

基于复高斯模型的雷达高分辨距离像目标识别新方法

王鹏辉 杜 兰 刘宏伟

(西安电子科技大学雷达信号处理国家重点实验室, 陕西 西安 710071)

摘要 为了利用雷达高分辨距离像(HRRP)中的相位信息改善识别系统性能,提出了一类针对复距离像的目标识别新方法。分析了复距离像的统计特性,将识别领域常用的三种高斯模型——自适应高斯分类器(AGC)模型、联合高斯(JG)模型和概率主分量分析(PPCA)模型推广至复数域对复距离像统计建模。研究表明,这三种模型及其参数估计结果均不受距离像初相的影响。此外,为了解决噪声环境中的稳健识别问题,进一步提出了噪声稳健的模型修正方法。实验结果显示:在识别过程中加入距离像相位信息能够获得更高的正确识别率;且经过噪声稳健修正后的模型大幅改善了低信噪比下的识别性能。

关键词 信号处理;模式识别;雷达目标识别;复高斯模型;高分辨距离像;噪声稳健

中图分类号 TN959.1+7 **文献标识码** A **doi**: 10.3788/AOS201434.0228004

A New Method Based on Complex Gaussian Models for Radar High Resolution Range Profile Target Recognition

Wang Penghui Du Lan Liu Hongwei

(National Key Laboratory of Radar Signal Processing, Xidian University, Xi'an, Shaanxi 710071, China)

Abstract This paper develops a new recognition method utilizing the phase information to improve the performance of radar high resolution range profile (HRRP) target recognition system. The statistical properties of complex HRRPs are analyzed, and three common Gaussian models, which are adaptive Gaussian classifier (AGC) model, jointly Gaussian (JG) model and probabilistic principal component analysis (PPCA) model, are generalized to the complex domain to model complex HRRPs. It is demonstrated that the structures and parameter estimators of the three complex models are invariant to the initial phase. Furthermore, to enhance the recognition performance under low signal-to-noise ratio (SNR) conditions, a noise robust modification algorithm is introduced. Experimental results show that the proposed method can obtain higher average correct recognition rates. Also, the modified models can deal well with the noisy test samples.

Key words signal processing; pattern recognition; radar target recognition; complex Gaussian model; high resolution range profile; noise robust

OCIS codes 280.5600; 000.5490; 070.5010; 100.5010

1 引 言

雷达目标识别是指利用目标反射的雷达信号对目标的类别或型号作出判断。常用的雷达目标识别手段主要分为以下两类:1)基于二维合成孔径雷达(SAR)图像/逆合成孔径雷达(ISAR)图像的目标识别^[1-5];2)基于一维高分辨距离像(HRRP)的目标识别。与SAR/ISAR图像相比,高分辨距离像具有获取容易、处理简单以及实时性好等优点,因此成为

研究的热点^[6-8]。

高分辨距离像(以下简称距离像)是复向量,包含了重要的目标结构信息,如散射中心的相对位置以及散射强度等。这些信息都包含在复距离像的幅度和相位中。为了避免复距离像初相敏感性的影响,已有的识别工作大多都丢掉了复距离像的相位,只使用其幅度(即实距离像)进行识别^[6-8]。这些方法存在以下问题:1)距离像相位所含的目标信息在

收稿日期: 2013-08-01; **收到修改稿日期**: 2013-09-16

基金项目: 国家自然科学基金(61271024, 61201292, 61201283)、新世纪优秀人才支持计划(NCET-09-0630)、全国优秀博士学位论文作者专项资金(FANEDD-201156)、国防预研基金、中央高校基本科研业务费专项资金

作者简介: 王鹏辉(1984—),男,博士,讲师,主要从事雷达目标识别方面的研究。

E-mail: wangpenghui@mail.xidian.edu.cn

识别过程中未加以利用;2)许多统计识别方法为了降低统计建模的复杂度,近似认为实距离像服从高斯分布^[7-8],模型与数据之间存在失配。以上问题都将导致识别性能受到限制。为了克服这些问题,一些工作探索了基于复距离像的识别方法。文献[9]中对复距离像统计建模并识别,取得了较好的识别结果。但该方法只针对转台仿真数据,回避了实际应用中存在的初相敏感性问题。文献[10]中将循环移位后的复距离像与原始复距离像共轭点乘来消除初相项。新生成的复距离像保留了原始复距离像中的部分相位信息,提高了识别率,但是新距离像的统计特性非常复杂,难以对其精确建模。文献[11-12]中分别采用不同方法从复距离像序列中提取强散射中心,计算其高阶矩作为特征,并利用隐马尔可夫模型进行识别。这类方法在特征提取过程中利用了相位信息,识别性能良好。然而它要求录取训练和测试样本序列时的信号重频相同且目标姿态变化一致,这些条件在实际测量当中不一定满足。

针对以上方法中存在的问题,本文在分析复距离像统计特性的基础上,提出使用复高斯模型对其统计建模,并采用 Bayes 分类器进行识别。该方法不受距离像初相的影响,且对数据录取没有要求,在识别过程中完整地利用了复距离像的相位信息。实测数据的实验结果表明,该方法能够有效提高识别系统的性能。

2 复距离像统计特性分析

本节将介绍复距离像的初相敏感性并分析其对复距离像统计特性的影响。为了克服复距离像的姿态敏感性、平移敏感性和幅度敏感性,在下面的分析中假设已将复距离像样本进行了分帧、归一化和对齐^[7-8]等预处理操作。

根据散射中心模型^[13],任一帧中第 m ($m=1, 2, \dots, M$) 个复距离像样本可表示为

$$\mathbf{x}(m) = \exp(j\theta_{m0}) [x_1(m), x_2(m), \dots, x_d(m)]^T, \quad (1)$$

式中 $\theta_{m0} = -4\pi R(m)/\lambda$ 为初相, λ 为波长, $R(m)$ 为雷达到目标参考中心的距离,上标 T 为转置操作符,第 n ($n=1, 2, \dots, d$) 个距离单元的合成回波为

$$x_n(m) = \sum_{l=1}^{V_n} \sigma_{nl}(m) \exp[j\phi_{nl}(m)] = \gamma_n(m) \exp[j\varphi_n(m)], \quad (2)$$

式中 V_n 为该距离单元的散射中心数目, $\sigma_{nl}(m)$ 和

$\phi_{nl}(m)$ 分别为该距离单元中第 l 个散射中心的散射强度与相位, $\gamma_n(m)$ 和 $\varphi_n(m)$ 分别为该距离单元合成回波的幅度与相位。

观察(1)式和(2)式可知,复距离像中的相位信息由以下两部分组成:

