

海杂波的多重分形关联特性与微弱目标检测

关键 刘宁波 张建 宋杰
(海军航空工程学院电子信息工程系 烟台 264001)

摘要: 该文研究了海杂波的多重分形关联特性及其在海杂波微弱目标检测中的应用。多重分形关联是对多重分形“单点”统计的推广,研究具有不同奇异性强度的两点之间的空间关联特性。该文首先从多重分形理论引出多重分形关联理论,给出了多重分形关联谱的计算方法,然后,以多重分形关联谱为特征进行相似度分析,并把目标检测问题归为一个二元分类问题,采用支持向量机(SVM)进行目标检测。最后,采用不同波段、不同极化方式和不同分辨率条件下的实测海杂波进行验证,结果表明,本文所提方法具有良好的微弱目标检测能力。

关键词: 目标检测;海杂波;多重分形关联;相似度;支持向量机

中图分类号: TN959.72

文献标识码: A

文章编号: 1009-5896(2010)01-0054-08

DOI: 10.3724/SP.J.1146.2008.00980

Multifractal Correlation Characteristic of Real Sea Clutter and Low-Observable Targets Detection

Guan Jian Liu Ning-bo Zhang Jian Song Jie

(Department of Electronic and Information Engineering,

Navy Aeronautical and Astronautical University, Yantai 264001, China)

Abstract: This paper studies the multifractal correlation characteristic of sea clutter and its application to the low-observable target detection within sea clutter. Multifractal correlation, which studies the spatial correlation of two points with different singularity intensity, is a generalization of multifractal ‘single point’ statistic. First, the paper introduces the multifractal correlation theory and the computation of the multifractal correlation spectrum. Then the multifractal correlation spectrum is used as a character to analyze the similarity degree to match board. In fact, target detection can be regarded as binary-classification, therefore the SVM (Support Vector Machine) is adopted for target detection. Finally, real sea clutter in different bands, polarizations and resolutions is used to verify the method proposed. The results show that the method has good performance of low-observable target detection.

Key words: Target detection; Sea clutter; Multifractal correlation; Degree of similarity; SVM

1 引言

对于欧几里德物体或分形物体上的测度,在经典物理中由于没有考虑其产生机理,继而也就没有考虑局部密度的奇异性,此时经典物理关于密度的定义失效了,这就自然地引入了奇异性强度^[1],并考虑奇异性强度的分布概率,即多重分形理论。多重分形理论,是对支集上任意一点观察到的奇异性强度 α 做统计分析,进而确定多重分形奇异谱 $f(\alpha)$ 。然而,分形物体上的测度由潜在的串级过程产生, $f(\alpha)$ 描述的是此种测度的宏观属性,对其中蕴含的物理本质的更深层次的理解则要求微观描述。1990年,Menuveau和Chhabra^[2]对多重分形“单点”统计

特性进行推广,研究了多重分形空间关联,即多重分形“两点”统计。分析两点统计特性主要考虑在两个相距为 r 的不同位置同时观测到两个给定 α 值的联合概率大小。显然,多重分形关联考虑了奇异性强度的空间相关特性,因此提供了比单点多重分形更丰富的自相似性信息。文献[3]研究了湍流的多重分形空间相关特性,分析了奇异性强度的自相关函数及其混合矩。周炜星等^[4]分析了一个随机二项测度的多重分形与多重分形关联特性,并研究了多重分形关联中呈现的标度区相变问题。迄今为止,运用多重分形关联理论对海杂波进行分析还鲜见相关文献报道。

由于噪声及其它随机因素影响,雷达所面临的环境十分复杂,很难用经典统计数学的方法对其进行确切的描述,而可将其作为一种模糊环境看待。在各种不确定性影响下,很难获得目标回波与海杂波特性的完整准确描述,尤其在强海杂波情况下,

2008-08-04收到, 2009-11-03改回

教育部新世纪优秀人才支持计划(NCET-05-0912)和国家自然科学基金(60672140, 60802088)资助课题

通信作者: 刘宁波 lhb198300@yahoo.com.cn

海杂波与目标回波特征的重叠现象较严重,二者之间没有明显的界限区分,不可能采用一个类似于检测门限的明显界限直接区分,即海杂波与目标回波特征之间存在着含糊的边界。此时,传统模式识别中具有良好定义的鉴别函数难以取得好的分类效果,而采用模糊集理论^[5]进行客观的定量分析与处理,可以在一定程度上解决这一问题。但对于模糊分类得到的相似度函数,若采用固定门限区分目标与杂波仍会造成误判,引起较高虚警。其实,海杂波中二元信号检测问题可以等价为信号分类问题。目前,在Vapnik提出的统计学习理论^[6]基础上发展来的支持向量机(Support Vector Machine, SVM),不仅具有严格的理论基础,而且能较好地解决小样本、非线性、高维数和局部极小点等实际问题,具有很强的泛化能力。

