

基于递归神经网络的飞机目标识别方法^{*}

肖怀铁 庄钊文 郭桂蓉

(国防科技大学电子技术系 长沙 410073)

摘 要 针对宽带高距离分辨全极化雷达体制,提出了一种基于实时递归神经网络算法的飞机目标自动识别方法,实现了全极化下五类飞机目标的自动识别。实验结果表明,递归神经网络用于飞机目标识别是有效可行的。

关键词 递归神经网络,飞机目标识别。

分类号 TN957.52

Aircraft Target Recognition Based on Recurrent Neural Network

Xiao Huaitie Zhuang Zhaowen Guo Guirong

(Department of Electronic Technology, NUDT, Changsha, 410073)

Abstract In this paper, an aircraft target automatic classifier based on real time recurrent neural network algorithm is proposed under the wide band fully polarized high range resolution radar. This new neural network classifier is applied to the classification of five types of aircraft targets. The result demonstrates the feasibility of using recurrent neural networks for aircraft target recognition.

Key Word recurrent neural network, aircraft target recognition.

由于复杂的识别背景和目标本身的动态变化,飞机目标识别是一个难度较大的模式识别问题。人工神经网络(ANN)具有自适应、自组织、自学习的能力,可以处理一些环境信息十分复杂、背景知识不清楚的问题,允许样本有较大的缺损和畸变,为非合作目标的识别提供了一种自适应的方法。ANN技术在飞机目标识别领域中有初步的应用,例如,文献[1]采用异联想存储器神经网络与基于微波成像来识别飞行器,文献[2]用多层感知器与基于多频雷达回波完成了商用飞行器的分类等。本文提出了一种基于实时递归神经网络算法的飞机目标自动识别方法,将高分辨一维距离像经过门限和加窗处理,获得反映

* 国防预研项目资助
1996年11月11日收稿

目标结构信息的特征, 作为神经网络分类器的输入矢量, 并综合 4 种单极化结果, 实现了全极化态下 5 类飞机目标的自动识别。

1 实时递归神经网络学习算法

递归神经网络具有很强的非线性变换特性, 实时递归学习算法 (RTRL)^{[3][4]} 是一种动态算法, 网络的输出不仅仅对当前输入数据产生响应, 而且与过去输入数据也有关。一个基本的递归网络包括两层神经元, 其结构如图 1 所示。每一个 RTRL 节点 i 在时间 t 的输出值 $y_i(t)$ 为:

$$y_i(t) = F_i \left[\sum_j Y_j(t-1) W_{ij}(t-1) \right] \quad (1)$$

式中, j 为输入层节点。当 $1 \leq j \leq m$ 时, $Y_j(t-1) = x_j(t-1)$; 当 $m+1 \leq j \leq m+n$ 时, $Y_j(t-1) = y_{j-m}(t-1)$ 。

$W_{ij}(t)$ 为节点 i 和节点 j 的连接权值, $F_i(\cdot)$ 为节点 i 的传输函数。 $\Delta W_{ij}(t)$ 为训练过程权值 $W_{ij}(t)$ 的修正量:

$$\Delta W_{ij}(t) = \alpha \sum_k (e_k(t) p_{ijk}(t)) \quad (2)$$

式中, i, k 为 RTRL 节点; α 为学习率;

$$e_k(t) = \begin{cases} \text{期望输出} - \text{实际值}, & \text{当 } i \text{ 为目标节点} \\ 0, & \text{当 } i \text{ 为非目标节点} \end{cases} \quad (3)$$

为节点 k 在 t 时刻的输出误差; $p_{ijk}(t) = \partial y_k(t) / \partial W_{ij}(t)$, 它反映了 $W_{ij}(t)$ 对节点 k 输出值 $y_k(t)$ 的影响。若 $t=0$, 则 $p_{ijk}(t)=0$; 若 $t+1$ 不为 0, l 为 RTRL 节点, m 为输入层节点,

$$p_{ijk}(t+1) = F_k' \left(\sum_m y_m(t) W_{km}(t) \right) \left[\sum_l W_{kl}(t) p_{ijl}(t) + \delta_{ik} y_j(t) \right] \quad (4)$$

