

用天气雷达回波资料作临近预报的 BP 网络方法

陈家慧, 张培昌

(南京气象学院 电子信息与应用物理系, 江苏 南京 210044)

摘要: 讨论了利用 BP 模型进行临近预报的方法, 并与傅立叶描绘子法作了比较, 从而说明人工神经网络方法用于临近预报是可行的。

关键词: 神经网络; BP 模型; 临近预报

中图分类号: P407.8 **文献标识码:** A

人工神经网络(Artificial Neural Network, 简记为 ANN), 简称神经网络, 是由大量称为神经元的简单信息单元广泛连接组成的复杂网络, 靠神经元对外部输入信息的动态响应来处理信息。目前, 国内外开展的人工神经网络在气象学科中的应用研究, 主要集中于预报方面。根据雷达回波的特点, 利用雷达资料作临近预报的人工神经网络方法是这方面的一个新尝试。

人工神经网络有多种模型, 应用最广泛的模型之一就是 BP(back propagation, 前馈多层网络)模型。本文详细讨论了利用 BP 模型进行临近预报的人工神经网络方法。

1 神经网络学习样本的获取

采用 1995 年 6 月 9 日厦门雷达站 9 个时刻混合型降水回波体扫资料, 方位角间隔是 1° ; 时间间隔基本上为 0.5 h, 分别是北京时间 0: 35、1: 05、1: 33、2: 05、2: 35、3: 06、3: 36、4: 05 和 4: 37 时。根据需要读取适当层次上的雷达反射率因子 Z 或速度资料, 用双线性内插法将资料从极坐标转换到直角坐标。再经过滤波、分割, 提取 6 个回波块的特征分量, 即圆形度 F_1 、细长度 F_2 、散射度 F_3 及凹度 F_4 等 4 个傅立叶描绘子^[1]及几何中心的坐标 x 、 y 。然后, 进行回波匹配。若某两时刻的回波块恰成匹配对, 则把 t_1 时刻回波块的 4 个傅立叶描绘子的值及几何中心坐标和 t_2 时刻回波块的几何中心坐标作为样本输入到数据文件, 用于神经网络学习。

2 神经网络的学习^[2~4]

2.1 模型的选择

考虑到所用样本包含了期望输出值, 故选择能够进行有导师学习的 BP 模型。BP 模型的训练速度较慢, 但它分类精度高, 自适应性高, 实现目标容易, 推广能力较好。

BP 模型是神经网络的重要模型之一。BP 模型所使用的 BP 算法(误差反传训练算法)是一种很有效的训练算法, 其核心就是把一组样本的 I/O 问题变为一个非线性优化问题, 使用优化中最普通的梯度下降法, 用迭代运算求解权值相应于学习记忆问题, 加入隐结点使优化问

题的可调参数增加,从而得到更精确的解。

BP 模型由分为不同层次的结点组成(图 1),每一层的结点输出送到下一层结点,输出值由于连接权值不同而被放大、衰减或抑制。除了输入层外,每一结点的输入为前一层所有结点输出值的加权和。每一个结点的激励输出值由结点输入、激励函数及偏置量决定。

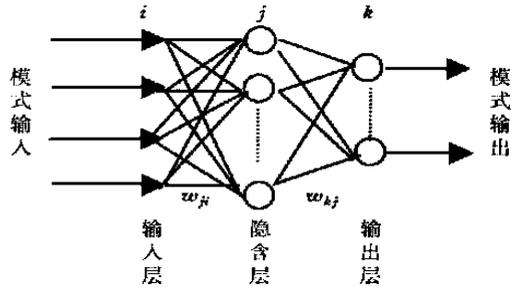


图 1 前馈多层网络

Fig. 1 Back propagation network

设激励函数(S 型压缩函数)为

$$o_j = \frac{1}{1 + \exp[-(\sum_j w_{ji}o_i + j)]} \quad (1)$$

如果我们将偏置值 j 看作与某个输出值恒定为 1 的结点相连的“连接”权值, j 就可以与其他连接权值一样来计算。对输出层与隐含层结点推广的规则分别由以下两式表示,

$$p_k = (t_{pk} - o_{pk}) o_{pk} (1 - o_{pk}); \quad (2)$$

$$p_j = o_{pj} (1 - o_{pj}) \sum_k p_k w_{kj} \quad (3)$$

可见,中间层结点的 p_j 可由它上面一层的 p_k 算出。因此,为了使误差函数最小,总是从输出层开始修正权值,即由(2)式算出所有的 p_k ,然后修正前层权值,使误差逐渐向下“传播”;即由(3)式算出下面各层次结点的 p_j 。从这一层意思讲,有反传的含义。

