

# 基于改进神经网络算法的雷达一维距离像识别

段沛沛<sup>1</sup>, 邱天<sup>2</sup>

(1 西安石油大学 计算机学院, 2 北方通用电子集团有限公司)

**摘要:** 雷达一维距离像具有径向分辨率高、相对于雷达目标二维成像获取与处理相对简单的优点, 成为当前国内外雷达目标识别领域研究的热点。但是基于一维距离像的特征提取却存在有平移敏感性、姿态敏感性等问题。针对目标的姿态敏感性问题, 采用与神经网络方法相结合的方法, 既能够使用大量样本学习各类目标的特征分布来进行识别, 又避免了模板匹配方法的大计算量问题。文中采用改进的 BP 网络算法来完善 HRRP 目标识别, 实验证明是可行的。

**关键词:** 高分辨距离像 目标识别 神经网络 激励函数

## 0 引言

常规雷达通常工作在军事目标的光学区, 而光学区目标散射场可以模型化为离散的多个散射中心回波之和[1-3]。雷达利用发射宽带信号可获得高分辨一维距离像(HRRP), 一维距离像具有径向分辨率高、相对于雷达目标二维成像获取与处理相对简单的优点, 使其成为当前国内外雷达目标识别领域研究的热点[4]。但是基于一维距离像的特征提取也存在其难点: HRRP 具有平移敏感性、姿态敏感性和幅度敏感性。一般而言, 提取具有平移和尺度不变性的中心矩特征可以克服平移敏感性和幅度敏感性, 且能反映目标的形状信息; 而针对目标的姿态敏感性问题, 理论上要利用足够大的方位和俯仰角域内的 HRRP 来建立模板库, 以求较完全地表征目标, 但这样直接带来的问题就是目标数据库的存贮量和匹配运算量会很大[5-6]。而神经网络方法能够使用大量样本学习各类目标的特征分布来进行识别, 避免了模板匹配方法的大计算量问题。但 BP 网络也存在明显的缺点, 就是其收敛速度慢; 存在已陷入“局部最小”问题。为此在传统的 BP 神经网络基础上对其进行改进, 用来完善 HRRP 目标识别是一种可行的新方法。

## 1 神经网络算法改进

### 1.1 BP 神经网络简介

BP (Back Propagation) 网络是误差反向传播神经网络的简称, 在 1986 年由 Rumelhart 和 McClelland 为首的科学家小组提出的, 是一种按误差逆传播算法训练的多层前馈网络。它能学习和存贮大量的输入-输出模式映射关系, 而无需事前揭示描述这种映射关系的数学方程。其学习规则是使用最速下降法, 通过反向传播来不断调整网络的权值和阈值, 使网络的误差平方和最小。BP 神经网络模型拓扑结构包括输入层(input)、隐层(hidden layer)和输出层(output layer), 如下图所示。




图 2-1 BP 神经网络模型

BP 网络实质上实现了一个从输入到输出的映射功能, 而数学理论已证明它具有实现任何复杂非线性映射的功能, 这使得它特别适合于求解内部机制复杂的问题。同时, BP 网络还具有自学习能力, 具有一定的推广、概括能力。但是也存在一些问题, 比如: 算法的学习速度很慢; 网络训练失败的可能性较大; 难以解决应用问题的实例规模和网络规模间的矛盾, 而这涉及到学习复杂性问题等问题。因此, 有必要研究更好的方法完善这种算法, 用于雷达目标识别。

## 1.2 算法改进

虽然传统 BP 算法具有诸多优点,但其最大的问题是网络训练时间长,有时甚至会不能训练,因此必须改进。而神经网络研究源于物理学、心理学和神经生理学的跨学科研究,这里就沿用生物的学习过程来完善算法,也就是说学习过程除了调整各神经元细胞间连接强度外,其本身的输入输出关系也是在不断的变化的,基于这种思想完善传统算法。

### 1.2.1 激励函数分析

为了便于分析,在此假设 BP 神经网络为三层,其中网络节点分别表示为输入节点  $x_j$ , 隐节点  $y_i$ , 输出节点  $O_l$ 。输入节点与隐节点间的网络权值为  $v_{ij}$ , 隐节点与输出节点的网络权值为  $\omega_{li}$ , 学习步长为  $\eta$ , 则 BP 模型的计算公式如下:

(1) 隐节点的输出为  $y_i = f(\sum_j v_{ij}x_j - \theta_i) = f(net_i)$ , 其中  $\theta_i$  为隐节点神经元的阈值,  $net_i$  为隐节点神经元的输入总和。

