

基于多分辨分析的雷达目标识别方法^{*}

张 恂 郭桂蓉 庄钊文

(国防科技大学自动目标识别国家实验室 长沙 410073)

摘 要 针对宽带高距离分辨率雷达的工作体制, 提出了一种基于多分辨分析和信息综合的目标识别算法。目标特征由小波变换在相邻分辨率上的能量之比的对数构成。利用多分辨分析, 将目标特征分解为反映目标结构概貌的低通特征和刻画目标结构细节的高通特征。利用辐射基函数神经网络分别对目标的低通特征和高通特征进行识别判决, 然后将基于目标的低通特征和高通特征的判决信息进行综合, 得到最终的识别结果。

关键词 目标识别, 小波变换, 神经网络

分类号 TN959.17

Radar Target Recognition Based on Multiresolution Analysis

Zhang Xun Guo Guirong Zhuang Zhaowen

(ATR National Laboratory, NUDT, Changsha, 410073)

Abstract A target recognition approach based on multiresolution analysis is proposed, and tested on returns of high range resolution radar. Features of targets are extracted by computing the logarithms of the ratios of energies in adjacent scales defined by wavelet transform. With multiresolution analysis, the features are decomposed into the highpass features reflecting detailed structure of targets and the lowpass features showing the outline of the targets. A radial basis function neural network is applied for classification.

Key words target recognition, wavelet transform, neural network

目标特征的提取方法以及分类识别算法是雷达目标识别的主要研究内容。对于近年来发展起来的宽带高距离分辨率雷达系统, 复杂目标可被视为由一组离散的散射中心所构成, 称之为目标的径向距离像。目标的径向距离像可由对频域测量数据进行逆傅立叶变

* 国防预研基金资助项目
1996 年 5 月 27 日收稿

换而获得^[1]。从时域的目标径向距离像中,可以得到有关目标的结构信息,因此目标径向距离像可以作为描述目标的特征。传统的傅立叶变换将在时域上无限延伸三角函数作为正交基函数。因此,傅立叶分析只能获得信号的整体频谱,而不能描述信号的局部特征。小波变换使用具有有限支撑性质的函数作为基函数。因此,小波变换在时域和频域上同时具有良好的局部化性质。Mallat 将正交小波基的构造统一起来,提出多分辨分析的概念^[2]。基于小波变换的多分辨分析是一种特征提取和数据压缩的有效方法。神经网络分类器有着比传统分类器更优良的性能。辐射基函数神经网络的训练速度快,它的接收域是局部的,非常适合于高维空间的分类问题^[3]。

1 基于小波变换的多分辨分析

多分辨分析是利用小波变换,将函数表示为在时间和频率的不同分辨率上的分量的组合,它将函数映射到一系列相互嵌套的逼近空间中。

设 P_j 为一线性算子,对于某个函数 $f \in L^2(R), f_j = P_j f$ 在分辨率 2^{-j} 上逼近函数 f 。对于向量空间 $V_j \subset L^2(R), f_j$ 是 f 的最佳逼近。易知, P_j 是 f 在 V_j 上的正交投影映射。若满足下面诸条件:

$$P_j f = f_j, V_j \subset L^2(R) \tag{1}$$

$$V_j \subset V_{j-1} \subset \dots, \forall j \in Z \tag{2}$$

$$\bigcup_{j \in Z} V_j = L^2(R) \tag{3}$$

$$\bigcap_{j \in Z} V_j = 0 \tag{4}$$

$$f \in V_j \Leftrightarrow f \in V_{j-1} \tag{5}$$

则空间 $L^2(R)$ 中的一系列闭子空间 $\{V_j, j \in Z\}$ 称为 $L^2(R)$ 的一个多分辨分析。显然,较高的分辨率空间 V_{j-1} 一般比较低的分辨率空间 V_j 含有更多的信息。设 W_j 为 V_j 在 V_{j-1} 中的正交补,则 $V_{j-1} = V_j \dot{\cup} W_j$ 。若 V_j 满足(1)式~(5)式,则存在尺度函数 $\mathcal{Q}_{j,k}(x) = 2^{-j/2} \mathcal{Q}(2^{-j}x - k), j, k \in Z$, 且 $\mathcal{Q}_{j,k}(x)$ 构成 V_j 的基。同理,存在小波函数 $\Psi_{j,k}(x) = 2^{-j/2} \Psi(2^{-j}x - k), j, k \in Z$, 且 $\Psi_{j,k}(x)$ 构成 W_j 的正交基。

$$\text{令 } h(n) = \int_{-\infty}^{+\infty} \mathcal{Q}(x) \mathcal{Q}(2x - n) dx, \text{ 则}$$

