

$$\text{WCIB}(a) = \int w(\theta) B_p(a, \theta) d\theta \quad (5.10.9)$$

式中 $w(\theta)$ 取很小的值，若 $\theta \approx k\pi/2, k$ 为整数。

总结以上讨论，我们可以看出，上述积分双谱都可视为某种形式的轴向积分双谱：

- AIB 是双谱 $B(\omega_1, \omega_2)$ 的轴向积分双谱，其积分路径与 ω_1 或 ω_2 轴平行。
- RIB 是双谱极坐标形式 $B_p(a, \theta)$ 的轴向积分双谱，其积分路径与 a 轴平行。
- PRIB 是 RIB 的相位。
- CIB 是双谱极坐标形式 $B_p(a, \theta)$ 的轴向积分双谱，其积分路径与 θ 轴平行。

积分双谱将二维的双谱函数变成了一个一维函数，有利于实时目标识别的实现。但是，这类方法存在以下共同的缺点。

(1) 积分双谱的计算机实现通常是将一条路径上的积分相加的结果。显然，某条路径的积分双谱被选择作为信号特征，是指这条路径上所有的双谱之和在目标识别中起着重要的作用。但是，这并不意味着该路径上的每一个双谱都对目标识别起重要作用。换言之，可能存在某些双谱点，它们对目标识别所起作用不大，属平凡的双谱。

(2) 如果原观测信号存在交叉项 (高分辨雷达的距离像就是这样的典型例子)，则通过三次相关函数得到三阶累积量时，交叉项将更严重。因此，得到的双谱估计中，交叉项一般比较严重。由于交叉项是随机分布的，所以在被选择的积分路径里，交叉项将很难避免。通常，交叉项对目标识别是有害的。

5.10.2 选择双谱

为了克服积分双谱的上述缺点, Zhang 等人提出了选择双谱方法^[222]。所谓选择双谱, 就是只有那些具有最强类可分离度的双谱才被选作信号的特征参数。显然, 这既可以避免平凡双谱, 也可以避免交叉项。

为了选择最强的双谱集合作特征参数集合, 首先需要有一个类可识别测度 $m(\omega)$ 来判断一个双谱值在信号类型识别中作用的大小。Fisher 类可分离度就是这样一个有名的测度。

考虑使用双谱作为第 i 类和第 j 类信号的类间可分离度。为方便叙述, 记 $\omega = (\omega_1, \omega_2)$ 和 $B(\omega) = B(\omega_1, \omega_2)$ 。假定 $\{B_k^{(i)}(\omega)\}_{k=1, \dots, N_i}$ 和 $\{B_k^{(j)}(\omega)\}_{k=1, \dots, N_j}$ 是在训练阶段得到的样本双谱集合, 其中, 下标 k 表示由第 k 组观测数据计算得到的双谱, 上标 i 和 j 表示信号的类型, 而 N_i 和 N_j 分别是第 i 类和第 j 类信号的观测数据组的个数。以三类信号为例, 我们需要分别计算 $m^{(12)}(\omega), m^{(23)}(\omega)$ 和 $m^{(13)}(\omega)$ 。

第 i 类和第 j 类信号之间的 Fisher 可分离度定义为

$$m^{(i,j)}(\omega) = \frac{\sum_{l=1, j} p^{(l)} \left[\text{mean}_k(B_k^{(l)}(\omega)) - \text{mean}_l[\text{mean}_k(B_k^{(l)}(\omega))] \right]^2}{\sum_{l=i, j} p^{(l)} \text{var}_k(B_k^{(l)}(\omega))}, \quad i \neq j \quad (5.10.10)$$

式中, $p^{(l)}$ 为随机变量 $B^{(l)} = B_k^{(l)}(\omega)$ 的先验概率, $\text{mean}_k(B_k^{(l)}(\omega))$ 和 $\text{var}_k(B_k^{(l)}(\omega))$ 分别代表第 l 类信号在频率 $\omega = (\omega_1, \omega_2)$ 处的所有样本双谱的平均值和方差, 而 $\text{mean}_l[\text{mean}_k(B_k^{(l)}(\omega))]$ 表示所有类型的信号在频率 ω 的样本双谱的总体中心。一般情况下, 可对各类信号取相同的先验概率 $p^{(l)}$ 。因此, $p^{(l)}$ 可从式 (5.10.10) 中撤掉。