(2) 输出节点的输出为  $O_l = f(\sum_i \omega_{li}y_i - \theta_l) = f(net_l)$ , 其中  $\theta_l$  为输出节点神经元的阈值,  $net_l$  为输出节点神经元的输入总和。

(3) 输出节点的误差为  $E = \frac{1}{2} \sum_l (t_l - O_l)^2$ , 其中  $t_l$  为输出节点的期望输出。

(4) 隐层至输出层权值调整为:

$$\frac{\partial E}{\partial \omega_{li}} = \sum_{k=1}^N \frac{\partial E}{\partial O_k} \cdot \frac{\partial O_k}{\partial \omega_{li}} = \frac{\partial E}{\partial O_l} \frac{\partial O_l}{\partial \omega_{li}} \quad (2-1)$$

因为 E 是多个  $O_k$  的函数,且只有一个  $O_l$  与  $\omega_{li}$  有关,同时各  $O_k$  之间相互独立,由此可得:

$$\frac{\partial E}{\partial O_l} = \frac{1}{2} \sum_k -2(t_k - O_k) \cdot \frac{\partial O_k}{\partial O_l} = -(t_l - O_l) \quad (2-2)$$

$$\frac{\partial O_l}{\partial \omega_{li}} = \frac{\partial O_l}{\partial net_l} \cdot \frac{\partial net_l}{\partial \omega_{li}} = f'(net_l) \cdot y_i \quad (2-3)$$

利用(2-2)式和(2-3)式可以将(2-1)式化简为:

$$\frac{\partial E}{\partial \omega_{li}} = -(t_l - O_l) \cdot f'(net_l) \cdot y_i \quad (2-4)$$

如果输出层是 purelin 型神经元,那么  $f'(net_l) = 1$ , 则  $\frac{\partial E}{\partial \omega_{li}} = -(t_l - O_l) \cdot y_i$ , 可以得到调整后的权值为:

$$\omega_{li} = \omega_{li} + \eta \frac{\partial E}{\partial \omega_{li}} \quad (2-5)$$

(5) 输入层至隐层的权值调整

$$\frac{\partial E}{\partial v_{ij}} = \sum_l \sum_i \frac{\partial E}{\partial O_l} \frac{\partial O_l}{\partial y_i} \frac{\partial y_i}{\partial v_{ij}} \quad (2-6)$$

同理，因为  $E$  是多个  $O_l$  函数，又因为针对某一个  $v_{ij}$  只对应一个  $y_i$ ，且与所有的  $O_l$  都有关(上式只对 1 求和)。由此可以得到：

$$\frac{\partial E}{\partial O_l} = \frac{1}{2} \sum_k -2(t_k - O_k) \cdot \frac{\partial O_k}{\partial O_l} = -(t_l - O_l) \quad (2-7)$$

$$\frac{\partial O_l}{\partial y_i} = \frac{\partial O_l}{\partial net_l} \cdot \frac{\partial net_l}{\partial y_i} = f'(net_l) \cdot \frac{\partial net_l}{\partial y_i} = f'(net_l) \cdot \omega_{li} \quad (2-8)$$

$$\frac{\partial y_i}{\partial v_{ij}} = \frac{\partial y_i}{\partial net_i} \cdot \frac{\partial net_i}{\partial v_{ij}} = f'(net_i) \cdot x_j \quad (2-9)$$

利用 (2-7)~(2-9) 式可以将(2-6)式化简为：

$$\begin{aligned} \frac{\partial E}{\partial v_{ij}} &= -\sum_l (t_l - O_l) f'(net_l) \cdot \omega_{li} \cdot f'(net_i) \cdot x_j \\ &= -\sum_l \sigma_l f'(net_i) \cdot \omega_{li} \cdot x_j \end{aligned} \quad (2-10)$$

从而得到调整后的权值为

$$\omega_{ij} = \omega_{ij} + \eta \frac{\partial E}{\partial \omega_{ij}} \quad (2-11)$$

从上面的公式可以看出：

(1)在保证收敛的前提下，由(2-11)式可知权值调整的幅度越大，则梯度的变化也越大，学习速度也越快。

由(2-4)式可知梯度的变化  $\frac{\partial E}{\partial \omega_{li}}$  与激励函数的导数  $f'(net_l)$  成正比。可见，激励函数的导数在学习过程中大量使用，因此对整个网络的学习过程将有非常大的影响。

(2)由于 S 型的激励函数都存在饱和区，当神经元的输出落入激励函数的饱和区时，激励函数的导数值都很小，所以每次学习周期只能对权值作较小修正，输出单元会在一段时间工作在平坦区中，相当于整个调节过程几乎停顿下来，减慢了网络的收敛速度。因此，需要对权值作较大的修正才可能尽快使处理单元逃出饱和区。