针对海杂波背景下的目标检测问题,本文将多重分形关联理论引入到海杂波微弱目标检测中,分别提取3组不同波段、不同极化、不同分辨率下实测海杂波的特征信息,进而得到海杂波的多重分形关联谱,同时基于雷达目标的模糊检测方法,以多重分形关联谱作为特征矢量进行相似度分析,最后引入一种改进核函数的SVM,实现海杂波背景下的微弱目标检测。

2 海杂波背景下的微弱目标检测

海上微弱目标检测一直是一个富有挑战性的课题,多重分形关联理论为海杂波背景下的雷达目标检测问题提供了新的思路。本节主要介绍本文所提方法的3方面主要内容:多重分形关联、模糊集理论和SVM分类。

2.1 多重分形关联

多重分形关联理论是在多重分形理论上推广而来的,因此,其参数的计算也与多重分形参数密切相关。

多重分形理论中计算多重分形谱时,首先定义一个配分函数 $\chi_q(\varepsilon)$ ^[7]

$$\chi_q(\varepsilon) \equiv \sum_i [P_i(\varepsilon)]^q = \varepsilon^{\tau(q)} \quad (1)$$

其中 $\tau(q)$ 为质量指数。令 $\mu_\varepsilon(x)$ 表示以点 x 为中心在尺度为 ε 条件下的测量单元里的测度,测度的不同矩和^[1]

$$M_r(q) = \langle \mu_\varepsilon(x)^q \rangle \propto \varepsilon^{\tau(q)+D_0} \quad (\varepsilon \rightarrow 0) \quad (2)$$

也可用不同的 $\tau(q)$ 来标度。因此, $\tau(q)$ 又称为矩指数。多重分形谱 $f(\alpha)$ 可由 $\tau(q)$ 进行Legendre变换^[7,8]求得,即

$$\tau(q) = \alpha q - f(\alpha) \quad (3)$$

$$\alpha = \frac{d\tau(q)}{dq} \quad (4)$$

多重分形考虑的是一点的奇异性强度 α 的分布概率,多重分形关联将其推广,研究在相距 r 的不同位置同时观测到的两个给定的奇异性强度 α' 和 α'' 的联合概率 $P_\varepsilon(\alpha', \alpha'', r)$,其中 α' 和 α'' 定义在相同的尺度 ε 下,并且有 $\varepsilon < r < 1$ (若 r 小于尺度,则相距为 r 的两个点被识别为一个点),由此,定义多重分形关联谱函数 $\tilde{f}(\alpha', \alpha'', \omega)$ ^[4]为

$$P_\varepsilon(\alpha', \alpha'', r) \propto \varepsilon^{D_0 - \tilde{f}(\alpha', \alpha'', \omega)} \quad (5)$$

其中 $\omega = \ln r / \ln \varepsilon$ 。

接着在由随机乘法过程产生的间断测度的基础上,确定 $\tilde{f}(\alpha', \alpha'', \omega)$ 与 $f(\alpha)$ 之间的关系。推广多重分形中“单点”统计的矩函数式(2),定义多重分形“两点”统计的测度空间自相关函数^[3]

$$C_\varepsilon(q', q'', r) \equiv \langle \mu_\varepsilon(x)^{q'} \mu_\varepsilon(x+r)^{q''} \rangle \quad (6)$$

式(6)比式(2)的单点矩包含了更多的空间信息。在这种测度下,式(6)右端平均值可以分解^[3]得到如下结论

$$\langle \mu_\varepsilon(x)^{q'} \mu_\varepsilon(x+r)^{q''} \rangle \propto \varepsilon^{\tau(q') + \tau(q'') + 2D_0 + \omega\Phi(q', q'')} \quad (7)$$

其中

$$\begin{aligned} \Phi(q', q'') &= \min\{\phi(q', q''), 1\} \\ &= \min\{\tau(q', q'') - \tau(q') - \tau(q'') - D_0, 1\} \end{aligned} \quad (8)$$

类似于式(2), $C_\varepsilon(q', q'', r)$ 可以用不同的关联矩指数 $\tilde{\tau}(q', q'', \omega)$ 来标度^[4],定义如下式所示:

$$C_\varepsilon(q', q'', r) \propto \varepsilon^{\tilde{\tau}(q', q'', \omega) + D_0} \quad (9)$$

对比式(7)与式(9)可得

$$\tilde{\tau}(q', q'', \omega) = \tau(q') + \tau(q'') + D_0 + \omega\Phi(q', q'') \quad (10)$$

