

# 复合基神经网络在水声目标分类识别中的应用

方世良 陆佶人

(东南大学无线电工程系, 南京 · 210018)

本文根据不同神经网络的分类特点, 提出将径向基函数网络和多层感知器网络复合构成复合基网络, 用于水声信号的分类识别。试验表明, 该网络的分类能力及对未训练目标的适应性优于 BP 网和 RBF 网。

关键词: 目标分类, 水声, 神经网络, 基函数

## The application of a combined basis neural network in the underwater acoustic target classification and recognition

FANG Shiliang LU Jiren

(Department of Radio Engineering, Southeast University, Nanjing · 210018)

In this paper, a combined basis neural network is proposed for underwater acoustic target classification. It is composed of radial basis functions and multi-layer perceptrons whose characteristics on the classification are different. It has been demonstrated by the recognition experiment that the network has higher correct recognition rate and better adaptability to untrained targets than BP or RBF network.

**Key words:** target classification, underwater acoustic, neural network, basis function

### 1 引言

近年来, 神经网络在水声目标分类识别中已得到了广泛的应用, 其非线性划分能力、自适应训练及高度并行性等优良性能为特征复杂的水声目标分类识别提供了好的手段。其中用得较为普遍的分类网络有误差反向传播训练的多层感知器网络(简称 BP 网络)、径向基函数(RBF)网络及  $\Sigma$  网络等, 不同的网络模型在识别性能方面各有特点。

BP 网分类器为超平面分类器, 其复杂的分类区域由神经元形成的超平面判决边界所

组成, 在合适的隐层设置下, 可完成任意复杂特征分布的目标分类, 识别率高。其缺点是训练时间长、学习算法不能保证学习的结果达到均方误差的全局极小、训练结果容易受不正确训练样本的错误引导, 这些缺点在水声目标分类中较为突出。其主要原因有: (1) 舰船目标辐射噪声特征维数高, 增加了训练的复杂性; (2) 实际工作中很难获得舰船辐射噪声信号的标准训练样本集, 一般只是在一定噪声下的有噪样本, 从函数逼近的角度看, 因为 BP 网络对此训练样本集有极强的匹配能力, 因而由此得到的网络并不是一个最佳网

\* 第一作者: 方世良, 男, 1960 年 8 月生, 副教授

收稿日期: 97-4-3; 修回日期: 97-10-16

络,它对于无噪样本本身或其它有噪样本必然存在偏差,从而影响了泛化分类性能。

RBF 网分类器为核分类器的一种,其核函数节点形成一系列部分覆盖的接收区,由它们构成复杂的决策域。其特点是学习速度快,群分类性能好。核函数的训练常用 K-均值聚类算法,当不同模式的样本信号在特征空间中能形成相应的独立区域时,该方法能给出好的结果。但实际应用时这一条件很难满足,舰船目标辐射噪声特征复杂,不同目标间常有较多的共性特征,而同类目标的信号特征又有很大的随机变化,因此识别率受到一定的限制。

兼顾 BP 网和 RBF 网的各自特点,本文将两种网络有机地结合在一起,构成多层复合神经网络,取长补短,使设计的网络一方面对舰船目标辐射噪声信号具有 BP 网的超平面判决能力,另一方面则利用 RBF 网的良好群分类能力改善泛化性,减小非标准训练样本集的错误引导影响,以提高整体分类性能。因 BP 网的神经元输出基函数为 S 型函数,RBF 网的基函数为径向对称的高斯函数,所以本文称其为复合基神经网络。经对收集的大量舰船辐射噪声信号的识别试验表明,该网络具有较好的综合分类识别性能。

## 2 复合基神经网络分类器的结构和训练

复合基神经网络的结构由 3 层前馈网组成,如图 1 所示,第 1、2 层为隐层,第 3 层为输出层。

第 1 隐层的输入为训练样本的特征数据,隐节点的基函数是高斯型核函数,

$$u(j) = \exp\left[-\frac{\bar{x} - \bar{w}_{1,j}}{1/(2\sigma_j^2)}\right] \quad (1)$$

$j = 1, 2, \dots, N_1$

式中  $u(j)$  是第  $j$  个隐节点的输出,  $\bar{x}$  是输入样本矢量,  $\bar{w}_{1,j}$  是输入层到隐层第  $j$  个节点的权矢量,也即第  $j$  个节点的高斯核函数中心,