2.2 模型的设计

接收输入的类型为连续性的,选取转移函数为 S 型压缩函数。受转移函数的限制,输入向量的值为区间 $[-1, +1]$ 内的连续数值。输入信号的组合方式就是输入的加权和。

Lippman 认为,不需要更复杂的网络,即使在模式空间中,各样本分布在互相犬牙交错的复杂区域内,一般只需 4 层网络就能构成所需要的任意复杂的判别函数(输入层作第一层)。而对于分类和判决边界问题(包括二进制输入输出的逻辑和判决界),一个隐含层就足够了^[2]。因此,我们先后选择了 3 层和 4 层的 BP 模型,进行学习与训练。

输入层的结点数为 6,分别为 t_1 时刻回波块的几何中心坐标及 4 个傅立叶描绘子。经过反复试验,若选择 3 层的 BP 模型,我们选择隐含层结点数为 10;若选择 4 层的 BP 模型,则选择第一隐含层结点数为 6,第二隐含层结点数为 3。输出结点数为 2,输出数据是连续性的,分别代表 t_2 时刻回波块几何中心的坐标(由 t_1 时刻外推所得)。网络的连接采用前馈连接,从灵活性出发,层间实行全连接。

在 BP 模型的学习与训练中,首先要选定训练样本和检验样本。所谓训练样本就是用以训练网络,从而使网络逐渐达到稳定的实际输入样本。而检验样本则是当网络训练结束后的新的输入,用以检验网络训练的效果。网络经训练达到稳定后,对训练样本具有一定的识别能力,称之为网络的记忆功能;而对检验样本作出相应的输出反映,称之为网络的联想功能,也就是临近预报中的预报结果。

若选择 2 层的 BP 模型,我们可以设 $X_i (i= 1, 2, \dots, 6)$ 为训练样本的输入, Y_{sk} 为其期望输出,实际输出为 $Y_k (k= 1, 2)$ 。令 w_{ji} 表示从输入层结点 i 到隐含层结点 j 的连接加权, w_{kj} 表示从隐含层结点 j 到输出层结点 k 的连接加权。再令 θ_j, R_k 分别为隐含层单元、输出层单元的阈值。BP 算法的实现步骤详见文献[2]。

2.3 模型的检验

用户可以根据需要随机选取一个样本作为全部训练样本的开始,再选取一个样本作为训练样本的结束,同时通过交互方式确定训练速率系数 g 的大小。在检验过程中,我们选定训练样本数为50。先后选择第0至第50个样本,第10至第60个样本,第20至第70个样本,第30至第80个样本作为训练样本,其余的为检验样本,经过120 000次迭代,用BP算法训练网络。另外,又采用了BP算法的几种改进和变形算法^[2],以加快训练速度,避免陷入局部最小。

第一种方法是改进误差函数,使输出层的误差函数 δ_j^k 变为

$$\delta_j^k = [F(s) + 0.1](T_j^k - y_j^k), \quad (4)$$

从而一方面恢复了 $F(s)$ 的某些影响,另一方面使 δ_j^k 在 s 变大时能够保持不等于0。

第二种方法是双极性S型压缩函数法,它采用双极性S型压缩函数作为激励函数,即

$$F(s) = -\frac{1}{2} + \frac{1}{1 + \exp(-s)}, \quad (5)$$

以减少收敛时间。那么,我们可将输入向量的范围变为 $[-1/2, +1/2]$,从而使输出结点的范围在 $[-1/2, +1/2]$ 。

第三种方法是附加冲量项,也就是为每个加权调节量 $w(n+1)$ 加上一项正比于前次加权变化量 $w(n)$ 的项。加权调节公式为

$$w_{pq}(n+1) = qy_p + b w_{pq}(n). \quad (6)$$

其中, b 为冲量系数,起缓冲平滑的作用。

在模型的检验过程中,我们分别对采用BP算法及其改进算法的3层BP模型进行了检验(表1),可以看出BP模型具有良好的记忆能力,能够对训练样本进行较准确的识别。并能够对从未见过的样本进行联想回忆,联想精确度基本令人满意。