1) 初相 θ_{m0} 。给定 λ , θ_{m0} 完全由 $R(m)$ 决定,与目标结构没有关系,因此 θ_{m0} 对识别无用;

2) 各距离单元合成回波相位 $\varphi_n(m)$ 。它反映了目标上各距离单元中散射中心的强度与相对位置,因此包含了目标结构信息,可用于识别。

宽带雷达通常发射高频信号,其回波初相对目标距离的变化非常敏感。假设发射信号载频为 5.5 GHz,波长 λ 约为 5.4 cm,当 $R(m)$ 变化 1.35 cm 时,初相的变化为 π ,此时整个回波将会反相,这就是所谓的初相敏感性。若将初相项视为乘性噪声,则所有运动目标的距离像都会受该噪声的影响。现有雷达的测距精度还不足以准确补偿初相,而各距离单元的回波相位 $\varphi_n(m)$ 又总是与初相 θ_{m0} 相互耦合,这就阻碍了目标识别中利用 $\varphi_n(m)$ 进行判别。下面从统计分析的角度出发,讨论初相对复距离像的影响。

不失一般性,假设 $R(m)$ 均匀变化,则 θ_{m0} 在 $[0, 2\pi)$ 上服从均匀分布,记为

$$\theta_{m0} \sim U(\theta_{m0} | 0, 2\pi). \quad (3)$$

通常认为各距离单元回波 $x_n(m)$ 服从均值为零的循环对称复高斯分布^[14-15](以下简称复高斯分布),记为

$$x_n(m) \sim CG[x_n(m) | 0, \sigma_{x_n(m)}^2], \quad (4)$$

式中 $\sigma_{x_n(m)}^2$ 为 $x_n(m)$ 的方差。由复高斯分布的性质可知, $x_n(m)$ 的幅度 $\gamma_n(m)$ 服从瑞利分布,相位 $\varphi_n(m)$ 服从均匀分布^[15],分别记为

$$\begin{aligned} \gamma_n(m) &\sim R[\gamma_n(m) | \sigma_{x_n(m)} / \sqrt{2}], \\ \varphi_n(m) &\sim U[\varphi_n(m) | 0, 2\pi]. \end{aligned} \quad (5)$$

为了分析初相对 $x_n(m)$ 的影响,令

$$\begin{aligned} \tilde{x}_n(m) &= \exp(j\theta_{m0}) x_n(m) = \\ &\gamma_n(m) \exp\{j[\theta_{m0} + \varphi_n(m)]\} = \\ &\gamma_n(m) \exp[j\tilde{\varphi}_n(m)], \end{aligned} \quad (6)$$

式中 $\tilde{\varphi}_n(m) = \theta_{m0} + \varphi_n(m)$ 。利用均匀分布的性质与复指数函数的周期性,有

$$\tilde{\varphi}_n(m) \sim U[\tilde{\varphi}_n(m) | 0, 2\pi]. \quad (7)$$

因此 $\tilde{x}_n(m)$ 仍然服从复高斯分布,即

$$\tilde{x}_n(m) \sim CG[\tilde{x}_n(m) | 0, \sigma_{x_n(m)}^2]. \quad (8)$$

对比(8)式与(4)式,可见初相对各距离单元合成回波的统计分布没有影响。

由以上分析可知:复距离像服从复高斯分布,且初相项的存在并不改变其统计分布特性。下面将在此结论的基础上讨论复距离像的统计建模问题。

3 复距离像统计建模

基于 Bayes 分类器的统计目标识别是一类重要的识别方法。文献[6]中介绍了统计目标识别的原理,其关键在于选取合适的统计模型对样本建模并估计模型参数。本节将介绍三种不同的复高斯模型对复距离像统计建模并分析初相对这些模型的影响。

3.1 自适应复高斯分类器模型

自适应高斯分类器(AGC)模型是美国休斯公司为了识别实距离像而开发的一种模型。本节将 AGC 模型推广至复数域,使用自适应复高斯分类器(ACGC)模型对复距离像建模。与 AGC 模型类似,ACGC 模型中也假设复距离像 \mathbf{x} 各距离单元回波相互独立,且服从不同的复高斯分布,记作

$$\mathbf{x} \sim \text{CG}(\mathbf{x} | \mathbf{0}, \mathbf{A}), \quad (9)$$

式中 $d \times d$ 维的对角矩阵 \mathbf{A} 表示 \mathbf{x} 的协方差矩阵。ACGC 模型具有结构简单,计算方便的优点,其模型自由度低,仅为 d ,因此对训练样本数要求不高。

给定一帧复距离像样本 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$, \mathbf{A} 可由最大似然估计得到,即

$$\mathbf{A} = \frac{1}{N} \text{diag} \left(\sum_{i=1}^N \mathbf{x}_i \mathbf{x}_i^H \right), \quad (10)$$

式中 $\text{diag}(\cdot)$ 表示将矩阵非对角元素置零操作符,上标 H 表示共轭转置操作符。下面分析初相对 ACGC 模型参数估计的影响。将 \mathbf{X} 中所有样本分别乘上不同的随机初相项 $\exp(j\theta_{i0}), i=1, 2, \dots, N$, 构成一帧新样本 $\mathbf{X}' = \{\mathbf{x}'_1, \mathbf{x}'_2, \dots, \mathbf{x}'_N\}$, 其中 $\mathbf{x}'_i = \mathbf{x}_i \exp(j\theta_{i0})$ 。则 \mathbf{X}' 对应的协方差矩阵 \mathbf{A}' 为

$$\begin{aligned} \mathbf{A}' &= \frac{1}{N} \text{diag} \left(\sum_{i=1}^N \mathbf{x}'_i \mathbf{x}'_i^H \right) = \\ &= \frac{1}{N} \text{diag} \left\{ \sum_{i=1}^N \mathbf{x}_i \exp(j\theta_{i0}) [\mathbf{x}_i \exp(j\theta_{i0})]^H \right\} = \\ &= \frac{1}{N} \text{diag} \left(\sum_{i=1}^N \mathbf{x}_i \mathbf{x}_i^H \right) = \mathbf{A}. \end{aligned} \quad (11)$$

可见初相不会改变 ACGC 模型的参数估计结果。

3.2 联合复高斯模型

文献[8]从距离像的物理成因出发,分析并验证了各距离单元回波间的相关性。因此本节采用联合复高斯(JCG)模型对复距离像 \mathbf{x} 建模,记作

$$\mathbf{x} \sim \text{CG}(\mathbf{x} | \mathbf{0}, \mathbf{\Sigma}), \quad (12)$$