$$\mathcal{Q}(x) = \sum_{n=-\infty}^{+\infty} h(n) \mathcal{Q}(2x - n) \tag{6}$$

$$\text{令 } g(n) = \int_{-\infty}^{+\infty} \Psi_0(x) \mathcal{Q}(2x - n) dx, \text{ 则}$$

$$\Psi_0(x) = \sum_{n=-\infty}^{+\infty} g(n) \mathcal{Q}(2x - n) \tag{7}$$

$h(n)$ 和 $g(n)$ 之间存在下面关系:

$$g(n) = (-1)^{n-1} h(1-n) \tag{8}$$

因此,对于这个多分辨分析算法,不同分辨率之间的计算仅仅依赖于函数 g 和 h , 而不必考虑函数 Ψ 和 \mathcal{Q} 。

由(8)式可知, g 和 h 的选取是有约束的,即 g 和 h 的选取应使 $\{\mathcal{Q}_{j,k}(x), j, k \in Z\}$ 构成

W_j 的规范正交基。考虑到实现的快速性和雷达目标回波中散射中心变化较缓慢的特点, 可选择满足上述约束条件的 Harr 小波:

$$h(n) = \begin{cases} \frac{1}{2} & n = 0, 1 \\ 0 & n \text{ 为其他整数} \end{cases} \quad (9a)$$

$$g(n) = \begin{cases} -\frac{1}{2} & n = 0 \\ \frac{1}{2} & n = 1 \\ 0 & n \text{ 为其他整数} \end{cases} \quad (9b)$$

信号的多分辨分析将信号在不同分辨率上分别分解为低通成分 h 和高通成分 g 。信号的低通成分反映信号的概貌, 信号的高通成分刻画信号的细节。

2 辐射基函数神经网络

辐射基函数神经网络是由隐含层和输出层构成的双层网络, 其结构如图 1 所示。隐含层的辐射基函数对输入激励产生了一个局部化响应, 也就是说, 当输入落到输入空间的一个较小的局部区域内时, 便产生一个有效的非零响应。辐射基函数一般采取如下形式的高斯核函数:

$$\mu_j = \exp\left[-\frac{(x - w_{1j})^T(x - w_{1j})}{2\sigma_j^2}\right] \quad j = 1, \dots, N_1 \quad (10)$$

其中, μ_j 是隐含层中第 j 个节点的输出, x 是输入模式, w_{1j} 是隐含层中第 j 个节点的加权矢量(关于第 j 个节点的高斯中心), σ_j^2 是隐含层中第 j 个节点的归一化参数, N_1 是隐含层的节点数。

输出层的节点形成对隐含层的输出的加权线性组合。

$$y_j = w_{2j}^T \mu_1 \quad j = 1, \dots, N_2 \quad (11)$$

其中, y_j 是输出层第 j 个节点输出, w_{2j} 是输出层中第 j 个节点的加权矢量, μ_1 是隐含层的输出矢量, N_2 是输出层的节点数。

因此, 整个神经网络通过形成(10)式中的非线性基函数的线性组合, 有效地确定数据中心的高斯核, 然后加权和取门限, 产生判决结果。

辐射基函数神经网络的学习分两步: 隐含层学习和输出层学习。隐含层的学习一般用非监督方法。这里采用 k -均值聚类方法得到隐含层的权矢量。然后, 求其归一化参数 σ_j^2 , 它表示每个节点收集数据的散布程度, 一般是使它等于训练模式和 w_j 之间的平均距离:

$$\sigma_j^2 = \frac{1}{m_{jx}} \sum_{\theta} (x - w_j)^T(x - w_j) \quad (12)$$

在输出层, 采用有监督的学习方法。输入是隐含层的输出 μ_j , 期望输出取节点输出




图 1

的最大值。这里使用最小均方误差算法来训练输出层的权值。

3 目标特征提取与识别

在雷达目标回波中, 径向散射中心的分布相对于噪声干扰的分布是慢变化的信息。因此, 目标中有相当一部分信息位于低频段。通过多分辨分析算法, 可以从低通特征 h 获得目标信号慢变化部分的信息; 从高通特征 g 获得目标信号快变化部分的信息。所以, 低通特征 h 是对目标结构特征概貌的描述, 而高通特征 g 是对目标结构特征细节的描述。

设目标信号在分辨率 2^{-j} 上的低通特征和高通特征分别为 $h_j(n)$ 和 $g_j(n)$, $n = 1, \dots, k$, 信号在其上低通特征和高通特征的能量为:

$$E_{h_j} = \sum_{n=1}^k h_j^2(n) \quad (13a)$$

$$E_{g_j} = \sum_{n=1}^k g_j^2(n) \quad (13b)$$

取相邻分辨率的能量比的对数构成目标特征向量的分量。对于低通情形和高通情形其特征向量分别为

$$\left\{ \log \frac{E_{h_1}}{E_{h_2}}, \log \frac{E_{h_2}}{E_{h_3}}, \dots \right\} \quad (14a)$$

$$\left\{ \log \frac{E_{g_1}}{E_{g_2}}, \log \frac{E_{g_2}}{E_{g_3}}, \dots \right\} \quad (14b)$$