$\sigma_j^2$  是第  $j$  个节点的核函数宽度,  $N_1$  是隐节点数,  $\bar{x} - \bar{w}_{1,j}$  为输入样本与核函数中心的距离,常用 Euclidean 距离,

$$\bar{x} - \bar{w}_{1,j} = \frac{1}{N} \sum_{i=1}^N x(i) - w_{1,j}(i) \quad (2)$$

$N$  为输入样本的数据长度。隐节点的输出动态范围从 0 到 1,输入越接近核函数中心,输出越接近 1,高斯核函数径向对称。




图 1 复合神经网络结构

第 2 隐层节点  $k$  的输出为

$$v(k) = F\left[\sum_{j=1}^{N_1} W_{2,k}(j) u(j)\right] \quad (3)$$

$k = 1, 2, \dots, N_2$

$W_{2,k}(j)$  是连接第 1 层第  $j$  个隐节点到第 2 层第  $k$  个隐节点的权值,  $N_2$  为第 2 层隐节点数,  $F(\cdot)$  为第 2 层节点的基函数,为 S 型函数,

$$F(Y) = 1/(1 + e^{-Y}) \quad (4)$$

输出层节点  $m$  的计算公式如下:

$$y(m) = F\left[\sum_{k=1}^{N_2} W_{3,m}(k) v(k)\right] \quad (5)$$

$m = 1, 2, \dots, N_3$

式中  $y(m)$  为输出层第  $m$  个节点的输出值,  $W_{3,m}(k)$  是连接第 3 层第  $k$  个隐节点到第  $m$  个输出节点的权值,  $N_3$  为输出节点数。

第 1 隐层核函数的中心  $\bar{w}_{1,j}$  和宽度  $\sigma_j^2$  由 K-均值算法训练所得:

(1) 设置第 1 层隐节点数  $N_1$  和隐层初始权值,

$$W_{1,j}(n) = x_j(n) \quad j = 1, 2, \dots, N_1 \quad (6)$$

(2) 输入新训练样本  $x\bar{x}$ , 计算新样本与各隐节点中心的 Euclidean 距离  $d_j$ , 并找出

最小距离  $d$  及对应节点  $q$ :

$$d = d_q = \min(d_j) \quad (7)$$

(3) 将此样本合并到最小距离对应的节点, 同时修正该节点的连接权值,

$$W_{1,q}(n) = \frac{1}{m_{q x_i q}} x_i(n) \quad (8)$$

$$n = 1, 2, \dots, N$$

$m_q$  为归入第  $q$  个节点的训练样本数。返回第 2 步, 直到所有的训练样本全部输入完。

(4) 计算误差平方和损失函数,

$$J = \sum_{j=1}^{N_1} \sum_{i=1}^N [x_i(n) - W_{1,j}(n)]^2 \quad (9)$$

若  $J$  已收敛, 则终止训练, 否则, 返回第 2 步继续训练。

(5) 计算核函数半径

$$\sigma_j^2 = \frac{1}{m_{i x_i j n=1}} [x_i(n) - W_{1,j}(n)]^2 \quad (10)$$

$$j = 1, 2, \dots, N_1$$

后两层网络的连接权值通过 BP 算法训练获得:

(1) 初始化后两层网络的连接权  $W_{2,k}(j)$  和  $W_{3,m}(k)$  为随机数;

(2) 提供训练对  $(\bar{x}, \bar{d})$ , 并由 (1) 式计算第 1 隐层输出  $u(j)$ ;

(3) 由 (3) ~ (5) 式计算第 2 隐层和输出层的输出  $v(k)$  和  $y(m)$ ;

(4) 计算输出误差修正值,

$$e(m) = F[y(m)][d(m) - y(m)]$$

$$= y(m)[1 - y(m)][d(m) - y(m)]$$

$$m = 1, 2, \dots, N_3 \quad (11)$$

(5) 修正输出层权值,

$$W_{3,m}^{s+1}(k) = W_{3,m}^s(k) + \alpha(s)e(m)v(k)$$

$$k = 1, 2, \dots, N_2 \quad m = 1, 2, \dots, N_3 \quad (12)$$

其中,  $\alpha(s)$  为随迭代次数  $s$  增加而逐渐减小的修正步长;