当 $\phi(q', q'') = 1$ 时,与 r 相关的 $C_\varepsilon(q', q'', r)$ 的标度指数 $\tilde{\tau}(q', q'', \omega)$ 的导数有一个急剧的跳变,这在多重分形的热动力学解释中可以认为是一种相变,即两个标度区域 $\phi(q', q'') < 1$ (区域I)和 $\phi(q', q'') > 1$ (区域II)之间不连续过渡。

在两个标度区域,多重分形关联谱 $\tilde{f}(\alpha', \alpha'', \omega)$ 分别与多重分形谱 $f(\alpha)$ 存在如下关系^[4]:当 (q', q'') 在区域I内时

$$\begin{aligned} \tilde{f}(\alpha', \alpha'', \omega) &= \omega f[\alpha(Q' + Q'')] + (1 - \omega) \\ &\quad \cdot \{f[\alpha(Q')] + f[\alpha(Q'')] - D_0\} \end{aligned} \quad (11)$$

当 (q', q'') 在区域II内时

$$\tilde{f}(\alpha', \alpha'', \omega) = f[\alpha(Q')] + f[\alpha(Q'')] - D_0 - \omega \quad (12)$$

由式(11)和式(12)可以确定 $P_\varepsilon(\alpha', \alpha'', r)$ 的表达式。

2.2 相似度分析

对于具有含糊边界的信号特征,采用传统方法

难以区分。本文采用模糊集理论提取其模糊特征——相似度。

将待检测信号分为两类，即纯杂波信号和目标加杂波信号，将多重分形关联谱作为特征矢量，每个特征矢量有 $M \times M$ 个特征。由于目标类型不同从而特征也变化较大，用其建立模板不具稳定性，而海杂波在一定区域一定时间段内特征相对稳定，因此，采用 N 组海杂波样本来建立模板，分别以样本的特征均值与特征方差来表示^[5]

$$\mathbf{E}_S = [m_1, m_2, \dots, m_{M \times M}] \quad (13)$$

$$\mathbf{V}_S = [v_1^2, v_2^2, \dots, v_{M \times M}^2] \quad (14)$$

在决策过程中，由于接收机热噪声、云雨杂波等随机因素的影响，各特征值会有波动，但波动幅度一般不大，主要聚集在模版(均值)附近，一般可采用高斯分布来建模。根据高斯分布的性质，特征值与均值之差大于 3 倍标准差的概率接近于零。因此，若待检测信号中只有杂波，则其特征值应落在模版的 3 倍标准差以内；若含有目标，则特征值应该落在 3 倍标准差以外的地方。

在计算相似度时，设待检测信号的特征矢量 $\mathbf{X} = [x_1, x_2, \dots, x_{M \times M}]$ ，定义第 i 个特征值对杂波模板的相似度为

$$d_i = \begin{cases} \exp[-(x_i - m_i)^2 / 2v_i^2], \\ (m_i - 3v_i) < x_i < (m_i + 3v_i) \\ 0, \text{ 其它} \end{cases} \quad (15)$$

其中 x_i 代表 3 维空间 $(\alpha', \alpha'', \tilde{f})$ 中的一个矢量点， $(x_i - m_i)^2 = (\alpha' - m_{\alpha'})^2 + (\alpha'' - m_{\alpha''})^2 + (\tilde{f} - m_{\tilde{f}})^2$ 为 3 维空间中的欧氏距离，相似度 $d_i \in [0, 1]$ 。定义待检测信号对海杂波模板的相似度为

$$D = \frac{1}{M^2} \sum_{i=1}^{M^2} d_i \quad (16)$$

当待检测信号为纯海杂波信号时，对应的 D 较大(理论上接近于 1)，当待检测信号中含有目标时，对应的 D 将变小(理论上应接近于 0)。因此，可以根据 D 的大小判定海杂波中是否存在目标。

2.3 SVM 分类

对于训练样本集 $(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_l, y_l)$ ，其中 $\mathbf{x} \in \mathbf{R}^n$ ， y 为类别编号， $y \in \{-1, +1\}$ (n 为输入维数， l 为样本数)。如果训练数据可以无误差地被划分，并且每一类数据距超平面距离最近的向量与超平面之间的距离最大，则称这个超平面为最优超平面。设最优超平面方程为

$$(\mathbf{w} \cdot \mathbf{x}) + b = 0 \quad (17)$$

其中“ \cdot ”是向量点积符号， \mathbf{w} 为权值向量， b 为偏移。

则分类判别函数如下：

$$y_i[\mathbf{w} \cdot \mathbf{x} + b] \geq 1 \quad (18)$$

式(18)中使等号成立的向量称为支持向量。

在两类样本线性可分情况下，求解决策函数可以看成解二次型规划问题，求解即可得最优分类函数^[9,10]

$$g(x) = \text{sgn}\{(\mathbf{w} \cdot \mathbf{x}) + b\} = \text{sgn}\left\{\sum_{i=1}^l a_i^* y_i (\mathbf{x}_i \cdot \mathbf{x}) + b^*\right\} \quad (19)$$