$m^{(i,j)}(\omega)$ 越大, 则第 i 类和第 j 类信号之间的可分离度越强。因此, 选择具有 Q 个最强 Fisher 类可分离度的频率集合 $\{\omega(h), h = 1, \dots, Q\}$ 作为特征频率。中心频率称为在双频率平面的选择频率。与它们相对应的双谱则称为选择双谱。

给定第 l 类信号第 k 个观测数据为 $x_k^{(l)}(1), \dots, x_k^{(l)}(N)$, 其中 $l = 1, \dots, c$ 和 $k = 1, \dots, N_l$ 。下面是离线的训练算法。

算法 5.10.1 (离线训练算法)

步骤 1 计算观测数据的 Fourier 变换 $X_k^{(l)}(\omega)$ 。

步骤 2 计算双谱

$$B_k^{(l)}(\omega) = B_k^{(l)}(\omega_1, \omega_2) = X_k^{(l)}(\omega_1)X_k^{(l)}(\omega_2)X_k^{(l)}(-\omega_1 - \omega_2)$$

步骤 3 使用式 (5.10.10) 计算所有可能的类组合 (i, j) 的 Fisher 类可分离度

$m^{(i,j)}(\omega)$, 将 M 个最大的测度排序成

$$m^{(ij)}(\nu_1) \geq m^{(ij)}(\nu_2) \geq \cdots \geq m^{(ij)}(\nu_M)$$

步骤 4 计算归一化的 Fisher 类可分离度

$$\bar{m}^{(ij)}(\nu_p) = \sqrt{\frac{m^{(ij)}(\nu_p)}{\sum_{k=1}^M [m^{(ij)}(\nu_k)]^2}}, \quad p = 1, \dots, M \quad (5.10.11)$$

用它确定 (i, j) 类间的选择双谱的“有效个数”，并用 $H^{(ij)}$ 表示之。相对应的频率 $\{\omega^{(ij)}(p), p = 1, \dots, H^{(ij)}\}$ 称为“有效”频率。对不同的 (i, j) 类，相同的有效频率只取一次。

步骤 5 将得到的有效频率 $\omega^{(ij)}(p), p = 1, \dots, H^{(ij)}$ 排成序列 $\omega(q), q = 1, \dots, Q$ ，其中 $Q = \sum_{(i,j)} H^{(ij)}$ 。将第 k 信号的选择双谱也排成序列 $\{B_k^{(l)}(q), q = 1, \dots, Q\}, k = 1, \dots, N_l$ 。第 1 类信号的特征向量记为 s_1, \dots, s_{N_1} ，第 2 类信号的特征向量记为 $s_{N_1+1}, \dots, s_{N_1+N_2}$ ，第 c 类信号的特征向量记为 $s_{N_1+\dots+N_{c-1}+1}, \dots, s_{N_1+\dots+N_c}$ 。这些特征向量都具有最强的 Fisher 类可分离度。

步骤 6 用选择的双谱训练径向基神经网络(分类器)。

上述算法中的双谱换成积分双谱 PRIB, RIB, AIB 或 CIB, 即构成积分双谱的训练算法。

考虑三类信号分类的径向基神经网络。令 s_1, \dots, s_{N_1} 是第一类信号的特征向量， $s_{N_1+1}, \dots, s_{N_1+N_2}$ 是第二类信号的特征向量，而 $s_{N_1+N_2+1}, \dots, s_{N_1+N_2+N_3}$ 是第三类信号的特征向量。