式中 $d \times d$ 维的矩阵 $\mathbf{\Sigma}$ 表示 \mathbf{x} 的协方差矩阵。与 ACGC 模型相比,JCG 模型能够刻画不同距离单元回波的相互关系,描述能力更强。但代价是其模型自由度增加至 $d(d+1)/2$,对训练样本数的要求大大提高。 $\mathbf{\Sigma}$ 也可利用最大似然估计得到,即

$$\mathbf{\Sigma} = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i \mathbf{x}_i^H. \quad (13)$$

与 ACGC 模型相似, $\mathbf{\Sigma}$ 的估计结果也不受初相的影响。

3.3 复数概率主成分分析模型

复距离像是高维向量,且实际中能获取的样本数量往往有限,此时,JCG 模型的协方差矩阵可能存在较大估计误差。因此本节将一种低自由度的联合高斯模型-概率主成分分析模型(PPCA)^[16]推广到复数域对复距离像建模。复数概率主成分分析(CPPCA)模型定义如下:

$$\mathbf{x} = \mathbf{U}\mathbf{y} + \boldsymbol{\varepsilon}, \quad (14)$$

式中 $d \times q$ 维的复矩阵 \mathbf{U} 为映射矩阵($q \ll d$), $q \times 1$ 维的复向量 $\mathbf{y} \sim \text{CG}(\mathbf{y} | \mathbf{0}, \mathbf{I}_q)$ 为隐变量, \mathbf{I}_q 为 q 维单位方阵, $d \times 1$ 维的复向量 $\boldsymbol{\varepsilon} \sim \text{CG}(\boldsymbol{\varepsilon} | \mathbf{0}, \sigma^2 \mathbf{I}_d)$ 为模型噪声。利用复高斯分布的线性性质,有 $\mathbf{x} \sim \text{CG}(\mathbf{x} | \mathbf{0}, \mathbf{U}\mathbf{U}^H + \sigma^2 \mathbf{I}_d)$ 。使用 CPPCA 模型建模具有以下优势:

1) CPPCA 模型通过约束协方差矩阵的结构来降低其自由度,兼顾了模型描述能力与参数估计精度;

2) 复距离像样本并非散布在整个高维空间中,而是聚集在某些低维子空间内^[7],使用 CPPCA 模型能够很好地描述复距离像的子空间结构;

3) CPPCA 模型受奇异样本的影响较小^[16]。

这里将期望最大化(EM)算法推广至复数域来估计 CPPCA 模型参数。EM 算法通过最大化模型的期望联合对数似然函数 $Q(\boldsymbol{\Theta})$ 来估计参数。CPPCA 模型的 $Q(\boldsymbol{\Theta})$ 定义如下:

$$\begin{aligned} Q(\boldsymbol{\Theta}) &= \text{E} \left\{ \sum_{i=1}^N \ln [p(\mathbf{x}_i, \mathbf{y}_i)] \mid \mathbf{X} \right\} = \sum_{i=1}^N \sigma^{-2} \{ \mathbf{x}_i^H \mathbf{x}_i - 2\mathbf{x}_i^H \mathbf{U} \text{E}(\mathbf{y}_i | \mathbf{x}_i) + \text{Tr}[(\mathbf{U}^H \mathbf{U} + \sigma^2 \mathbf{I}_d) \text{E}(\mathbf{y}_i \mathbf{y}_i^H | \mathbf{x}_i)] \} - \\ &= N(d+q) \ln \pi - Nd \ln \sigma^2, \end{aligned} \quad (15)$$

式中参数集 $\Theta = \{U, \sigma^2\}$, $E(\cdot)$ 表示求期望操作符, $\text{Tr}(\cdot)$ 表示矩阵求迹操作符。下面给出 EM 算法的具体步骤:

1) 令迭代次数符号 $\tau=0$, 设定模型参数初始值 $\tilde{\Theta}(0) = \{\tilde{U}(0), \tilde{\sigma}^2(0)\}$ 和迭代结束门限 $\eta(0 < \eta <$

1);

2) 假设 $\tilde{\Theta}(\tau) = \{\tilde{U}(\tau), \tilde{\sigma}^2(\tau)\}$ 是第 τ 步迭代估计的参数值, 按下式计算隐变量的后验均值与后验协方差矩阵:

$$\begin{aligned} E[y_i | x_i; \tilde{\Theta}(\tau)] &= \tilde{U}(\tau)^H [\tilde{U}(\tau) \tilde{U}(\tau)^H + \tilde{\sigma}^2(\tau) \mathbf{I}_d]^{-1} x_i = \tilde{U}(\tau)^H \tilde{C}(\tau)^{-1} x_i, \\ E[y_i y_i^H | x_i; \tilde{\Theta}(\tau)] &= \mathbf{I}_q - \tilde{U}(\tau)^H \tilde{C}(\tau)^{-1} \tilde{U}(\tau) + E[y_i | x_i; \tilde{\Theta}(\tau)] E[y_i^H | x_i; \tilde{\Theta}(\tau)], \end{aligned} \quad (16)$$

式中 $\tilde{C}(\tau) = \tilde{U}(\tau) \tilde{U}(\tau)^H + \tilde{\sigma}^2(\tau) \mathbf{I}_d$ 。

3) 把(16)式代入(15)式, 将 $Q(\Theta)$ 关于 U 和 σ^2 求导, 并令导数为零, 得到第 $\tau+1$ 步时参数的估计值, 即

$$\begin{aligned} \tilde{U}(\tau+1) &= \left\{ \sum_{i=1}^N x_i E(y_i^H | x_i; \tilde{\Theta}(\tau)) \right\} \left\{ \sum_{i=1}^N E[y_i y_i^H | x_i; \tilde{\Theta}(\tau)] \right\}^{-1}, \\ \tilde{\sigma}^2(\tau+1) &= \frac{1}{N} \mathbf{1}_d^T \cdot \text{diag} \left\{ \sum_{i=1}^N \{x_i x_i^H - \tilde{U}(\tau+1) E[y_i | x_i; \tilde{\Theta}(\tau)] x_i^H\} \right\} \cdot \mathbf{1}_d, \end{aligned} \quad (17)$$

式中 $\mathbf{1}_d$ 表示所有元素取值为 1 的 $d \times 1$ 维向量;

4) 若 $|Q[\tilde{\Theta}(\tau+1)] - Q[\tilde{\Theta}(\tau)]| / |Q[\tilde{\Theta}(\tau)]| < \eta$, 则算法收敛; 否则令 $\tau^{\text{new}} = \tau^{\text{old}} + 1$, 同时返回步骤 2) 继续迭代。

下面分析初相对 CPPCA 模型结构及 EM 算法的影响。将(14)式两边同乘上任意一个初相项 $\exp(j\theta_0)$, 即

$$\mathbf{x} \exp(j\theta_0) = \mathbf{A} \mathbf{y} \exp(j\theta_0) + \boldsymbol{\varepsilon} \exp(j\theta_0). \quad (18)$$