其中, $F_k'(\cdot)$ 为 $F_k(\cdot)$ 的导数, δ_{ik} 为 Kronecker 函数。训练中权值的更新由下列公式描述:

$$\begin{aligned} \Delta W_{ij}^*(t) &= 0, p_{ijk}(t) = 0, && \text{对于每一迭代开始时刻 } t \\ \Delta W_{ij}^*(t) &= \Delta W_{ij}^*(t-1) + \Delta W_{ij}(t) && \text{对于每一个迭代时间 } t \end{aligned} \quad (5)$$

$$W_{ij}(t) = W_{ij}(t-1) + \Delta W_{ij}^*(t) \quad \text{对于每一迭代结束时刻 } t \quad (6)$$

每一次迭代过程, RTRL 节点的输出值为:

$$y_i(t+1) = F_i \left(\sum_j Y_j(t) W_{ij} \right) \quad (7)$$

W_{ij} 为连接节点 i 和节点 j 的权值, 在每次迭代过程中保持为常数。

2 基于实时递归神经网络算法的飞机目标识别方法

2.1 高分辨一维距离像




图 1 递归神经网络结构示意图

高分辨力雷达对目标的探测可以揭示目标精细的几何结构和表面材料的组成。频带越宽,对目标的径向距离分辨力越高。一个复杂的目标可视为多个散射中心的合成。当发射信号的带宽足够宽,可以使径向距离分辨力远小于目标尺寸。此时目标占据连续多个距离单元,在距离轴上的投影为目标的径向距离像(Range Profile),如图2所示。




图2 雷达目标一维距离像

2.2 目标特征预选与压缩

测量是对每一离散频率点进行的,获得的一组频域数据为:

$$S[k] = S[(f_k - f_{\min}) / \Delta f] (k = 0, 1, \dots, N - 1)$$

其中, N 为取样频率点数, f_k 为第 k 个频率, f_{\min} 为最低频率, Δf 为频率间隔。

目标散射中心沿径向距离的分布图是 $S[k]$ 的逆富氏变换:

$$s(n) = \frac{1}{N} \sum_{k=0}^{N-1} S[k] e^{j2\pi kn / (N-1)} (n = 0, 1, \dots, M - 1)$$

其径向距离单元数比较大,不能直接作为神经网络的输入,仍需对时域数据作些处理。给距离像加入适当的门限后,假设目标 i 距离像包含 m 个距离分辨单元,它反映了目标的不同宽度,作为神经网络的输入特征。然后,将 m 个距离分辨单元分成 n 个等区间,在每一区间,取峰值的均值作为特征。

2.3 目标特征序列的获取

目标的一维距离像和窄带 RCS 的变化趋势基本一致,但目标的高分辨一维距离像随姿态的变化没有 RCS 剧烈,显示出一维距离像用于目标识别的优势。但是距离像对姿态的变化还是比较敏感,姿态较大变化时发生距离漂移。要完整表征目标,需要各个姿态角的距离像,数据量应很大的。本文采用距离像序列来表征飞机目标,因为相邻姿态的距离像存在相似性,用较小姿态角变化获得的距离像序列表征目标,可以减少姿态角变化对识别性能的影响,克服利用单个距离像来识别的困难,得到的目标特征序列更具有代表性。

2.4 飞机目标自动识别算法

2.4.1 基于递归神经网络的训练算法:

(1) 从每类目标中选取一定数目的特征序列构成训练集 T , 设训练集 T 由 S 个序列组成, 每个序列包括 F 个特征矢量。

(2) 若目标类别数为 m , 输入特征矢量的维数为 n , 神经网络的隐层数为 h , 则网络的输出层节点数为 $M = m + h$, 网络输入层节点数为 $N = M + n$ 。

(3) $t = 0, s = 0, f = 0$, 初始化网络权值 $W_{ij}(t) (i = 1, 2, \dots, M; j = 1, 2, \dots, N)$ 。