令 $\mathbf{H} = [h_{ij}]_{(N_1+N_2+N_3)(N_1+N_2+N_3)}$ 表示隐层节点的输出矩阵，其中

$$h_{ij} = \exp\left(-\frac{\|s_i - s_j\|^2}{\sigma^2}\right) \quad (5.10.12)$$

其中，高斯核函数的方差 σ^2 是所有特征向量 $s_i, i = 1, \dots, N_1 + N_2 + N_3$ 的总体方差。于是，径向基神经网络的权矩阵由下式给出：

$$\mathbf{W} = (\mathbf{H}^\top \mathbf{H})^{-1} \mathbf{H}^\top \mathbf{O} \quad (5.10.13)$$

式中 \mathbf{O} 是 $(N_1 + N_2 + N_3) \times 3$ 期望输出矩阵，定义为

$$\mathbf{O} = \begin{bmatrix} 1 & \cdots & 1 & 0 & \cdots & 0 & 0 & \cdots & 0 \\ 0 & \cdots & 0 & 1 & \cdots & 1 & 0 & \cdots & 0 \\ 0 & \cdots & 0 & 0 & \cdots & 0 & 1 & \cdots & 1 \end{bmatrix} \quad (5.10.14)$$

其中，第 1 行、第 2 行和第 3 行的元素 1 的个数分别为 N_1, N_2 和 N_3 。

一旦作为分类器的径向基神经网络训练好后，只要存储神经网络的权矩阵 W 即可。

令 $x = [B(1), \dots, B(Q)]^T$ 是从一组观测数据计算的双谱，它们分别是 Q 个选择频率的样本双谱。将这一向量输入到训练好的径向基神经网络，则神经网络隐层节点的输出向量为

$$h_i = \exp\left(-\frac{\|x - s_i\|^2}{\sigma_i^2}\right) \quad (5.10.15)$$

式中，高斯核函数的方差 σ_i^2 是在训练阶段确定的特征向量 s_i 的方差。最后，径向基神经网络的输出向量由下式给出：

$$o = W^T h \quad (5.10.16)$$

由它即可判决观测数据向量属于哪一类信号。

5.10.3 实验结果

实验数据包括微波暗室的高分辨雷达距离像和远场高分辨雷达的实测距离像。

例 5.10.1 一实验雷达在微波暗室中分别观测三种模型飞机 (B52, Q6 和 Q7) 的原始数据。对这些数据进行 Fourier 反变换后，得到 1084 组距离像。其中，B52 的距离像有 322 组，而 Q6 和 Q7 的距离像分别有 311 和 451 组。三种模型飞机中，B52 和 Q6 的机长近似相等，而 Q6 和 Q7 的翼宽相差很小。在这些距离像中，第 1, 6, 11, … 组距离像作为训练样本集，其他作为测试样本集。原始数据的信噪比约为 25dB。通过加入高斯白噪声后，又得到信噪比为 10dB 的 1084 组距离像。图 5.10.1 和图 5.10.2 分别画出了在不同信噪比情况下，四种方法 (选择双谱、RIB、AIB 和 CIB) 的识别率随特征个数的变化关系。

例 5.10.2 飞机位于远场，用 ISAR 雷达实际测量得到原始数据，经过 Fourier 反变换后，共得到三种飞机的距离像 (雅克 12 飞机为 131 组，安 20 为 111 组，螺旋桨飞机为 83 组)。仍然采用第 1, 6, 11, … 组作为训练样本，其他数据作测试样本。原始数据的信噪比约为 23dB，添加高斯白噪声后，又得到信噪比 10dB 的另一数据集合。图 5.10.3 和图 5.10.4 分别画出了选择双谱、RIB、AIB 和 CIB 等四种双谱方法的识别率随特征个数的变化关系。