其中 $\text{sgn}\{\cdot\}$ 为符号函数； b^* 为分类阈值，可用任意一个支持向量或两个支持向量取中值求得；不为零的 a_i^* 对应的向量为支持向量。

在线性不可分条件下，SVM 可通过事先选择的非线性映射 $\varphi: \mathbf{R}^n \rightarrow \mathbf{H}$ ，将输入向量映射到一个高维特征空间(Hilbert 空间)，在这个空间中其线性可分，然后构造最优分类超平面。这时，线性可分时的点积运算变为核函数

$$k(x, y) = (\varphi(x) \cdot \varphi(y)) \quad (20)$$

采用核函数(kernel function)可以避免在高维特征空间中进行复杂的运算，而且通常不需要显式地知道 φ 和 \mathbf{H} ，只需选择核函数就可以确定一个向量机^[11]。此时最优分类函数为

$$\begin{aligned} g(x) &= \text{sgn}\left\{\sum_{i=1}^l a_i^* y_i (\varphi(x_i) \cdot \varphi(x)) + b^*\right\} \\ &= \text{sgn}\left\{\sum_{i=1}^l a_i^* y_i k(\mathbf{x}_i \cdot \mathbf{x}) + b^*\right\} \end{aligned} \quad (21)$$

文献[12]中指出 SVM 的错误率均值有上界

$$E(P_{\text{err}}) \leq \frac{E(N_a)}{N_x - 1} \quad (22)$$

式中 P_{err} 是测试样本的错误率； N_a 是支持向量的个数， N_x 是训练矢量的个数。由此可知，减少支持向量的个数，增大训练矢量的个数，可以提高 SVM 的分类能力。所以采用改进的径向基核函数^[12]

$$k(x, x_i) = \lambda \exp\{-\|\mathbf{x}_i - \mathbf{x}\|^2 / 2\sigma^2\} \quad (23)$$

即增加一个大于 1 的系数 λ ，减小 a 值并减少支持向量个数，从而提高 SVM 的性能。

3 实测数据验证及分析

为验证本文所提方法，分别采用不同波段、不同极化和不同分辨率下的实测海杂波数据进行验证与对比分析。数据 1 来源于“Osborne Head Database”，测量平台基于 X 波段 IPIX 雷达，测量数据的详细情况可以参考 IPIX 网站^[13]，数据 2 来源于某 ISAR 雷达对海照射采集得到的海杂波数据，其为高分辨雷达，分辨率为 3.75 m，其中杂波

中有一个固定点目标，信杂比接近于 0 dB。图 1 分别给出了数据 1 与数据 2 的归一化海杂波时域波形图。

首先对数据进行多重分形分析，判定其具有多重分形特性。图 2 和图 3 给出了两类实测海杂波数据的配分函数、奇异性强度、质量指数及多重分形谱曲线。从图 2(a)和图 3(a)中可以看到，在对数坐标下尺度与配分函数在较大范围内成线性，且图 2(c)和图 3(c)所示的质量指数 $\tau(q)$ 均不是 q 的线性函数。根据多重分形判定准则^[14]可以判定，本文所用的实测数据都是多重分形的。在此基础上继续分析海杂波的多重分形关联特性，图 4 给出了数据 1 的中间函数的 3 维图及其等高线图，可以看到整个 (q', q'') 面分成两个区域，即区域 I 与区域 II，其中区域 II 对应的高度为 1，其在 3 维图形中对应一个平台。点(0, 0)是 (q', q'') 平面内的排斥子，从 3 维图

形中可以看出其为一个鞍点。3 维立体图关于 $q' = q''$ 平面对称，相应的等高线图关于直线 $q' = q''$ 对称。这里需说明的是，本文以数据 1 在 HH 极化下数据为例，实际上对其它数据进行分析可以得到类似的结果。

关联矩指数采用式(10)进行计算，如图 5 所示，其中 $\omega = 0.5$ 。此时关联矩指数 $\tilde{\tau}(q', q'', \omega)$ ，相对于多重分形分析中的矩指数 $\tau(q)$ 而言，已经由 2 维曲线变为 3 维曲面，并由式(8)可知， $\phi(q', q'') = 1$ 将标度区域分成两部分，类似于图 4 所示情况。对于给定的 (q', q'') ，关联矩指数 $\tilde{\tau}(q', q'', \omega)$ 的值由一个特定的点集决定，这个点集中的点满足一定的条件，即点集中的奇异性强度为 α' 的点，与其相距为 r 处必有奇异性强度为 α'' 的点。