(4) 令均方误差 $J = 0, \Delta W_{ij}^*(t) = 0, t = t + 1, s = 0$ 。

(5) 令 $y_i(t) = 0, p_{ijk}(t) = 0, s = s + 1, f = 0$ 。

(6) 令 $e(i) = 0, \Delta W_{ij}(t) = 0, f = f + 1$ 。

(7) 输入第 s 个序列的第 f 个特征矢量。

(8) 由(1)式计算 RTRL 节点的输出值 $y_i(t)$ 。

- (9) 由(3)式计算输出误差 $e(i)$ 和 $J = J + 0.5e(i) \cdot e(i)$ 。
- (10) 利用(2)、(5)式计算权值 $W_{ij}(t)$ 的修正量 $\Delta W_{ij}(t)$ 和累积权值修正量 $\Delta W_{ij}^*(t)$ 。
- (11) 由(4)式计算参数 $p_{ijk}(t)$ 。
- (12) 若 $f = F$, 则转(13), 否则转(6)。
- (13) 由(6)式得到新的权值。
- (14) 若 $s = S$, 则转(15), 否则转(5)。
- (15) 若 $J <$ 设定值, 则存储 $W_{ij}(t)$, 结束, 否则修正学习步长 α , 转(4)。

2.4.2 基于递归神经网络的分类算法:

网络训练结束后, 用它来对测试样本进行分类, 对每个序列的分类算法如下:

- (1) 设每个序列包括 F 个特征矢量, 令 $f = 0$ 。
- (2) $f = f + 1$ 。
- (3) 输入序列的第 f 个特征矢量。
- (4) 由(7)式计算 RTRL 节点的输出值 $y_i(t)$ 。
- (5) 若 $f = F$, 则将结果分类; 否则转(2)。

基于以上讨论, 我们构造了一个飞机目标自动分类器, 其结构如图3所示。




图3 递归神经网络飞机目标分类器

3 目标识别实验研究

本文共对5种飞机缩比模型进行了测量, 5种飞机是H: 战斗机, J: 歼击轰炸机, Y: 预警机, W: 侦察机, F: 战斗机。目标缩比后, 尺寸大约在1.5m ~ 2.0m之间。测量系统为毫米波全极化阶梯变频雷达, Ka波段, 带宽1GHz, Δf 为2MHz。测量角度间隔1°。对偏航角分三段测量: 鼻锥向(0° ~ 30°)、机腹向(-20° ~ 20°)、机尾向(0° ~ 30°), 识别时只需预知目标姿态的大致范围。频域500点测量数据IFFT后, 得到一维距离像, 距离单元数为64。将目标距离像序列经过门限、加窗和特征预选, 获得了五类目标的特征序列, 特征维数为8。

3.1 单极化时的识别结果

在单极化(HH、HV、VH或VV)情况下, 对5种飞机目标在每一偏航角范围段内分别建模。其中对奇数姿态角度下的特征序列数据加入SNR=25dB的白噪声, 形成共1400个训练样本来训练神经网络。测试时, 利用偶数姿态角度下的特征序列数据加入白噪声(SNR=25dB、15dB、10dB三种情况), 形成共4560个测试数据, 来检验飞机目标自动分类器性能。表(1)给出了在三种信噪比下的识别结果, 从表中结果可知, 在信噪比为25dB时, 可得到82%的平均识别率; 信噪比为10dB时, 仍有65%的平均识别率。此说明识别算法是有效的并有较好的抗噪性。

表 1 单极化态时, 5 类飞机目标在信噪比分别为 25dB, 15dB, 10dB 时的识别统计结果

待测目标	F			Y			J			H			W			
SNR(dB)	25	15	10	25	15	10	25	15	10	25	15	10	25	15	10	
结果	F	772	736	660	28	39	65	56	81	104	28	42	67	36	53	68
	Y	28	33	59	752	684	612	35	64	89	65	82	106	27	44	85
	J	49	56	78	34	48	67	735	649	552	37	55	68	41	57	90
	H	38	51	74	61	85	90	38	55	83	740	666	588	48	66	98
	W	25	36	41	37	56	78	47	68	84	42	67	83	760	692	571
识别率(%)	84.6	80.7	72.4	82.5	75.0	67.1	80.6	71.2	60.5	81.1	73.0	64.5	83.3	75.9	62.6	