令 $\mathbf{x}' = \mathbf{x} \exp(j\theta_0)$, $\mathbf{y}' = \mathbf{y} \exp(j\theta_0)$, $\boldsymbol{\varepsilon}' = \boldsymbol{\varepsilon} \exp(j\theta_0)$, 则(18)式可改写为

$$\mathbf{x}' = \mathbf{A} \mathbf{y}' + \boldsymbol{\varepsilon}'. \quad (19)$$

利用第 2 节的分析结果, 有

$$\mathbf{y}' \sim \text{CG}(\mathbf{y}' | \mathbf{0}, \mathbf{I}_q), \boldsymbol{\varepsilon}' \sim \text{CG}(\boldsymbol{\varepsilon}' | \mathbf{0}, \boldsymbol{\Psi}). \quad (20)$$

因此有

$$\mathbf{x}' \sim \text{CG}(\mathbf{x}' | \mathbf{0}, \mathbf{U} \mathbf{U}^H + \sigma^2 \mathbf{I}_d). \quad (21)$$

综上可知 \mathbf{y}' , $\boldsymbol{\varepsilon}'$ 和 \mathbf{x}' 分别具有与 \mathbf{y} , $\boldsymbol{\varepsilon}$ 和 \mathbf{x} 完全相同的分布类型和分布参数, 这说明初相不改变 CPPCA 模型的统计结构。

再看初相对 EM 算法的影响。在第 τ 次迭代时, \mathbf{X}' 中所有样本对应隐变量 $\{y'_1, y'_2, \dots, y'_N\}$ 的后验均值和后验协方差矩阵分别为

$$\begin{aligned} E[y'_i | x'_i; \tilde{\Theta}(\tau)] &= \tilde{U}(\tau)^H [\tilde{U}(\tau) \tilde{U}(\tau)^H + \tilde{\sigma}^2(\tau) \mathbf{I}_d]^{-1} x'_i = \exp(j\theta_0) E[y_i | x_i; \tilde{\Theta}(\tau)], \\ E[y'_i y'^H_i | x'_i; \tilde{\Theta}(\tau)] &= \mathbf{I}_q - \tilde{U}(\tau)^H \tilde{C}(\tau)^{-1} \tilde{U}(\tau) + E[y'_i | x'_i; \tilde{\Theta}(\tau)] E[y'^H_i | x'^H_i; \tilde{\Theta}(\tau)] = E(y_i y_i^H | x_i; \tilde{\Theta}(\tau)). \end{aligned} \quad (22)$$

其相应的参数更新公式为

$$\begin{aligned} \tilde{U}(\tau+1) &= \left\{ \sum_{i=1}^N x'_i E(y_i^H | x'_i; \tilde{\Theta}(\tau)) \right\} \left\{ \sum_{i=1}^N E[y'_i y'^H_i | x'_i; \tilde{\Theta}(\tau)] \right\}^{-1} = \\ &= \left\{ \sum_{i=1}^N x_i E[y_i^H | x_i; \tilde{\Theta}(\tau)] \right\} \left\{ \sum_{i=1}^N E(y_i y_i^H | x_i; \tilde{\Theta}(\tau)) \right\}^{-1}, \\ \tilde{\sigma}^2(\tau+1) &= \frac{1}{N} \mathbf{1}_d^T \cdot \text{diag} \left\{ \sum_{i=1}^N \{x'_i x'^H_i - \tilde{U}(\tau+1) E[y'_i | x'_i; \tilde{\Theta}(\tau)] x'^H_i\} \right\} \cdot \mathbf{1}_d = \\ &= \frac{1}{N} \mathbf{1}_d^T \cdot \text{diag} \left\{ \sum_{i=1}^N \{x_i x_i^H - \tilde{U}(\tau+1) E[y_i | x_i; \tilde{\Theta}(\tau)] x_i^H\} \right\} \cdot \mathbf{1}_d. \end{aligned} \quad (23)$$

分别对比(22)式与(16)式、(23)式与(17)式, 不难发现初相只改变隐变量的后验均值, 不改变 EM 算法最终的估计结果。

由以上分析可知 CPPCA 模型的结构及参数估计结果都不受初相的影响。

4 噪声稳健的模型修正方法

第3节中提出了三种用于复距离像统计建模的复数模型,然而这些模型同其他统计模型一样,在应用中存在着对噪声敏感的问题。因为通常用于学习模型的距离像训练样本具有很高的信噪比(SNR),而实际测试样本总是含有一定水平的噪声成分。此时,库中模型与测试样本间的信噪比失配会导致识别性能恶化^[17]。为了解决这个问题,可以在识别过程中根据测试样本信噪比对模型参数进行修正。基于实距离像的识别方法在修正模型参数时近似认为实距离像带噪测试样本中的噪声为加性噪声^[17-18],即

$$|\hat{\mathbf{x}}| = |a\mathbf{t} + \mathbf{n}| \approx a|\mathbf{t}| + |\mathbf{n}|, \quad (24)$$

式中 \mathbf{x} 为接收的带噪测试样本, \mathbf{t} 为能量归一的目标距离像, a 为取值未知的尺度缩放因子 ($a > 0$), 它由发射机功率和目标距离等因素决定, \mathbf{n} 为噪声, 它包含了接收机热噪声以及外部环境中的噪声。通常认为 \mathbf{n} 服从复高斯分布, 即 $\mathbf{n} \sim \text{CG}(\mathbf{n} | \mathbf{0}, \sigma_n^2 \mathbf{I}_d)$, σ_n^2 为其功率。在低信噪比条件下, 使用(24)式修正模型将会产生较大的近似误差, 从而影响识别性能。但在利用复距离像进行识别时有 $\hat{\mathbf{x}} = a\mathbf{t} + \mathbf{n}$, 即噪声为真正的加性噪声, 无需以上近似, 这是利用复距离像识别的另一个优势。下面给出一种适用于本文所有复高斯模型的噪声稳健修正方法。

为了克服测试样本的幅度敏感性, 首先对 $\hat{\mathbf{x}}$ 进行能量归一, 将归一后的 $\hat{\mathbf{x}}$ 记为 \mathbf{x}_0 , 则

$$\mathbf{x}_0 = \frac{\hat{\mathbf{x}}}{\sqrt{a^2 + d\sigma_n^2}} = \frac{a}{\sqrt{a^2 + d\sigma_n^2}} \mathbf{t} + \frac{1}{\sqrt{a^2 + d\sigma_n^2}} \mathbf{n}. \quad (25)$$