这种特征向量能够有效地反映目标结构中的自相似性。由于利用信号在某一段时间上的能量而不是信号在这段时间上的波形信息, 因而对那种随时间波形发生变化而能量不变的信号而言, 其特征具有相对不变性。这正是目标识别中所希望的特性。

基于上述方法提取的目标特征在低通情形和高通情形下分别为 T_1 和 T_2 。将特征 T_1 和 T_2 输入辐射基函数神经网络得到判决 D_1 和 D_2 。将 D_1 和 D_2 按下面方法综合为最终判决 D :

$$D = \alpha D_1 + (1 - \alpha) D_2 \quad (0 \leq \alpha \leq 1) \quad (15)$$

在判决层, 对 D 择大弃小, 作出判断。这种方法有助于提高了目标的识别率。

4 实验结果及分析

本文使用的数据是由 Ka 波段阶梯变频雷达对 5 类军用飞机目标的缩比模型进行测量所得到的。这 5 类飞机目标的代号分别是: H, J, Y, W, F。在横滚角为 0° 、俯仰角为 0° 、偏航角为 $0 \sim 30^\circ$ 的情形下, 对目标鼻锥向进行测量, 角度步进间隔为 1° 。

训练时, 对 $0 \sim 30^\circ$ 偶数姿态角的信噪比为 25dB 的测量数据, 利用本文提出的方法提取目标的特征, 形成 3000 个训练样本。识别时, 利用目标在 $0 \sim 30^\circ$ 范围内奇数姿态角的特征, 加入高斯白噪声, 形成 3000 个测试数据, 将之输入到辐射基函数神经网络中, 便得到表 1~3 所示的实验结果。表 1 是在 $\alpha = 0$, 即仅使用高通特征判决信息时所得到的结果。表 2 是在 $\alpha = 1$, 即仅使用低通特征判决信息时所得到的结果。表 3 是在 $\alpha = 0.6$, 即综合低通特征判决信息和高通特征判决信息时所得到的结果。从实验结果可以看出, 使用高

通特征在信噪比较低情形下识别率较低。这是因为高通特征对噪声较为敏感。由于低通特征对噪声较不敏感,故在信噪比较低情形下识别率较高。但由于低通特征包含目标的细节信息较少,故在高信噪比情形下识别率不如高通特征的好。当综合这两种特征信息时可以得到较好的识别率。

表 1 五类飞机目标在不同信噪比下的识别率, $\alpha=0$

识别率 信噪比 类型	0 dB	5 dB	10 dB	15 dB	20 dB
F	14.0%	43.3%	67.3%	85.0%	89.8%
Y	21.0%	49.7%	78.3%	80.3%	83.3%
J	12.0%	37.3%	88.0%	94.5%	96.0%
H	28.7%	43.2%	71.0%	80.3%	84.0%
W	38.7%	48.0%	84.0%	90.5%	92.2%

表 2 五类飞机目标在不同信噪比下的识别率, $\alpha=1$

识别率 信噪比 类型	0 dB	5 dB	10 dB	15 dB	20 dB
F	40.0%	63.3%	71.3%	78.0%	80.0%
Y	60.0%	67.8%	70.3%	74.3%	78.3%
J	63.5%	73.5%	80.0%	85.5%	87.0%
H	44.7%	59.3%	63.0%	67.3%	70.0%
W	58.0%	68.0%	70.0%	73.7%	77.7%

表 3 五类飞机目标在不同信噪比下的识别率, $\alpha=0.6$

识别率 信噪比 类型	0 dB	5 dB	10 dB	15 dB	20 dB
F	45.7%	69.3%	80.3%	88.5%	90.7%
Y	70.0%	78.0%	85.0%	86.7%	88.7%
J	70.7%	84.7%	95.3%	97.3%	98.3%
H	55.3%	67.3%	80.2%	85.3%	87.3%
W	64.7%	79.3%	91.4%	92.5%	94.5%

参考文献

- 1 Mensa D L. High Resolution Radar Imaging. Deaham, MA: Artech House, 1981
- 2 Mallat S G. A Theory for Multiresolution Signal Decomposition: the Wavelet Representation. IEEE Transaction on Pattern Analysis and Machine Intelligence, 1989, 11: 674 ~ 693
- 3 Powell. M J D. Radial Basis Function Approximations to Polynomials. in Proc. 12th Biennial Numerical Analysis Conference, 1987: 223 ~ 241

(责任编辑 潘生)