由式(11)，式(12)可以得到海杂波的多重分形关联谱，如图 6 所示。




图 1 归一化海杂波时域波形图

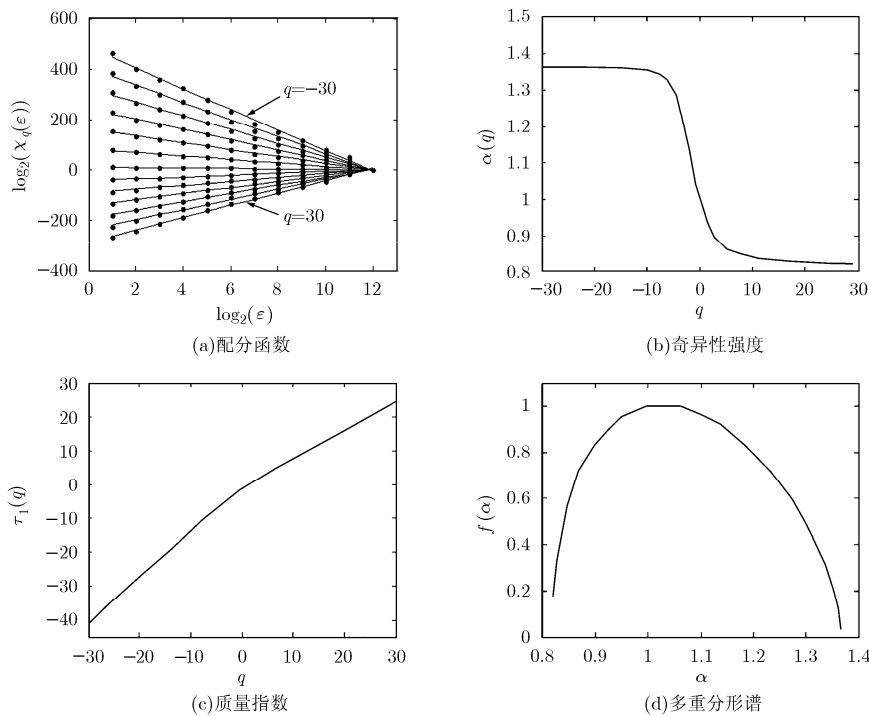


图 2 数据 1 多重分形特性

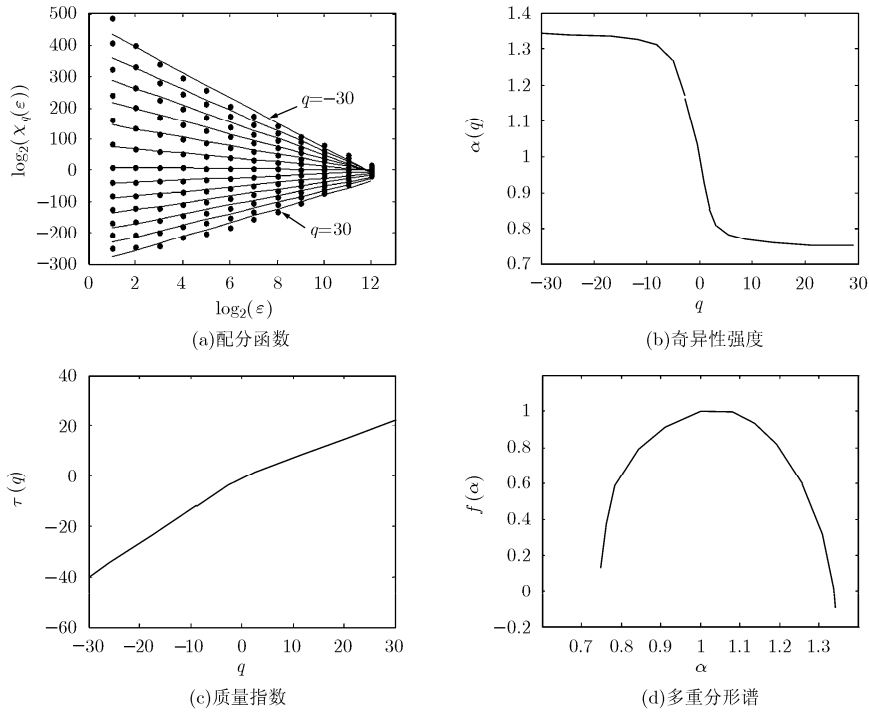




图 3 数据 2 多重分形特性



(a) 3 维图



(b) 等高线图

图 4 $\Phi(q', q'')$ 的 3 维图及其等高线图







图 5 关联矩指数



(a) 数据 1(HH 极化)



(b) 数据 1(VV 极化)



