

卫星面降水估计人工神经网络方法

师春香 卢乃锰 张文建

(国家卫星气象中心, 北京 100081)

摘要 介绍了人工神经网络原理和卫星云图估计降水的原理。从 GMS 红外卫星云图资料中抽取 12 个降水云图特征量, 构造了网络结构为 12-98-7 的降水估计人工神经网络模型, 并用 1993 年的小时地面雨量资料和 GMS 数字云图资料对神经网络模型进行训练, 用 1992 和 1994 年资料对该神经网络模型分别进行测试。在日面降水估计试验中, 地面雨量计和卫星估计降水之间的相关系数分别为 0.94 和 0.97, 相对误差分别为 41% 和 32%。

关键词: 卫星云图; 降水估计; 人工神经网络

1 引言

早在 20 世纪 60 年代就已开始了卫星资料估计地面降水的研究工作。随着气象卫星及星载探测器的不断改进, 卫星资料估计降水的技术也得到发展, 以 Arkin 提出的方法为代表的云指数法以其简单方便的优点, 被广泛应用于气候研究中; 以 Scofiled 提出的方法为代表的云生命史法, 不仅考虑了云顶温度与降水的关系, 也考虑了云的发展变化与降水的关系, 被用于强对流云团的降水估计中^[1]。在过去的研究中, 当选定了用于降水估计的通道和特征变量之后, 大都采用经验方法或逐步回归分析方法构造降水估计方程^[2,3]。由于降水是一个非常复杂的过程, 而且地面降水与云顶温度等变量之间存在非线性关系, 因此, 用统计方法构造的降水方程存在一定的局限性^[4]。

到目前为止, 人工神经网络已被广泛应用于多种研究和技术领域, 它在解决非线性、复杂问题方面具有潜力和优势^[5,6]。本文从 GMS 红外数据中提取与降水相关的云特征, 建立了人工神经网络降水估计模型, 并将其试用于面降水估计。

2 资料

地面小时雨量资料共有 22672 个, 取自于 1992~1994 和 1998 年夏季, 河南、湖北和四川的 300 多个雨量站。卫星资料为日本 GMS 卫星 S-VISSL 数字云图, 原始的卫星图像经等经纬度投影后转换成分辨率为 $0.06^\circ \times 0.05^\circ$ 的标准图像。所有在研究区域内的云顶温度低于 -37°C 的强对流云团均被选入样本, 共计云图 4000 多张。

3 人工神经网络模型及算法

人工神经网络理论在许多领域得到广泛的应用。到目前为止, 人工神经网络模型也

已达上百种，本文采用在模式识别领域得到广泛应用的多层前馈网络的B-P算法（B-P网络模型）建立卫星降水估计模型。B-P网络模型是典型的多层网络，它包括输入层、隐层和输出层，层与层之间采用全互连方式，同一层单元之间不存在相互连接。图1给出了一个三层B-P网络结构模型。