对采用BP算法的3层BP模型和4层BP模型进行检验的结果见表2。

表1 3层BP模型的检验结果

Table 1 The test results from the three layer BP network

| 训练算法 | | 训练样本 | | | | 检验平均值 |
|-----------|-------|--------|--------|--------|--------|--------|
| | | 0~50 | 10~60 | 20~70 | 30~80 | |
| BP 算法 | g | 0.995 | 0.995 | 0.995 | 0.200 | |
| | 记忆(%) | 78.000 | 75.000 | 80.000 | 81.000 | 78.500 |
| | 联想(%) | 73.684 | 73.684 | 71.053 | 63.158 | 70.395 |
| 改进误差函数 | g | 0.900 | 0.825 | 0.925 | 0.950 | |
| | 记忆(%) | 81.000 | 77.000 | 81.000 | 85.000 | 81.000 |
| | 联想(%) | 75.000 | 73.684 | 72.368 | 60.526 | 70.395 |
| 双极性S型压缩函数 | g | 0.995 | 0.850 | 0.900 | 0.200 | |
| | 记忆(%) | 78.000 | 78.000 | 81.000 | 82.000 | 79.750 |
| | 联想(%) | 69.737 | 77.632 | 75.000 | 64.474 | 71.711 |
| 附加冲量项 | g | 0.900 | 0.800 | 0.900 | 0.850 | |
| | b | 0.800 | 0.850 | 0.850 | 0.850 | |
| | 记忆(%) | 79.000 | 75.000 | 81.000 | 87.000 | 80.500 |
| | 联想(%) | 65.790 | 68.421 | 68.421 | 71.053 | 68.421 |

通过对用 BP 算法及其改进和变形方法训练出的各 BP 模型的测试, 可以看到, BP 模型具有良好的记忆能力, 能够对训练样本进行较准确的回忆, 并能够对从未见过的检验样本进行联想回忆, 联想精确度基本令人满意。网络得到了完全训练, 可应用于实际业务工作。

4 层 BP 模型比 3 层 BP 模型收敛速度要快(表 2), 且前者的记忆和联想能力相对要高些。

表 2 3 层与 4 层 BP 模型的检验结果比较

Table 2 Comparison of the test results from BP network of 3 layers and 4 layers

| 训练样本 | 3 层 BP 模型(120 000 次迭代) | | | 4 层 BP 模型(60 000 次迭代) | | |
|-------|------------------------|--------|--------|-----------------------|--------|--------|
| | g | 记忆(%) | 联想(%) | g | 记忆(%) | 联想(%) |
| 0~50 | 0.995 | 78.000 | 73.684 | 0.995 | 78.000 | 76.316 |
| 10~60 | 0.995 | 75.000 | 73.684 | 0.925 | 74.000 | 80.263 |
| 20~70 | 0.995 | 80.000 | 71.053 | 0.925 | 80.000 | 75.000 |
| 30~80 | 0.200 | 81.000 | 63.158 | 0.995 | 85.000 | 55.263 |
| 平均 | | 78.500 | 70.395 | | 79.250 | 71.711 |

3 BP 模型法与傅立叶描绘子法的比较

为了检验人工神经网络方法的临近预报效果, 我们采用傅立叶描绘子法^[1]跟踪雷达回波的运动, 并将其临近预报的结果与人工神经网络方法的结果进行了比较。

傅立叶描绘子是对各回波边界进行傅氏变换后提取的表征各回波块形状特征的因子, 即圆形度、细长度、散射度和凹度。傅立叶描绘子法根据这些形状特征因子进行两时刻间回波的“配对”, 求出其移向移速并进行线性外推预报。下面简单介绍利用傅立叶描绘子法进行临近预报时, 两时刻间回波的“配对”及外推预报两方面的内容。