(c) 数据 2

图 6 杂波单元与目标单元的多重分形关联谱

由图 6 可知，多重分形关联谱从中心到两侧的“翼”部分有一个“剧变”，这与标度区域相变对应。同时，距离单元中目标的存在会引起多重分形关联谱的变化，而且这种变化相对比较稳定，但对不同类的数据而言，目标与杂波的区别不尽相同：图 6(a)

与 6(b)所示的是同一波段不同极化条件下的数据的多重分形关联谱，目标的存在使谱有所“展宽”，并且从直观上来讲，HH 极化下的区别要大于 VV 极化下的区别；对比图 6(a)，6(b)和 6(c)，这是在不同波段不同分辨率条件下得到的多重分形关联谱，

相对于图 6(a), 6(b), 在图 6(c)中, 目标的存在使谱有所“收缩”, 但任一种情况下, 谱的差异均比较明显。进一步分析, 引起差异不同的因素可能有: 目标物理特性不同, 从而导致回波特性也存在差异; 雷达极化方式的不同。这两方面因素的影响程度并不相同, 下文分别对这两方面因素的影响程度加以量化分析, 得到主要影响因素。图 7 与图 8 分别给出了 3 种情况下海杂波以及存在目标情况下海杂波的多重分形关联谱的比较。

这里采用欧氏距离来度量海杂波和目标加杂波的多重分形关联谱之间的差异。距离大表明对应的因素对结果影响大, 反之, 则对应的因素对结果影响较小。表 1 和表 2 分别给出了 3 种情况下数据的多重分形关联谱之间的距离。表中所示距离值是每组海杂波(存在与不存在目标两种情况)各取 100 段数据进行计算并取平均值得到的。从表 1 和表 2 中可以看到, 数据 1 的 HH 与 VV 极化情况之间的多重分形谱距离相对较小, 分别为 9.7975 和 6.6768, 而数据 1 两种极化条件下的目标为同一目标, 其它条件基本相同, 因此这个差异主要是因为雷达极化方式不同引起的, 可见, 针对本文数据而言, 由极化引起的差异相对较小; 而数据 1 与数据 2 多重分形关联谱之间的差异相对于数据 1 两种极化条件下多重分形关联谱之间的差异都较大, 存在目标的情况下, 差异更大一些。数据 1 与数据 2 的极化方式、分辨率以及目标回波特性均不相同, 但对比表 1 与表 2 可以发现, 数据 1 与数据 2 之间的极化方式、分辨率之间的差异均未发生变化, 只有目标发生了变化, 因此, 可以认为是目标回波特性的不同使表 2 中数据 1 与数据 2 之间的差异加大。这里需指出的是, 此处的分析将问题简单化, 并没有考虑其它随机因素的影响。同时, 从表 1 还可以看到, 纯海杂波的多重分形关联谱在不同分辨率下不同极化方式下也是比较稳定的。

表 1 纯海杂波多重分形关联谱之间的距离

	数据 1 (HH 极化)	数据 1 (VV 极化)	数据 2
数据 1 (HH 极化)	—	9.7975	10.3623
数据 1 (VV 极化)	9.7975	—	13.1368
数据 2	10.3623	13.1368	—

表 2 存在目标情况下数据多重分形关联谱之间的距离

	数据 1 (HH 极化)	数据 1 (VV 极化)	数据 2
数据 1 (HH 极化)	—	6.6768	23.7863
数据 1 (VV 极化)	6.6768	—	21.8998
数据 2	23.7863	21.8998	—

为将这种差异用于检测, 本文将这种距离非线性化, 并采用模板(均值)来减小随机因素的影响, 因此, 可利用 2.2 节中给出的相似度来分析回波信号中是否包含目标回波。

首先, 在 3 种情况下的数据中, 每组数据选择 200 段纯杂波数据用于训练模板, 每段数据为 4096 个采样点, 段与段之间重叠 50%。然后, 输入测试数据, 分别计算其对海杂波模板的相似度, 若其中不含目标, 则根据海杂波多重分形关联谱的稳定性, 相似度应该接近于 1; 若含有目标, 则相似度应该较小, 接近于 0。

图 9 给出了利用多重分形关联谱进行相似度分析的结果。可以看到, 数据 1 在 HH 极化条件下, 杂波与目标对杂波模板的相似度重叠较少, 可分性较强, 数据 2 也有类似于此的结果; 数据 1 在 VV 极化条件下, 杂波与目标的重叠比较严重, 可分性较弱。为便于对比, 图 10 给出了利用相同数据的多重分形谱进行相似度分析的结果。可以很直观地看到, 利用多重分形关联谱进行相似度分析的可分性总体上要优于利用多重分形谱进行相似度分析的可分性, 究其原因, 主要是因为多重分形关联谱考虑了序列多重分形统计的空间相关特性, 即“两点”统