如果 \mathbf{t} 来自于第 k ($k = 1, 2, \dots, K$) 类目标的第 f ($f = 1, 2, \dots, F_k$) 帧, 则其类条件概率密度函数 $p(\mathbf{t} | k, f) = \text{CG}(\mathbf{t} | \mathbf{0}, \mathbf{\Pi}_{kf})$, 其中 $\mathbf{\Pi}_{kf} = \{\mathbf{A}_{kf}, \mathbf{\Sigma}_{kf}, \mathbf{C}_{kf}\}$ 表示不同模型利用该帧训练样本(假设训练样本中不含噪声)估计得到的协方差矩阵。相应地, \mathbf{x}_0 的均值和协方差矩阵分别为

$$\mathbf{E}(\mathbf{x}_0) = \frac{a}{\sqrt{a^2 + d\sigma_n^2}} \mathbf{E}(\mathbf{t}) + \frac{1}{\sqrt{a^2 + d\sigma_n^2}} \mathbf{E}(\mathbf{n}) = \mathbf{0}, \quad (26)$$

$$\text{Cov}(\mathbf{x}_0) = \frac{a^2}{a^2 + d\sigma_n^2} \text{Cov}(\mathbf{t}) + \frac{1}{a^2 + d\sigma_n^2} \text{Cov}(\mathbf{n}) = \frac{a^2}{a^2 + d\sigma_n^2} \mathbf{\Pi}_{kf} + \frac{\sigma_n^2}{a^2 + d\sigma_n^2} \mathbf{I}_d, \quad (27)$$

式中 $\text{Cov}(\cdot)$ 表示求协方差矩阵操作符, 所以 \mathbf{x}_0 的类条件概率密度函数为

$$p(\mathbf{x}_0 | k, f) = \text{CG}\left(\mathbf{x}_0 \left| \mathbf{0}, \frac{a^2}{a^2 + d\sigma_n^2} \mathbf{\Pi}_{kf} + \frac{\sigma_n^2}{a^2 + d\sigma_n^2} \mathbf{I}_d \right.\right). \quad (28)$$

定义 \mathbf{x}_0 的信噪比为

$$\gamma = 10 \lg(a^2 / d\sigma_n^2), \quad (29)$$

将 γ 代入(28)式, 则 \mathbf{x}_0 的类条件概率密度函数可改写为

$$p(\mathbf{x}_0 | k, f) = \text{CG}\left[\mathbf{x}_0 \left| \mathbf{0}, \frac{10^{\gamma/10}}{1 + 10^{\gamma/10}} \mathbf{\Pi}_{kf} + \frac{1}{d(1 + 10^{\gamma/10})} \mathbf{I}_d \right.\right]. \quad (30)$$

在识别阶段, 首先估计测试样本的信噪比 γ , 然后利用(30)式对模板库中的协方差矩阵进行修正, 即可实现噪声稳健识别。与文献[17]相比, 本节方法不但避免了(24)式中加入噪声假设产生的近似误差, 提高了模型修正精度, 而且显著降低了模型修正的计算复杂度。

5 基于复高斯模型的雷达高分辨距离像目标识别步骤

下面给出基于三种复高斯模型的雷达高分辨距离像目标识别系统训练阶段和测试阶段的基本步骤:

1) 训练阶段

① 将第 k ($k = 1, 2, \dots, K$) 类目标的训练样本均匀分为 F_k 帧, 每一帧包含 N 个复距离像训练样本, 记为 $\mathbf{X}_{fk} = \{\mathbf{x}_1^{fk}, \mathbf{x}_2^{fk}, \dots, \mathbf{x}_N^{fk}\}$, ($f = 1, 2, \dots, F_k$)。对各帧训练样本进行能量归一和对齐处理^[8];

② 分别使用 ACGC 模型、JCG 模型和 CPPCA 模型对所有目标的各帧训练样本建模, 并利用(11)式、(13)式和复数 EM 算法计算各帧训练样本对应的模型参数 $\mathbf{\Pi}_{kf} = \{\mathbf{A}_{kf}, \mathbf{\Sigma}_{kf}, \mathbf{C}_{kf}\}$, 将其存入识别系统模板库。

2) 测试阶段

① 将复距离像测试样本 \mathbf{x} 能量归一, 记归一后的 \mathbf{x} 为 \mathbf{x}_0 , 并估计其信噪比 γ ;

② 利用(30)式对各帧训练样本的模型参数进行修正, 并计算 \mathbf{x}_0 相应于各类目标的条件似然值 $p(\mathbf{x}_0 | k) = \max[p(\mathbf{x}_0 | k, f)]$ 。其中,

$$p(\mathbf{x}_0 | k, f) = \frac{1}{(2\pi)^d \left| \frac{10^{\gamma/10} d\mathbf{H}_{kf} + \mathbf{I}_d}{d(1 + 10^{\gamma/10})} \right|} \exp \left\{ -\mathbf{x}_0^H \left[\frac{10^{\gamma/10} d\mathbf{H}_{kf} + \mathbf{I}_d}{2d(1 + 10^{\gamma/10})} \right]^{-1} \mathbf{x}_0 \right\}; \quad (31)$$

3) 使用 Bayes 分类器对 \mathbf{x}_0 分类,其原理是将 \mathbf{x}_0 判为具有最大后验概率的一类目标 $\bar{k}(\mathbf{x}_0)$, 即

$$\bar{k}(\mathbf{x}_0) = \arg \max_k [p(k | \mathbf{x}_0)], \quad (32)$$

式中 $p(k | \mathbf{x}_0)$ 为 \mathbf{x}_0 属于第 k 类目标的后验概率。根据 Bayes 公式,可以得到 $p(k | \mathbf{x}_0) \propto p(k)p(\mathbf{x}_0 | k)$ 。