3.2 全极化时的识别结果

根据图 3 的飞机目标自动分类器, 综合 4 种极化态下的数据对 5 类目标进行识别研究。第一级判决采用单极化下的处理方法, 分别得到 4 种极化态下的输出矢量 $\mathbf{c}_{hh} = (y_{hh1}, y_{hh2}, y_{hh3}, y_{hh4}, y_{hh5})$, $\mathbf{c}_{hv} = (y_{hv1}, y_{hv2}, y_{hv3}, y_{hv4}, y_{hv5})$, $\mathbf{c}_{vh} = (y_{vh1}, h_{vh2}, h_{vh3}, y_{vh4}, y_{vh5})$, $\mathbf{c}_{vv} = (y_{vv1}, y_{vv2}, y_{vv3}, y_{vv4}, y_{vv5})$, 综合评判矩阵 $\mathbf{R} = [c_{hh}, c_{hv}, c_{vh}, c_{vv}]^T$ 。第二级判决选择综合判决矢量 $\mathbf{D} = \mathbf{W} \cdot \mathbf{R} = (d_1, d_2, d_3, d_4, d_5)$, \mathbf{W} 为权重; 根据选大原则, 将被测目标判为 $C_i = \max(d_1, d_2, d_3, d_4, d_5)$ 的目标类 i 。取 $\mathbf{W} = (0.25, 0.25, 0.25, 0.25)$, 结果见表(2)。比较单极化和全极化下的结果, 可以看出, 全极化下的正确识别率有了很大的提高。

表 2 全极化态时, 5 类飞机目标在信噪比分别为 25dB, 15dB, 10dB 时的识别统计结果

待测目标	F			Y			J			H			W			
SNR(dB)	25	15	10	25	15	10	25	15	10	25	15	10	25	15	10	
结果	F	220	211	191	2	2	5	5	8	19	1	13	20	4	7	5
	Y	1	4	10	215	200	178	3	9	20	6	11	16	5	9	15
	J	4	7	14	4	8	14	210	190	161	3	1	5	2	7	16
	H	2	4	9	6	15	22	2	6	10	213	175	168	0	4	11
	W	1	2	4	1	3	9	8	15	18	5	28	19	217	201	181
识别率(%)	96.7	92.5	83.9	94.5	87.6	78.1	92.3	83.5	70.4	93.6	85.4	73.6	95.1	88.2	79.4	

4 结束语

本文应用实时递归神经网络算法, 提出了一种基于高分辨一维距离像序列的飞机目标识别方法, 实现了全极化条件下 5 类飞机目标的自动识别。实验结果表明:

- (1) 网络学习后得到的连接权值, 表征了目标回波的特征信息, 可视为神经网络自动获取的不变性特征, 可称之为“网络不变性”。它不敏感于目标姿态角的变化。
- (2) 本文的预处理方法计算简单, 识别算法具有良好的抗噪性能, 整个识别过程速度快, 正确识别率高, 适于实时处理。
- (3) 雷达回波中极化信息的利用(间接方法), 增加了目标的有关信息, 识别率得到很

大的提高,说明极化中包含了目标丰富的信息。

参考文献

- 1 Nabil H. Farhat Microwave diversity imaging and automated target identification based on models of neural networks. Proceedings of IEEE, 1989, 77(5): 670 ~ 680
- 2 Jouny, L., Garber, F. Classification of radar target using synthetic neural networks. IEEE Trans on Aerospace and Electronic Systems, 1993, 29(2), 336 ~ 344
- 3 Williams, R. J., Zipsper, D. Experimental analysis of the real-time recurrent learning algorithm. Connection Science, 1989, 1: 87 ~ 111
- 4 Lindsey, Randall L. Function prediction using recurrent neural networks MS thesis, AFIT/GE/ENG/91D-02

(责任编辑 潘生)