### 1.2.2 改进方法

改进激励函数，可以改变误差曲面，尽量减少局部极小值的可能性。原则上可以采用任何一种非线性函数，但对于反转学习算法，要求用连续可微的非线性函数。本文选取  $\text{tansig}$  函数作为隐层节点激励函数的基本形式，即：

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2-12)$$

改进的 BP 算法是对标准的 S 型函数引入新的参数  $\theta_0$ 、 $\theta_1$ ，则函数变为：

$$f(x) = \frac{1}{1 + \exp[-(x + \theta_0) / \theta_1]} \quad (2-13)$$

其中  $\theta_0$ 、 $\theta_1$  为激励函数中的可调参数。参数  $\theta_1$  用于改变激励函数的斜率，

较小的  $\theta_1$  使 sigmoid 函数逼近一个阶跃限幅函数，而较大的  $\theta_1$  将使 sigmoid 函数变得较为平坦。参数  $\theta_0$  的作用使得激励函数沿水平方向左右移动，正的  $\theta_0$  使激励函数水平向左移动。两个参数的引入使得激励函数对于输入  $x$  而言可以自由进行伸缩。下图是参数  $\theta_0$ 、 $\theta_1$  对激励函数的调节。

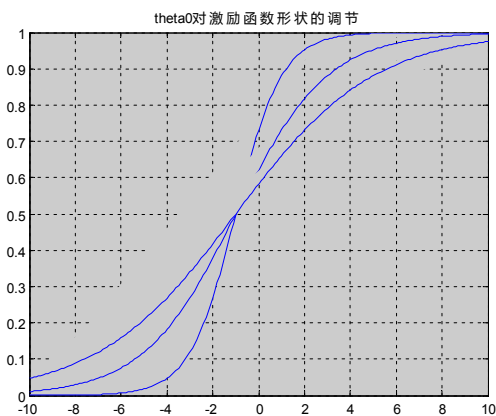


图 2-3  $\theta_0$  对激励函数的调节




图 2-4  $\theta_1$  对激励函数的调节

实际上，式 (2-13) 所表示的非线性函数满足如下两个条件：一是连续光滑且具有单调性；二是定义域为  $(-\infty, +\infty)$ ，值域为  $(0, 1)$ ，故符合激励函数要求。而且它使得激励函数曲线变得平坦，方便在  $y_j \approx 0$  或  $1 - y_j \approx 0$  时避开局部极小，因此该函数具有更好的函数逼近能力以及容错能力。

## 2 基于改进算法的雷达目标识别

### 2.1 仿真数据

基于多散射点模型，本文采用四种形状的目标作为测试目标，分别为“|”字型目标、“V”字型目标、“干”字型目标和“小”字型目标。图 3-1 示意了该四种目标的形状。“|”字型目标散射点数为 5，“V”字型和“小”字型目标的散射点数为 7，“干”字型目标的散射点数为 8。实验中雷达发射信号带宽为 150MHz，则其距离分辨率为 1m。数据为四类仿真目标“|”、“V”、“干”和“小”在姿态角范围为  $0^\circ$ - $180^\circ$  的高分辨率距离像，将奇姿态角样本作为学习样本，偶姿态角样本作为测试样本，由此得到训练样本集  $M$  和测试样本集  $X$ 。




图 3-1 “|”字型、“V”字型、“干”字型和“小”字型目标

### 2.2 仿真实验及结果分析

选择 BP 神经网络为分类器，设计的 BP 网络为单隐含层的三层网络。

### 2.2.1 基于 BP 算法进行雷达目标识别

在输出层分别以 (10,01) 表示两类目标, 所以输出层的节点数为 2。在隐含层神经元传递函数为正切函数 tan-sigmoid 函数, 而输出层神经元传递函数为对数函数 log-sigmoid 函数; 设置网络的收敛条件实际输出对目标输出的均方误差  $MSE \leq 0.001$ , 学习率  $a=0.95$ , 步长  $\eta=0.1$ , 网络权值和阈值的初始值为一组较小的随机数, 训练网络选用的算法是 L-M 算法。测试网络的分类性能, 然后用训练好的网络对测试样本集分类。先分别对样本进行特征提取后再进行实验。对两个、三个仿真目标在不同姿态角范围内的样本进行识别, 样本的信噪比为 20db。