(1) 两时刻间回波的“配对” 由于在一定的时间内回波不可能移动太远, 回波面积不可能变化太多, 所以先要进行回波检验。首先计算两块回波几何中心之间的距离 d 和两者的面积差 A 与 t_2 时刻回波面积 A_2 之比 $r(r = A/A_2)$, 然后比较 d 与 d_0 , r 与 r_0 的大小。如果 $d > d_0$ 或者 $r > r_0$, 则认为这两块回波不可能是同一块回波。

在进行回波“配对”时, 允许特征量有一定的变化范围, 即满足

$$\frac{F_{2i} - F_{1i}}{F_{2i}} < h_0, \quad i = 1, 2, 3, 4, \quad (7)$$

则认为这两块回波有同为一块的可能性。其中, F_{2i} 与 F_{1i} 分别是 t_2, t_1 时刻回波的第 i 个特征量。如果 t_1 时刻仅有一块回波满足 (7) 式, 则认为 t_2 时刻的这块回波与 t_1 时刻中的该块回波“配准”。对配准的回波根据其几何中心的位移求出其移向移速。

(2) 外推临近预报 由于有的回波形变太大, 以及生消等原因使得一些回波不能被配准, 因此不能直接获取其速度, 只能以其周围已“配准”回波的速度进行插值而获得。对于速度插值, 我们选择了最简单的两点平均法, 来获得中间点的速度以代表该块回波的速度。这样一来, 我们就获得了每块回波的速度。

然后, 我们根据下式进行线性外推,

$$\begin{cases} x = ut + x_0; \\ y = vt + y_0. \end{cases} \quad (8)$$

其中 (x_0, y_0) 是 t_1 时刻某块回波几何中心的位置, t 是外推时间, u, v 是回波的 x, y 轴向速度,

(x, y) 是回波的预报位置。

用 2 层、3 层 BP 模型及傅立叶描绘子法进行临近预报, 预报准确率分别为 70.395%、71.711% 和 57.692%。说明利用人工神经网络的自组织、自学习能力及其记忆联想功能, 根据雷达回波的各特征向量, 建立一个复杂的非线性的映射关系, 利用雷达资料作临近预报的神经网络方法是可行的。

4 问题及讨论

文中所用 BP 模型的输入向量的选取有待进一步研究, 应选取最具代表性的、正交的参数。尽管文中所用的 6 个特征分量的确代表了某一回波的若干特征, 但是否能够代表回波的全部特征, 及彼此间是否满足正交要求, 关系到人工神经网络的训练结果以及其应用识别能力。其次, 试验的个例还不够多, 不能够包含有足够的信息, 以至于网络的识别精度还不够高。

人工神经网络作为一个利用雷达资料进行临近预报的新方法, 本文选择了目前最为广泛应用的 BP 模型, 进行了初步尝试。尽管人工神经网络技术应用于临近预报方面(利用雷达资料进行临近预报) 还不够成熟, 但它是一个较为科学的研究方向, 其应用前景十分广阔。

参 考 文 献

- [1] 边肇祺. 模式识别[M]. 北京: 清华大学出版社, 1988.
- [2] 周继成, 周青山, 韩飘扬. 人工神经网络——第六代计算机的实现[M]. 北京: 科学普及出版社, 1993.
- [3] 焦李成. 神经网络系统理论[M]. 西安: 西安电子工业科学出版社, 1990.
- [4] 胡守仁, 于少波, 戴 葵. 神经网络导论[M]. 长沙: 国防科技大学出版社, 1993.

The Back Propagation Network Method for Nowcasting Using Weather Radar Data

Chen Jiahui Zhang Peichang

(Department of Electronic Information and Applied Physics, NIM, Nanjing 210044)

Abstract: The BP model method for nowcasting is discussed in this paper. The results are compared with that from Fourier descriptor method, and it is shows that the artificial neural network method is feasible for nowcasting.

Key words: neural network, back propagation model, now casting