在没有先验信息的条件下,通常假设各类目标具有等先验概率^[7], 即 $p(1) = p(2) = \dots = p(K) = 1/K$, 因此(32)式等价于:

$$\bar{k}(\mathbf{x}_0) = \arg \max_k [p(\mathbf{x}_0 | k)]. \quad (33)$$

图 1 给出了整个识别系统的流程图。

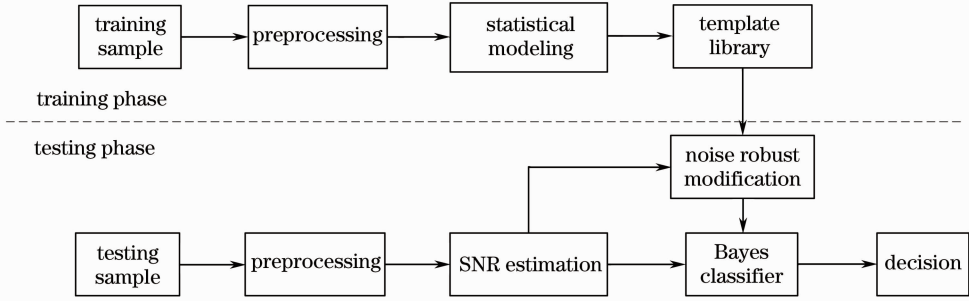


图 1 识别系统流程图

Fig. 1 Flow diagram of the recognition system

6 实验结果和讨论

6.1 数据与实验设置介绍

识别实验使用某 ISAR 雷达实测的 3 类飞机数据。该雷达发射信号载频为 5.5 GHz,带宽为 400 MHz。3 类飞机的尺寸如表 1 所示,其各自航迹如图 2 所示。为了检验识别方法的推广性能,将 HRRP 数据分段,并分别在不同数据段内选取训练和测试样本。其中,雅克-42 的第 2、5 段、奖状的第 6、7 段和安-26 的第 5、6 段数据作为训练样本,其余各段作为测试样本。除雅克-42 第 5 段数据包含 10000 个样本外,

其他数据段都有 25000 个样本。各样本均为 256 维的复向量。实验中设定帧长 $N = 1000$, 分别将雅克-42、奖状和安-26 的训练样本等间隔划分为 35、50、50 帧。

表 1 三类飞机参数

Table 1 Parameters of the three planes

Type	Length /m	Width /m	Height /m
Yak-42	36.38	34.88	9.83
Cessna	14.40	15.90	4.57
An-26	23.80	29.20	8.58




图 2 三类飞机的航迹在地面投影。(a)雅克-42; (b)奖状; (c)安-26

Fig. 2 Target trajectories of three planes onto the ground plane. (a) Yak-42; (b) Cessna; (c) An-26

6.2 复高斯模型与实高斯模型性能对比

为了检验相位信息在识别中的作用,本节实验将分别采用 ACGC 模型、JCG 模型和 CPPCA 模型对复距离像建模,并比较它们与相应实数模型的识

别性能。表 2 和表 3 中分别给出了实数模型与复数模型对三类目标的识别结果。其中, Y 表示雅克-42, C 表示奖状, A 表示安-26。

表 2 三种实数模型的混淆矩阵

Table 2 Confusion matrix of three real models

unit: %

Model	AGC			JG			PPCA		
	Y	C	A	Y	C	A	Y	C	A
Y	97.9	0	2.1	99	0	1	98.4	0	1.6
C	3.6	75.1	21.3	3	87.3	9.7	1.4	82.8	15.8
A	4.9	3	92.1	11.3	1.7	87	5.7	1.3	93
ACRR	88.3			91.1			91.4		

表 3 三种复数模型的混淆矩阵

Table 3 Confusion matrix of three complex models

unit: %

Model	AGC			JG			PPCA		
	Y	C	A	Y	C	A	Y	C	A
Y	99	0	1	99.2	0	0.8	99.2	0	0.8
C	1.4	79.7	18.9	2.6	91.2	6.2	1.4	89.1	9.5
A	4	4.2	91.8	9.3	1.3	89.4	6.7	0.4	92.9
ACRR	90.2			93.3			93.7		

观察表 2 与表 3 中的结果,可以得到以下结论:

1) 三种复数模型的平均正确识别率(ACRR)均高于相应的实数模型。其中,ACGC 模型的 ACRR 比 AGC 模型提高了 1.9%,JCG 模型比 JG 模型提高了 2.2%,CPPCA 模型比 PPCA 模型提高了 2.3%。这说明复距离像的相位中包含了有用的目标判别信息,而合理利用该信息能有效地改善识别性能。2) 对于三种复数模型来说,ACGC 模型的 ACRR 明显低于其他两者。这是因为 ACGC 模型的描述能力有限,未能刻画不同距离单元之间的相关性。同时,由于 CPPCA 模型考虑了复距离像的子空间结构,且对奇异样本具有一定的稳健性,因此其 ACRR 要高于 JCG 模型。3) 采用复数模型建模后,安-26 的正确识别率提升幅度相对较小,甚至略有下降。这是因为安-26 是螺旋桨飞机,其回波中一些距离单元的相位会受到螺旋桨调制的破坏,从而影响了最终的识别性能。在实际应用中,可采取以下分层识别的思想来解决这个问题:通常雷达工作时交替发射宽带与窄带信号。此时,首先利用目标窄带回波中的微多普勒^[19]调制信息对目标类别进行判断(即判断目标为固定翼飞机或螺旋桨飞机)。若目标为固定翼飞机,可直接使用本文方法对其分类;反之,若目标是螺旋桨飞机,则可将本文识别方法与目标的微多普勒调制信息相融合,从而提高对螺旋桨飞机的识别性能。

6.3 复高斯模型与实高斯模型计算复杂度对比

与实距离像识别相比,采用复距离像识别会带来计算量的增加。为了定量地比较两类识别方法的计算复杂度,表 4 中分别给出了三种实数模型和三

种复数模型在训练和测试阶段的计算时间。

表 4 不同模型的训练时间与测试时间

Table 4 Training time and testing time of different models

Model	Training time per frame /s	Testing time per sample /s
AGC	5.5	0.038
JG	5.6	0.049
PPCA	10.4	0.048
ACGC	5.6	0.039
JCG	5.8	0.051
CPPCA	13.5	0.051

从表中可以观察到以下现象:1) AGC 模型、JG 模型、ACGC 模型和 JCG 模型在训练阶段所需的计算时间较短,因为这些模型的参数估计过程相对简单。而 PPCA 模型和 CPPCA 模型的训练时间较长,因为这两个模型的参数估计过程涉及迭代运算。2) 与 AGC 模型和 JG 模型相比,ACGC 模型和 JCG 模型在训练阶段的计算时间几乎没有增加,而 CPPCA 模型在训练阶段的计算时间比 PPCA 模型增加了约 29%。3) 三类复数模型在测试阶段的计算时间与三类实数模型相当。对于识别系统来说,在离线训练、在线识别的工作模式下,由于对训练阶段的实时性没有要求,通常可采用 CPPCA 模型;而在对库外目标进行在线学习与识别时,需要训练和测试阶段都有较好的实时性,此时优先考虑使用 ACGC 模型或 JCG 模型。

6.4 训练样本数对识别性能的影响

对于非合作目标,往往难以获取大量的训练样本。因此研究不同训练样本数条件下统计模型的识别性能具有很强的现实意义。本节实验将从所有目

标各帧训练样本中抽取不同数量的样本构成一系列训练样本集,分别利用这些样本集来学习 ACGC 模型、JCG 模型和 CPPCA 模型。令 T 表示各帧中抽取的训练样本数,这里分析三种模型的 ACRR 随 T