表 3-1 所示为 100 次仿真实验结果的平均。

目标	正确识别率		
	0o-30o	0o-60o	0o-90o
“1” “V”	1	1	0.9872
“1” “干”	0.9865	0.9756	0.9651
“1” “小”	0.9854	0.9743	0.9624
“V” “干”	0.9732	0.9658	0.9537
“V” “小”	0.9718	0.9637	0.9541
“干” “小”	0.9621	0.9516	0.9422
平均识别率	0.9798	0.9718	0.9607

### 2.2.2 基于改进方法的 BP 算法雷达目标识别

对激励函数的参数  $\theta_0$ 、 $\theta_1$  经过多次试验, 利用梯度下降法的原理找到最优参数值  $\theta_0=2$ 、 $\theta_1=1.5$ 。这样, 就构造了改进的 BP 神经网络模型, 利用此模型对不同姿态范围内的 HRRP 进行识别, 试验结果如表 3-2 所示。

表 3-2 基于 BP 算法对两类目标的识别结果

目标	正确识别率		
	0o-30o	0o-60o	0o-90o
“1” “V”	1	1	0.9901
“1” “干”	1	0.9869	0.9831
“1” “小”	0.9886	0.9813	0.9807
“V” “干”	0.9752	0.9781	0.9624
“V” “小”	0.9752	0.9764	0.9631
“干” “小”	0.9613	0.9608	0.9500
平均识别率	0.9834	0.9805	0.9716

对比表 3-1、3-2 中数据, 可见在相同的姿态角范围内, 改进后的 BP 网络的平均识别率比标准 BP 网络识别的平均识别率高出 1%~2%。

图 3-2 和图 3-3 分别为在同组样本下, 共同采用基于平移不变 KPCA 特征提取方法、相同的模型参数和样本噪声, 标准 BP 神经网络和改进 BP 神经网络对两类目标的识别误差曲线图。由误差曲线图可以看出: 经过改进的 BP 神经网络对误差的收敛速度明显高于标准的 BP 神经网络误差的收敛速度。

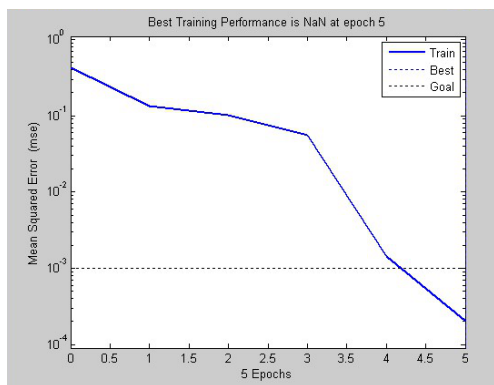


图 3-2 BP 算法目标识别误差曲线图




图 3-3 改进 BP 算法目标识别误差曲线图

### 3 结论

文中分析了利用修正的 BP 神经网络算法完善雷达目标识别的方法。这种 BP 网络修正方法，克服了传统 BP 算法收敛速度慢；存在已陷入“局部最小”问题。这种方法能够使用大量样本学习各类目标的特征分布来进行识别，避免了模板匹配方法的大计算量问题。实验证明，这种方法是一种可行的 HRRP 目标识别方法。

#### 参考文献

- [1] HUDSON S, PSALTIS D. Correlation filters for aircraft identification from radar range profile [J]. IEEE Trans of AES, 1993, 29 (3): 741-746.
- [2] KM K T, SEO D K, KM H T. Radar target identification using one-dimensional scattering centers [J]. IEE Proceedings Radar, Sonar Navigation, 2001, 148 (5): 285-296.
- [3] JACOBS S P, OSOLL IVAN J A. Automatic target recognition using sequences of high resolution radar profiles [J]. IEEE Trans of AES, 2000, 36 (2): 364-380.
- [4] 付耀文, 贾宇平, 庄钊文. 基于一维散射中心匹配的雷达目标识别 [J]. 电子学报, 2006, 34 (3): 404-408.
- [5] LI H J, WANG Y D, WANG L H. Matching score properties between range profiles of high resolution radar targets [J]. IEEE Transactions on Antennas and Propagation, 1996, 44 (4): 444-452.
- [6] 郭桂蓉, 庄钊文, 陈曾平. 电磁特征抽取与目标识别 [M]. 长沙: 国防科技大学出版社, 1996.
- [7] 陈伟涛, 杨沛, 刘朝阳, 盛思佳. BP 神经网络在雷达目标识别中的应用 [J]. 电子科技, 2010, 12: 18-19.
- [8] 朱玉鹏, 袁琼清, 王芹, 付耀文, 王宏强. 基于小波变换和多神经网络融合的雷达一维距离像目标识别 [J]. 电光与控制, 2009, 16(1): 34-38.
- [9] 张立明. 人工神经网络的模型及应用 [M]. 上海: 复旦大学出版社, 1993.