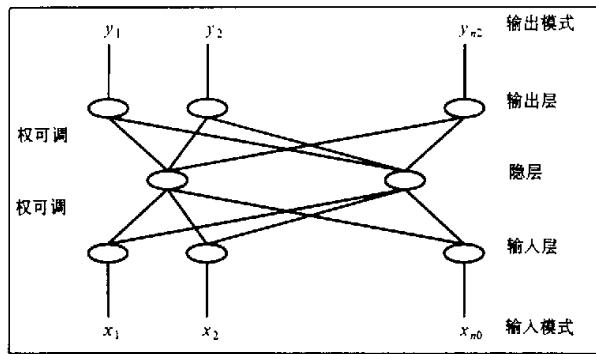


图1 B-P网络结构

网络中神经元的输入是上一层神经元输出的权重和：

$$n_j = \sum_i w_{ij} o_i,$$

由网络神经元激活函数（一般为sigmoid函数）将权重和转换为神经元输出：

$$o_j = 1 / [1 + \exp(-n_j + \theta_j)],$$

其中， θ_j 为常数，在训练过程中，用下式调整权重：

$$\Delta w_{ji}(n+1) = \eta(\delta_j o_i) + \alpha \Delta w_{ji}(n),$$

其中， $\Delta w_{ji}(n+1)$ 为连接神经元*i*和*j*的权重被修改后的值， δ_j 为误差修正项， η 为学习率， α 为动量项。

该网络实现了多层次网络学习的设想，当给定网络一个输入模式时，它由输入层单元传到隐层单元，经隐层单元逐层处理后再送到输出层单元，由输出层单元处理后产生一个输出模式，这是一个逐层状态更新的过程，称为前向传播。若输出与期望输出模式有误差且误差不满足要求时，误差转入后向传播过程，将误差值沿连接通路逐层传送并修正各层连接权值，这就是误差后向传播的涵义。用给定的一组训练模式，重复对网络训练，也就是重复前向传播和误差后向传播的过程，当各个训练模式都满足要求时，多层次前馈人工神经网络学习过程结束，并保留一组连接权系数。已训练好的神经网络模型可以对新的输入模式给出判别结果。

4 卫星降水估计原理

降水是大气中水的相变过程，是云滴增长变为雨滴而下降的过程，它是大气动力作

用和热力作用的综合结果。这种作用不仅决定了云中的降水，而且决定了降水云的外在形态。可见光及红外降水估计方法正是借助于可见光与红外扫描辐射仪对降水云外在形态的探测去推断云中的降水信息。对大量降水过程的定量分析表明，一些云图特征量与降水有一定的对应关系^[7,8]。

强对流云团云顶温度和云顶温度梯度是与降水强度关系最为密切的两个云图特征量。图 2 为对流云团云顶温度与降水强度的关系，其中横坐标为 GMS 卫星云图灰度

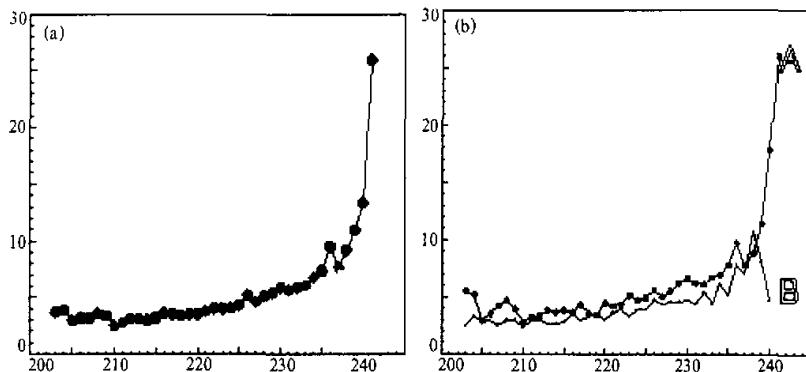


图 2 云顶灰度与降水强度关系曲线
横坐标为灰度，纵坐标为降水量
(a) 所有云团；(b) 膨胀着的云团（曲线 A）与萎缩着的云团（曲线 B）

值，与温度有一一对应的关系，纵坐标为小时雨量。从图 2 可以看到，当云顶温度较低时，对流云团云顶温度与降水强度的对应关系较好，而当云顶温度较高时，对流云团云顶温度与降水强度的对应关系较差。图 3 是云顶温度梯度与降水强度的关系曲线。云顶温度梯度大，说明云顶的纹理丰富，起伏剧烈，从某种意义上讲，云顶温度梯度的大小体现了云团内部的对流活跃程度。从图 3 可以看到，在弱降水区，云顶温度梯度与降水强度呈正相关，在强降水区则相反。定量分析还表明云团的生命史以及云团的移动速度也与降水有关。发展阶段的云团的降水强度大于消亡阶段的云团降水强度，云团的发展阶段由云团的膨胀率定量表示，云团膨胀率与降水强度存在正相关。云团的移动速度与降水也是正相关关系。另外，对流云体相对于云团中心的偏离量与降水强度的关系为：越靠近对流云团中心的云，它的降水强度越大；越远离对流云团中心的云，它的降水强度越小。