表 5 不同训练样本数下 4 种复数模型的平均正确识别率(均值±标准差,%)

Table 5 ACRRs of four complex models under different training sample numbers (mean±standard deviation, %)

T	ACGC	JCG	CPPCA	CFA
900	90±0.1	93.1±0.3	93.2±0.2	94.2±0.2
700	89.9±0.2	92.2±0.4	92.4±0.3	93.9±0.2
500	89.6±0.2	90.6±1.1	91.9±0.4	92.3±0.4
300	89.2±0.4	87±1.5	90.3±0.5	90.9±0.6
200	88.9±0.5	—	85.4±0.9	84.6±1.1
100	88.5±0.6	—	66.9±1.2	64.7±1.7
70	87.5±0.9	—	60.2±1.5	59.1±1.9

从表 5 可以看到,当各帧训练样本数减少时,4 种模型的参数估计精度随之下降,因而其各自的识别性能都有不同程度的损失。其中,ACGC 模型的自由度最低,其 ACRR 随 T 下降缓慢;JCG 模型的自由度最高,其 ACRR 随 T 下降相对较快。值得注意的是当各帧的训练样本数接近或小于样本维数时,估计的 JCG 模型协方差阵成为奇异矩阵,此时 JCG 模型失去了识别能力。CPPCA 模型和 CFA 模型的自由度介于 ACGC 模型与 JCG 模型之间,当 $T \geq 300$ 时,二者 ACRR 下降较慢。当 $T < 300$ 时,二者的 ACRR 下降速度增快。由于 CFA 模型的自由度大于 CPPCA 模型,其描述能力更强,因此当 $T \geq 300$ 时,其 ACRR 略高于 CPPCA 模型,而当 $T < 300$ 时,CFA 模型的参数估计精度较差,其 ACRR 又低于 CPPCA 模型。由以上结果可知,在对不同目标的样本建模时,可根据其训练样本数分以下三种情形选择模型:1)各帧样本数充足($T \geq 700$)。此时可选用 JCG 模型、CPPCA 模型或 CFA 模型建模。其中,JCG 模型在训练阶段的计算复杂度明显低于后两者;2)各帧样本数非常有限($T < 300$)。此时应选用 ACGC 模型建模;3)各帧样本数介于情形 1)、3)之间($300 \leq T < 700$)。此时可选用 CPPCA 模型或 CFA 模型建模。

6.5 低信噪比下识别性能改善分析

为了检验文中噪声稳健修正方法的有效性,将进行以下实验:向原始测试样本中分别加入不同水平的复高斯白噪声,依次生成信噪比为 5 dB、10 dB、15 dB、20 dB、25 dB、30 dB、35 dB 的带噪测试样本集。在识别这些带噪样本时,利用(30)式分别对三种复数模型进行修正。这里采用文献[20]中的中值绝对

取值的变化情况。此外,将三种模型的识别结果与文献[21]中 CFA 模型的识别结果也进行了比较。其中,对于 T 的不同取值,所有模型的识别实验都重复 5 次,最终结果如表 5 所示。

偏差估计器来估计带噪样本的信噪比。此外,为了比较说明复数模型在噪声稳健修正方面的优势,参考文献[17]中的方法,计算了三类实数模型在噪声稳健修正前后的识别结果。

图 3 给出了 6 种模型在噪声稳健修正前后的 ACRR 随信噪比变化情况,从图中可以得到以下结论:

1) 对模型进行修正能够减少模型与测试样本间由噪声引起的失配,并因此改善低信噪比下的识别性能。其中,修正 ACGC 模型的 ACRR 比无修正 ACGC 模型平均提高了 15.5%,修正 JCG 模型比无修正 JCG 模型平均提高了 27.1%,修正 CPPCA 模型比无修正 CPPCA 模型平均提高了 22%。这里的平均指对所有信噪比下的识别结果求平均。同时,修正后的三类实数模型其 ACRR 也都有了明显提高。

2) 复数修正模型的 ACRR 总是高于相应的实数修正模型。这一方面是由于实数修正模型丢掉了判别有用的相位信息,另一方面是因为实数修正模型近似认为噪声是加性高斯噪声,存在一定误差。随着信噪比下降,这种误差会逐渐增大,因而实数修正模型与复数修正模型识别性能的差距也越来越大。

3) 当信噪比小于 30 dB 时,大多数情况下无修正复数模型的 ACRR 低于相应的无修正实数模型。这是因为使用无修正的复数模型进行识别时,测试样本与模板之间同时具有幅度和相位两方面的失配。