图 7 不同数据的海杂波多重分形关联谱




图 8 不同数据的杂波加目标的多重分形关联谱




图 9 多重分形关联谱对模板的相似度




图 10 多重分形谱对模板的相似度

计, 得到了比多重分形的“单点”统计更多的信息。

相似度分析的结果可以直接用于目标检测, 首先对大量数据进行统计, 得到经验门限值, 然后把待测信号的相似度与门限比较, 低于门限即认为海杂波中存在目标, 反之则认为不存在目标。这种门限是固定门限, 而且要得到门限需要大量确知样本的支持, 这无疑降低了检测的效率与检测方法的实用性。

实际上, 海杂波中的目标检测问题可以等效为一个二元分类问题, 即存在目标和不存在目标。因此, 可以采用 2.3 节中给出的 SVM 来区分目标与杂波。SVM 是针对线性不可分的情况, 通过使用非线性映射算法将低维输入空间线性不可分的样本转化到高维特征空间使其线性可分, 从而使在高维特征空间采用线性算法对样本的非线性特征进行线性分析成为可能, 而且它对小样本同样可用, 较好地解决了无法得到大量样本的问题。另外, 在所采用的目标检测方法中, 模板的选取以及 SVM 的训练可以直接利用同一批海杂波进行。这样是符合实际情况的, 原因如下: 首先, 岸基雷达所面对的海面区域基本是一定的, 海面情况在短时间内变化不会太大(与海情有关); 其次, 雷达照射时间一般比较短, 这么短的时间内海情变化不大。

采用改进的径向基核函数^[12,15,16], 参数为 $\sigma = 1.2$, $\lambda = 19$, $C = 100$ 。表 3 给出了虚警概率

在 0.05 以下时分别采用固定门限时和 SVM 分类时的检测概率, 可以发现采用 SVM 进行分类的检测概率远高于采用固定门限时的检测概率。这是因为采用改进径向基核函数的 SVM 把原本线性不可分的情况映射到高维空间后变得可分了, 而采用固定门限时, 对于图 9(a)、9(c)可分性较好的情况, 要达到较高的检测概率, 门限必须较高, 这同时也带来了较高的虚警概率, 而对于图 9(b)所示的情况, 基本上无法区分。同时, 表 3 也给出了以多重分形谱作为特征矢量然后采用 SVM 进行检测的检测概率, 可见其远不如以多重分形关联谱为特征进行检测的检测概率。

最后, 分析参数 ω 对检测结果的影响。在区域 I 中, 当 $\omega \rightarrow 0$ 时, $r \rightarrow 1$, 此时式(11)与式(12)化为相同的形式, 这时相变消失; 而 $\omega \rightarrow 1$ 时, $r \rightarrow \varepsilon$, $\tilde{\tau}(q', q'', \omega)$ 是由奇异性强度为 $\alpha(q', q'')$ 的特定集支

表 3 采用不同方法的检测概率(%)

采用特征及分类方法	数据 1 (HH 极化)	数据 1 (VV 极化)	数据 2
多重分形谱+SVM	69	49	71
多重分形关联谱 +固定门限	57	19	56
多重分形关联谱 +SVM	90	67	88

配, 换言之为, 在奇异性强度为 α' 的小区域内找到的点奇异性强度 α'' 就为 α' (即 $\alpha'' = \alpha'$)。在区域 II 中, α' 与 α'' 彼此独立地支配 $\tilde{\tau}(q', q'', \omega)$, 与 ω 无关。为量化 ω 对最终检测结果的影响, 选取 100 段测试数据, 其中 50 段含有目标, 另外 50 段不含有目标, 混杂在一起。表 4 给出了不同 ω 值下通过 SVM 分类后含目标数据段正确判决的数目。

表 4 不同 ω 值下的正确判决数

ω	0	0.2	0.4	0.6	0.8	0.95	1
正确判决	46	46	46	46	45	45	46

由表 4 可以发现, ω 值对最终判决结果的影响不大, 正确发现的概率都在 88% 左右。可见, 由于标度区域的相变而引起的多重分形关联谱的边缘“剧变”, 并没有影响 SVM 的分类结果, 主要原因是存在目标引起的多重分形关联谱的这种差异同时体现在两个标度区域, 而 ω 的变化只是使两个标度区域的范围重新划分, 这种差异还是稳定存在的, 从而使进行相似度分析的结果基本不受影响, 最终基本不影响分类结果。