(6) 计算第 2 隐层输出误差修正值:

$$e(k) = F[v(k)] \sum_{m=1}^{N_3} e(m)W_{3,m}(k)$$

$$k = 1, 2, \dots, N_2 \quad (13)$$

(7) 修正第 2 隐层权值:

$$W_{2,k}^{s+1}(j) = W_{2,k}^s(j) + \alpha(s)e(k)u(j)$$

$$j = 1, 2, \dots, N_1 \quad k = 1, 2, \dots, N_2 \quad (14)$$

(8) 返回(2)循环, 直至网络收敛。

### 3 试验结果

为了验证网络的分类识别性能, 本文对实测的 34 个海上舰船或鱼雷目标、79 个航次或工况的辐射噪声信号共 1747 个采样数据文件(每个文件 16384 点数据)进行了识别试验。根据目标属性, 把信号分成 3 大类别, 数据文件经数据预处理后转换成 250 维的特征样本, 选取其中 29 种工况中的 245 个特征样本组成训练样本集。双基网络的第 1 隐层有 100 个隐节点, 第 2 隐层 50 个隐节点, 输出节点为 3 个, 采用编码方式输出, 识别结果如表 1。为了便于比较, 表中同时列出了 BP 网络和 RBF 网络的测试结果, 两种网络均为 2 层前馈网络, 隐层节点同为 100 个, 输出节点为 3 个, 采用编码方式输出。表中综合识别率为训练目标及未训练目标的正确识别样本数之和与两部分样本总数之和的比。

表 1 识别试验结果统计表

识别方法	训练目标识别试验结果			未训练目标识别试验结果			综合识别率
	样本总数	识别数	识别率	样本总数	识别数	识别率	
双基网	631	618	97.9%	1116	902	80.8%	87.0%
BP 网	631	620	98.3%	1116	831	74.5%	83.0%
RBF 网	631	593	94.0%	1116	858	76.9%	83.1%

### 4 性能分析

表 1 结果表明, 对部分样本参加训练的目标, 该网络有与 BP 网相近的识别率, RBF 网最低。对未训练目标, 该网络的识别效果则比单纯的 BP 网有明显的改善, 亦好于 RBF 网, 其综合识别率为最高。事实上, 由于在 BP 网的前级加入了径向基函数运算, 使网络的输入特征维数得到了较大的压缩, 简化了判

(下转 62 页)

冲多普勒信号的频谱宽度. 复旦学报(自然科学版), 1996; 35: 545 ~ 550

3 Wang YY, Fish PJ. Correction for nonstationary and window broadening in Doppler spectrum estimation. IEEE signal processing letters. 1994; 4: 18 ~ 20

4 Ruano MG, Fish PJ. Cost/benefit criterion for selection of pulsed Doppler ultrasound spectral mean frequency and bandwidth estimators. IEEE trans. BME, 1993; 40: 1338 ~ 1341

5 汪源源, 王威琪. 自适应谱线增强技术提取

噪声中弱超声多普勒血流信号及其频谱. 复旦学报(自然科学版), 1994; 33: 33 ~ 40

6 Wang YY, Fish PJ. Comparison of Doppler signal analysis techniques for velocity waveform, turbulence and vortex measurement: a simulation study. Ultrasound Med. Biol., 1996; 22: 635 ~ 649

7 Guo ZY, Durand LG, Lee HC. The time-frequency distributions of nonstationary signals based on a Bessel kernel. IEEE trans. signal processing, 1994; 42: 1700 ~ 1707

---

(上接第 56 页)

决边界的学习。另外, 径向基函数良好的群聚能力则改善 BP 网络的泛化能力。相反, 由于水声目标辐射噪声类间特征重叠严重, 适用于群聚特征的单纯径向基函数网络容易产生类间模糊, 也难取得好的识别效果, BP 网络的细化划分正好弥补了这一缺陷。因径向基网络学习速度很快, 第 1 层网络的训练只需较少的时间, 而维数的降低则使后面 BP 网络的训练大大简化, 因此, 该网络在训练速度上也比 BP 网络有了较大的提高。为了进一步减少训练时间, 后级的 BP 网络还可采用改进的卡尔曼快速算法进行训练。

#### 参考文献

1 Richard P. Lippmann. Pattern classification

using neural networks. IEEE Communications Magazine, 1989; Nov: 47 ~ 64

2 郑君里, 杨行峻. 人工神经网络. 高等教育出版社, 1992: 26 ~ 89

3 M. T. Musavi, W. Ahmed, K. H. Chan, K. B. Farris, D. M. Hummels. On the training of radial basis function classifiers. Neural Networks, 1992; 5: 595 ~ 603

4 Jang, J. S. R & Sun, C. T. Functional equivalence between radial basis function networks and fuzzy inference systems. IEEE Transactions on Neural Networks, 1993; 4(1): 156 ~ 158

5 Heggere S. R., Derek E. K. & S. Richard F. Sims. Self partitioning neural networks for target recognition. Neural Networks. 1995; 8: 1475 ~ 1486