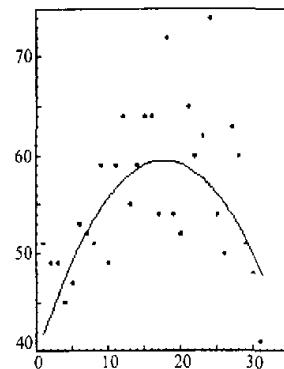


图 3 云团的云顶灰度梯度与降水强度关系曲线
横坐标为降水量，
纵坐标为梯度

5 降水估计神经网络模型结构与输入特征

5.1 特征提取

根据卫星云图估计降水的原理以及通过对大量降水过程的定量分析, 选出了 12 个与降水相关性较强的云图特征量(见表 1)。表 1 中, IT 为被讨论的像素点的红外云顶亮度温度; ITM 为云团的最冷云顶亮度温度; 考虑到对流云团云顶亮度温度与降水之间的关系的特点, 根据云顶亮度温度将云团划分为四层, 每一层的面积分别表示为 IS1、IS2、IS3、IS4; ISS 为云团第一层(灰度为 203~219)的膨胀速度, IDSS 为云团最冷层膨胀速度; IG 为云顶亮度温度梯度, 梯度的表达式为

$$G = \{[T(i+1,j) - T(i-1,j)]^2 + [T(i,j+1) - T(i,j-1)]^2\}^{1/2},$$

其中, T 为灰度, i 、 j 为图像坐标; ISP 为云团移动速度; LP 为不对称因子; ID0 为对流云类型($ID0=1$, 表示云团接近圆形; $ID0=2$, 表示云团接近长形; $ID0=3$, 表示复杂云团)。

表 1 神经网络模型输入变量

序号	输入变量	物理意义	序号	输入变量	物理意义
1	IT	红外云顶亮度温度	7	ISS	云团第一层膨胀速度
2	ITM	云团最冷云顶亮度温度	8	IDSS	云团最冷层膨胀速度
3	IS1	第一层面积(203~219)	9	IG	云顶亮度温度梯度
4	IS2	第二层面积(220~228)	10	ISP	云团移动速度
5	IS3	第三层面积(229~236)	11	LP	不对称因子
6	IS4	最冷层面积(>236)	12	ID0	对流云类型

5.2 神经网络结构

神经网络结构取决于输入特征数, 要识别的类别数、隐层层数和各隐层神经元数目的选择。网络输入层神经元个数对应输入特征的数目, 输出层对应要识别的类别数, 为了减小网络结构, 节省资源, 输出的小时雨量值由 7 个二进制数的组合表示, 因此该网络模型可估计出 0~127 mm 的小时雨量。隐层层数和各隐层神经元数目的选择目前还没有成熟的理论, 在大多数的应用中根据经验和试验确定。这方面还有待于进一步的研究。

在输入层和输出层以及训练样本不变的条件下, 通过改变隐层数目和隐层神经元数目可改变网络结构, 通过试验选择合适的结构。经过大量的试验, 本文最后选择的神经网络模型结构为 12-98-7, 即输入层 12 个神经元, 包括一个隐含层, 隐含层神经元 98 个, 7 个输出变量。

6 人工神经网络降水估计试验

由于降水是一个复杂的过程, 涉及多个气象要素和非气象要素。利用卫星云图估计降水又是一种间接的方法, 且 12 个云图特征量之间还存在相关, 从而增加了构造降水

估计方程的难度。使用统计方法构造降水估计方程时, 为减小误差, 需要对不同地区和不同亮温范围建立不同的方程, 还必须舍掉一些与其他特征相关的特征, 使得不能充分利用所提取出的信息。对相同的样本集, 估计日最大降水时, 用统计回归方法需建立8个降水估计方程, 误差为30%, 相关系数为0.69^[9]。而神经网络方法则不同, 我们对整个研究区域构造了卫星云图降水估计B-P神经网络模型。用1993年小时雨量和云图特征量数据作为训练样本对降水估计神经网络模型进行训练, 有效样本数据为3810个。并用1992和1994年数据作为测试样本对训练好的模型分别进行测试试验。1992年有效样本数据为12894个, 降水日数为54天; 1994年有效样本数据为19763个, 降水日数为61天。图4为地面观测降水和卫星估计降水之散点图, 其中图4a为1992年6~8月的情况, 地面观测每日面降水和卫星估计每日面降水之间的相关系数为0.94, 相对误差为41%; 图4b为1994年6~8月的情况, 地面观测每日面降水和卫星估计每日面降水之间的相关系数为0.97, 相对误差为32%。