4 结束语

本文主要研究了海杂波的多重分形关联特性及其在微弱目标检测中的应用。首先介绍了多重分形关联的参数估计方法, 分析实测海杂波的多重分形关联特性, 得到了海杂波的多重分形关联谱。然后, 根据海杂波与目标的多重分形关联谱的差异, 采用模糊理论进行分析, 得到相似度函数, 并采用支持向量机分类的方法解决固定门限所带来的虚警概率较高的问题。最后, 分析比较了该检测方法的检测性能, 并研究了参数 ω 对最终检测性能的影响。试验结果表明, 本文所提方法检测概率较高, 具有良好的微弱目标检测能力, 这里需要指出的是, 本文在采用实测海杂波进行分析过程中, 没有考虑风速、风向、气象杂波等因素的影响, 这有待于进一步研究。

参 考 文 献

[1] Falconer K. Fractal Geometry: Mathematical Foundations and Applications (second edition) [M]. England: John Wiley & Sons, 2003: 3-108.

[2] Meneveau C and Chhabra A. Two-point statistics of multifractal measures[J]. *Physica A*, 1990, 164: 564-576.

[3] O'Neil J and Meneveau C. Spatial correlation in turbulence: Predications from the multifractal formalism and comparison with experiments[J]. *Physics Fluids A*, 1993, 5(1): 158-172.

[4] 周炜星, 王延杰, 于遵宏. 随机二项测度的多重分形分析和多重分形关联分析[J]. 非线性动力学学报, 2001, 8(3): 199-207. Zhou Wei-xing, Wang Yan-jie, and Yu Zun-hong. On the multifractal and multifractal correlation of random binomial measures[J]. *Journal of Nonlinear Dynamics in Science and Technology*, 2001, 8(3): 199-207.

[5] 王艳玲, 张玘, 罗诗途. 基于模糊模式识别的场景图像分类方法[J]. 微计算机信息, 2007, 23(34): 226-227. Wang Yan-ling, Zhang Qi, Luo Shi-tu. Classification method of scene pictures based on blur pattern recognition[J]. *Microcomputer Information*, 2007, 23(34): 226-227.

[6] Vapnik V N. The Nature of Statistical Learning Theory[M]. New York: Springer-Verlag, 1995: 5-39.

[7] 孙霞, 吴自勤, 黄昀. 分形原理及其应用[M]. 合肥: 中国科学技术大学出版社, 2006: 53-87.

[8] 陈双平, 郑浩然, 马猛, 等. 用统计物理的方法计算信源熵率[J]. 电子与信息学报, 2007, 29(1): 129-132. Chen Shuang-ping, Zheng Hao-ran, and Ma Meng, et al. Computing the entropy rate of information source with methods of statistical physics [J]. *Journal of Electronics & Information Technology*, 2007, 29(1): 129-132.

[9] 李京华, 许家栋, 李红娟. 支持向量机的战场直升机目标分类识别[J]. 火力与指挥控制, 2008, 33(1): 31-34.

[10] 刘宏兵, 熊盛武. 一类快速模糊支持向量机[J]. 系统仿真学报, 2008, 20(24): 6664-6667. Liu Hong-bing and Xiong Sheng-wu. A kind of fast fuzzy support vector machines[J]. *Journal of System Simulation*, 2008, 20(24): 6664-6667.

[11] Ji Ai-bing, Pang Jia-hong, and Li Shu-huan. Support vector machine for classification based on fuzzy training data[C]. Proceedings of the 5th International Conference on Machine Learning and Cybernetics, Dalian, 2006: 1609-1614.

[12] 姜斌, 王宏强, 黎湘. 海杂波背景下的目标检测新方法[J]. 物理学报, 2006, 55(8): 3985-3991. Jiang Bin, Wang Hong-qiang, and Li Qiang. A novel method of target detection based on the sea clutter[J]. *Acta Physica Sinica*, 2006, 55(8): 3985-3991.

[13] <http://soma.ece.mcmaster.ca/ipix>[EB/OL]

[14] Hu Jing, Tung Wen-wen, and Gao Jian-bo. Detection of low-observable targets within sea clutter by structure function based multifractal analysis[J]. *IEEE Transactions on Antennas and Propagation*, 2006, 54(1): 136-143.

[15] Sebald D J and Bucklew J A. Support vector machine techniques for nonlinear equalization[J]. *IEEE Transactions on Signal Processing*, 2000, 48(11): 3217-3226.

[16] Gunn S R. Support vector machines for classification and regression[R]. Technical Report, University of Southampton, 1998: 5-23.

关 键: 男, 1968 年生, 教授, 博士生导师, 研究方向为雷达信号处理、恒虚警检测、侦察图像处理等。

刘宁波: 男, 1983 年生, 博士生, 研究方向为雷达信号处理。

张 建: 男, 1982 年生, 博士生, 研究方向为雷达信号处理。

宋 杰: 男, 1981 年生, 博士, 讲师, 研究方向为雷达信号处理。