从图 5.10.1 ~ 图 5.10.4 可以看出以下结果：

(1) 由于只使用了三阶累积量切片 $c_{3x}(0, \tau)$ ，AIB 方法的识别率最低。这一事实反映出保持相位信息对雷达目标识别的重要性。

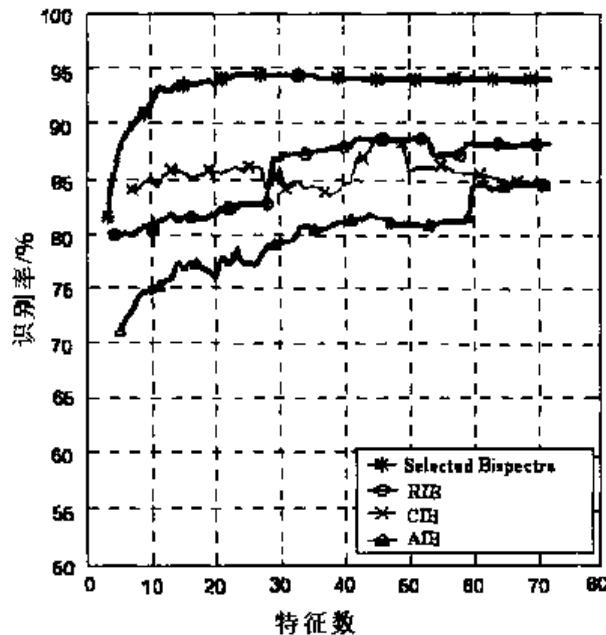


图 5.10.1 识别率随特征个数的变化关系 (微波暗室数据, $\text{SNR} = 25\text{dB}$)

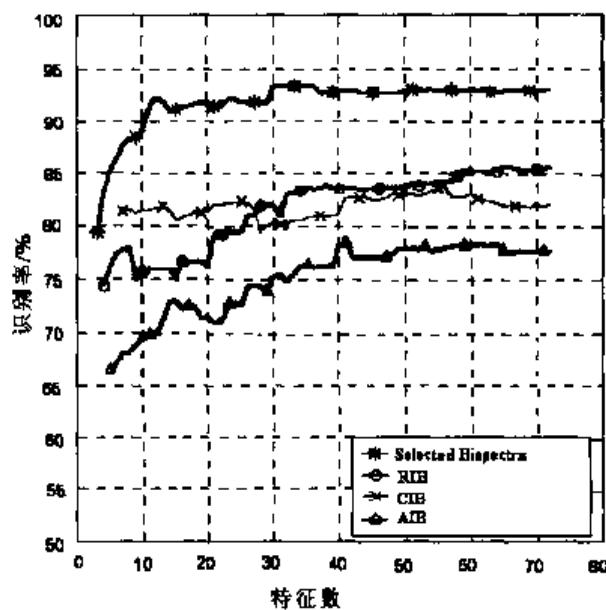


图 5.10.2 识别率随特征个数的变化关系 (微波暗室数据, $\text{SNR} = 10\text{dB}$)

(2) 由于保持了尺度变化性和所有相位信息, RIB 和 CIB 方法具有比较高的分辨率。

(3) 在四种双谱方法中, 选择双谱方法具有最高的识别率。特别地, 当特征个数大于 10 时, 选择双谱方法的识别率对特征个数的变化不敏感。因此, 特征个数容易确定。

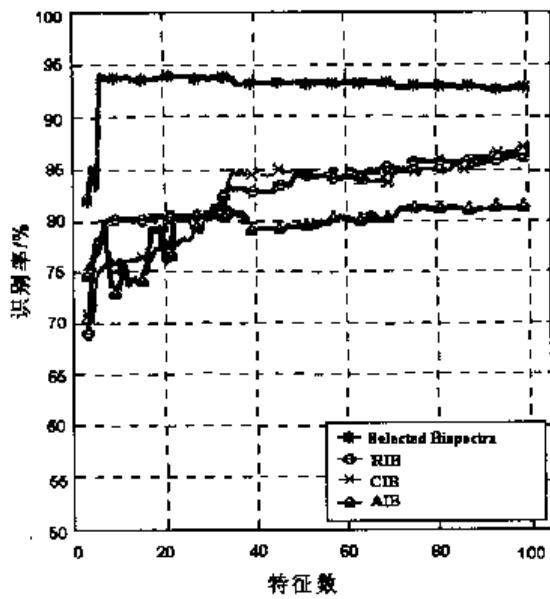


图 5.10.3 识别率与特征个数的关系比较 (实测数据, SNR = 23dB)