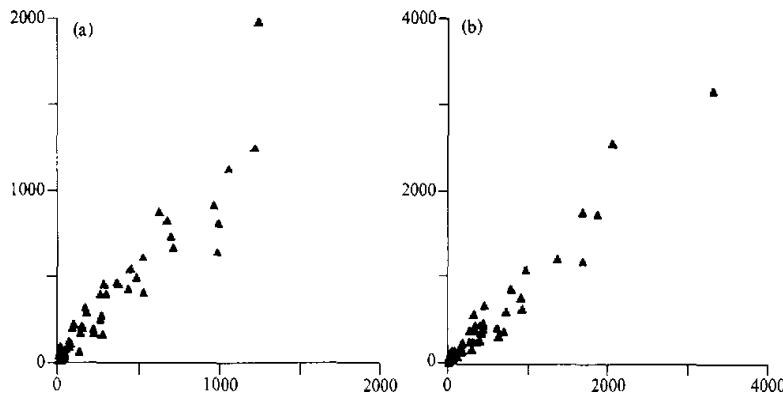


图4 地面观测降水和卫星云图估计降水之散点图
横坐标为日面降水地面观测值, 纵坐标为日面降水卫星估计值, 单位: mm
(a) 1992年6~8月; (b) 1994年6~8月

用神经网络方法构造降水估计方程与用统计回归方法构造降水估计方程相比具有优势: 第一, 在建立方程时可包含更多的特征变量; 第二, 可简化构造降水估计方程的过程, 减少方程个数; 另外, 从理论上讲, 神经网络能更好地描述非线性复杂过程, 并且容错性强。

7 小结

对整个研究区域构造了卫星云图降水估计B-P神经网络模型, 通过试验选出的网络结构为12-98-7。由从GMS卫星红外通道中提取的12个云图特征量, 用1993年的小时地面雨量资料和GMS数字云图资料对神经网络模型进行训练, 用1992和1994年资料分别对该神经网络模型进行测试。在日面降水估计试验中, 地面雨量计值和卫星估计降水之间的相关系数分别为0.94和0.97, 相对误差分别为41%和32%。

参 考 文 献

- 1 Alvin and Xie. The globe precipitation climatology project: first algorithm intercomparison project, *Bull. Amer. Meteo. Soc.*, 1994, **75**, 401~419.
- 2 Kou-Lin Hsu, Xiaogang Gao, Soroosh Sorooshian and Hoshin V. Gupta, Precipitation estimation from remotely sensed information using artificial neural networks, *Journal of Applied Meteorology*, 1997, **36**, 1176~1190.
- 3 Lu Naimeng, Satellite rainfall estimation, the 8th Conference on Satellite Meteorology and Oceanography, 1997, 527~533.
- 4 Atkinson, P. M. and A. R. L. Tatnall, Introduction: Neural networks in remote sensing, *International Journal of Remote Sensing*, 1997, **18**(4), 699~710.
- 5 杨行峻、郑君里, 人工神经网络, 北京: 高等教育出版社, 1992.
- 6 罗四维, 人工神经网络建造, 北京: 中国铁道出版社, 1998.
- 7 卢乃锰、师春香、张文健, 卫星降水估计结果与地面降水观测结果的融合技术, 淮河流域能量与水分循环研究(1--), 北京: 气象出版社, 1999, 125~129.
- 8 卢乃锰、吴蓉璋, 强对流降水云团的云图特征分析, 应用气象学报, 1997, **8**(3), 269~275.
- 9 Course of Meteorological Satellite Application and Hazards Monitoring, National Satellite Meteorology Center, October 1997.

Precipitation Estimation from Remotely Sensed Information Using Neural Networks

Shi Chunxiang, Lu Naimeng and Zhang Wenjian

(National Satellite Meteorology Center, China Meteorological Administration, Beijing 100081)

Abstract We designed a model with 12 inputs, one hidden layers and 7 outputs (12-98-7) for precipitation estimation using GMS IR image. The neural network model is trained with hourly ground observations and 12 satellite imagery features data from summer 1993 and tested with data from summer 1992 and 1994. Then it is applied to estimating daily area rainfall. The results reveal that their errors is 31.8% and 41.0% for daily area rainfall estimation, and their correlation coefficients are 0.97 and 0.94.

Key words: satellite image; precipitation estimate; artificial neural network.