4) 当信噪比等于 35 dB 时,经过修正的模型的 ACRR 并无明显提升,甚至有所下降。原因是修正

模型假设原始样本为无噪样本,而实际上原始样本中也存在有低水平的噪声成分。当信噪比较低时可以忽略这部分噪声的影响,而当信噪比较高时这部

分噪声会引起模型修正误差。因此,对于高信噪比的测试样本可以不进行模型修正,直接识别。

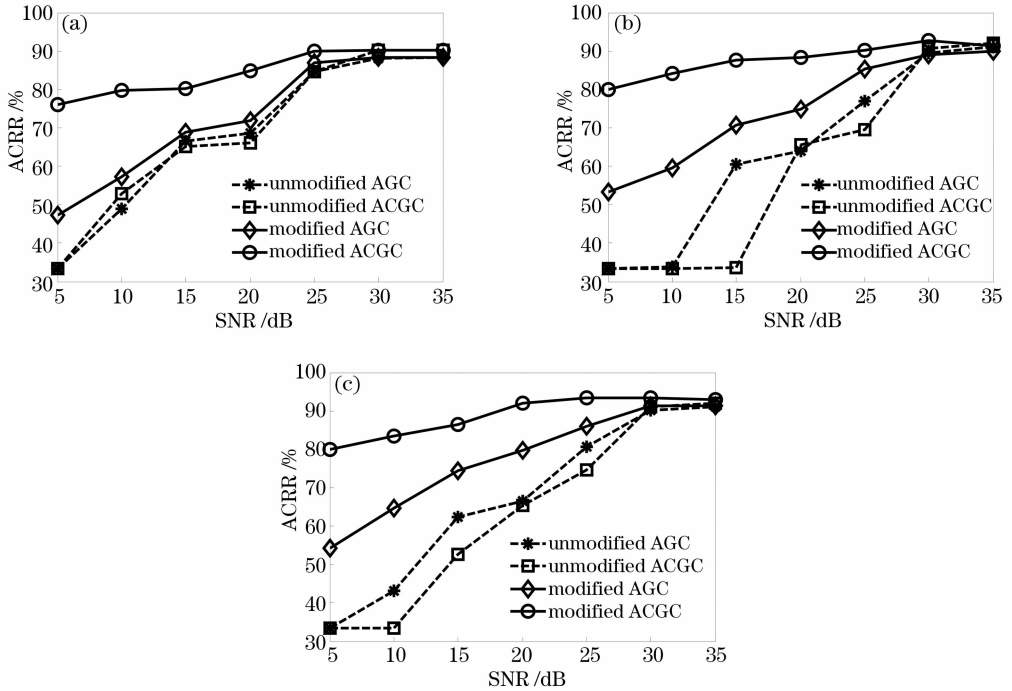


图3 不同模型修正前后的识别率随信噪比变化曲线。(a) AGC模型与ACGC模型;(b) JG模型与JCG模型;(c) PPCA模型与CPPCA模型

Fig. 3 Variation curves of recognition performance with SNR of different models before and after modification, (a) AGC model and ACGC model; (b) JC model and JCG model; (c) PPCA model and CPPCA model

7 结 论

研究了基于复距离像的雷达目标识别问题。分析了复距离像的统计特性,并提出了三种复高斯模型对其统计建模。这三种复数模型不受初相影响,能够在相应实数模型的基础上进一步利用相位信息改善识别性能。另外,为了解决低信噪比环境中的稳健识别问题,针对所提模型给出了一种模型修正方法。实验结果表明经过修正后的三种模型能够显著提高识别系统在低信噪比下的正确识别率。

参 考 文 献

- Xia Zhiwei, Li Qi, Ding Shenghui, *et al.*. Ladar intensity image denoising by non-local means algorithm [J]. *Acta Optica Sinica*, 2011, 31(s1): s100409.
- 夏志伟, 李琦, 丁胜晖, 等. 基于非局部均值滤波的激光雷达强度像去噪研究[J]. *光学学报*, 2011, 31(s1): s100409.
- Yan Yi, Jin Xiaofeng, Sun Jianfeng, *et al.*. Research of spotlight mode incoherently synthetic aperture imaging ladar [J]. *Acta Optica Sinica*, 2012, 32(2): 0211003.
- 严毅, 金晓峰, 孙建锋, 等. 聚束非相干合成孔径激光成像雷达研究[J]. *光学学报*, 2012, 32(2): 0211003.
- Dong Jihui, Hu Qiquan, Sun Dongsong. Techniques of depressing image noise in laser imaging tracking system [J].

Chinese J Lasers, 2011, 38(1): 0109002.

- 董吉辉, 胡企铨, 孙东松. 空间激光成像跟踪系统中的图像噪声抑制技术[J]. *中国激光*, 2011, 38(1): 0109002.
- Li Xinlei, Li Biao. Review on progress of real-time THz sensing and imaging technology [J]. *Laser & Optoelectronics Progress*, 2012, 49(9): 090008.
- 李昕磊, 李 彪. 实时太赫兹探测与成像技术新进展[J]. *激光与光电子学进展*, 2012, 49(9): 090008.
- Liu Liren. Principle of down-looking synthetic aperture imaging ladar [J]. *Acta Optica Sinica*, 2012, 32(9): 0928002.
- 刘立人. 直视合成孔径激光成像雷达原理[J]. *光学学报*, 2012, 32(9): 0928002.
- A R Webb. Gamma mixture models for target recognition [J]. *Pattern Recognition*, 2000, 33(12): 2045-2054.
- L Du, H Liu, Z Bao. Radar HRRP statistical recognition: parametric model and model selection [J]. *IEEE Trans Signal Process*, 2008, 56(5): 1931-1944.
- L Du, H Liu, Z Bao. Radar HRRP statistical recognition based on hypersphere model [J]. *Signal Processing*, 2008, 88(5): 1176-1190.
- S P Jacobs. *Automatic Target Recognition Using High-Resolution Radar Range Profiles* [D]. St. Louis: Washington University, 1997.
- L Du, H Liu, Z Bao, *et al.*. A novel feature vector using complex HRRP for radar target recognition [J]. *Lecture Notes in Computer Science*, 2007, 4491: 1303-1309.
- B Pei, Z Bao. Multi-aspect radar target recognition method based on scattering centers and HMMs classifiers [J]. *IEEE Trans*

- Aerosp Electron Syst, 2005, 41(3): 1067–1074.
- 12 Zhang Xinzhen, Huang Peikang. Multi-aspect SAR target recognition based on features of sequential complex HRRP using CICA [J]. Systems Engineering and Electronics, 2012, 34(2): 263–269.
张新征, 黄培康. 基于复值 HRRP CICA 特征的多方位 SAR 目标识别[J]. 系统工程与电子技术, 2012, 34(2): 263–269.
- 13 W G Carrara, R S Goodman, R M Majewski. Spotlight Synthetic Aperture Eadar-Signal Processing Algorithms [M]. Norwood: Artech House, 1995.
- 14 N R Goodman. Statistical analysis based on a certain multivariate complex Gaussian distribution [J]. The Annals of Mathematical Statistics, 1963, 34(1): 152–177.
- 15 M Evans, N Hastings, B Peacock. Statistical Distributions [M]. New York: Wiley, 1993.
- 16 M B Christopher. Pattern Recognition and Machine Learning [M]. New York: Springer Science Business Media, 2006.
- 17 H Liu, F Chen, L Du, *et al.*. Robust radar automatic target recognition algorithm based on HRRP signature [J]. Frontiers of Electrical and Electronic Engineering, 2012, 7(1): 49–55.
- 18 L Du, H Liu, P Wang, *et al.*. Noise robust radar HRRP target recognition based on multitask factor analysis with small training data size [J]. IEEE Trans Signal Process, 2012, 60(7): 3546–3559.
- 19 Dong Jing, Chen Rui, Li Xiaolong, *et al.*. Laser coherent detection of moving target based on micro-Doppler effect [J]. Chinese J Lasers, 2012, 39(10): 1014001.
董 晶, 陈 蕊, 李小龙, 等. 运动目标微多普勒效应的激光雷达相干探测及特征提取[J]. 中国激光, 2012, 39(10): 1014001.
- 20 P Shui, H Liu, Z Bao. Range-spread target detection based on cross time-frequency distribution features of two adjacent received signals [J]. IEEE Trans Signal Process, 2009, 57(10): 3733–3745.
- 21 Wang Penghui. Study of Radar High Resolution Range Profile Target Recognition Based on Statistical Modeling [D]. Xi'an: Xidian University, 2012.
王鹏辉. 基于统计建模的雷达高分辨距离像目标识别方法研究[D]. 西安:西安电子科技大学, 2012.

栏目编辑: 张 腾