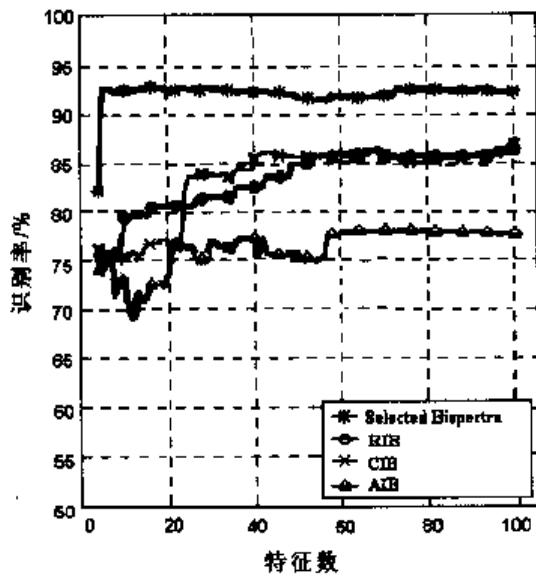


图 5.10.4 识别率与特征个数的关系比较 (实测数据, SNR = 10dB)

本章小结

本章介绍了非高斯信号的高阶统计分析与处理的理论、方法及应用。首先，引出了矩、累积量和高阶谱的定义，并分别讨论了它们的数学性质。然后，重点介绍了基于高阶累积量的非最小相位系统的辨识、谐波恢复以及自适应滤波的理论与方

法。最后，以时延估计和雷达目标识别为例，介绍了如何利用累积量和高阶谱解决实际的工程问题。

可以说，信号的高阶统计分析实际上是我们所熟悉的基于相关函数和功率谱的随机信号统计分析的推广与深入。分析信号更深层次的统计信息正是高阶统计信号分析要达到的主要目的。

习 题

5.1 令 x_1, x_2, \dots, x_n 是 n 个独立的高斯随机变量，它们的均值为 μ 、方差为 σ^2 ，即对于 $i = 1, \dots, n$ 有

$$\begin{aligned} E\{x_i\} &= \mu \\ \text{var}(x_i) &= E\{[x_i - \mu]^2\} = \sigma^2 \end{aligned}$$

令

$$\bar{x} = \frac{1}{N} \sum_{i=1}^n x_i$$

试求样本均值 \bar{x} 的概率密度分布。

5.2 令 x 是一高斯随机向量，其均值（向量）为 v ，协方差矩阵为 R 。证明 x 的矩生成函数为

$$\Phi(x) = \exp(\omega^\top v + 0.5\omega^\top R\omega)$$

5.3 若有限能量信号 $x(n)$ 的 k 阶矩定义为

$$m_{kx}(\tau_1, \dots, \tau_{k-1}) \stackrel{\text{def}}{=} \sum_{n=-\infty}^{\infty} x(n)x(n+\tau_1)\cdots x(n+\tau_{k-1})$$

一序列由 $x(n) = a^n u(n)$ 给出，其中 $-1 < a < 1$ ，且 $u(n)$ 是一单位阶跃函数。试求 $x(n)$ 的矩 $m_{1x}, m_{2x}(\tau), m_{3x}(\tau_1, \tau_2)$ 和 $m_{4x}(\tau, \tau, \tau, \tau)$ 。

5.4 标量随机变量 x 的 k 阶累积量 c_{kx} 定义为 $k \times 1$ 向量 $[x, \dots, x]^\top$ 的累积量。证明

$$c_{kx} = \left. \frac{d^k \Psi_x(\omega)}{d\omega^k} \right|_{\omega=0}$$

式中 $\Psi_x(\omega)$ 是标量随机变量 x 的累积量生成函数。

5.5 令 x 具有平移的指数分布 $f(x) = e^{-(x+1)}, x \geq -1$ (x 平移 -1 是为了使 x 的均值等于零)。试求 $c_{kx} = \text{cum}(x, \dots, x)$ 。