

# 川西高原大雪人工神经网络短期预报系统

陈晓刚 郭 斌 张 政

(四川省阿坝州气象局, 马尔康 624000)

## 提 要

采用初级预报模式结合人工神经网络(BP算法)的方法,使用阿坝牧区大雪天气过程历史资料,研制了川西高原牧区大雪天气预报系统。利用9210工程接收到的数据资料,自动完成因子采集和结论输出,每次输出后,因子库自动增加新的因子,网络再次学习,从而进一步提高预报精度。

**关键词:**大雪 短期预报 人工神经网络 反向传播 自学习功能

## 前 言

川西高原地处青藏高原东南缘,四川省西部,地形为海拔3300~4000m的丘状高原。经济以牧业为主。主要的自然灾害是雪冻灾害天气,大雪是致灾的重要因素之一。因此提高大雪天气预报的准确率,对决策部门防灾、减灾有着重要意义。

目前实用的人工神经网络主要有<sup>[1]</sup>madavine、BP、Hopfield、Hamming等几种。本文使用的是BP网络,它是当前广泛应用的一种神经网络,它把对一组样本的输入输出问题变为一个非线性优化问题,使用了最优化中最普通的一种沿梯度下降算法。用迭代运算求解,加入隐节点使得优化问题的可调参数增加,从而得到更精确的解。BP网络结构简单,工作状态稳定,易于实现,较适用于天气预报领域。

## 1 大雪天气过程的初级预报模式

大雪天气的发生是在一定的影响系统如:高空锋区、能量条件、水汽条件和冷空气活动等共同作用下产生的。为了更精确地描述大雪天气发生前的各要素特征,我们采用分月建立初级预报模式的方法。总共选取了55个因子,建立了初级预报模式。限于篇幅,各因子的具体量化指标就不作详细说明,只是将各因子的物理意义和模式的结构予以说明。

### 1.1 起报条件

选用阿坝牧区14时地面资料中的 $T$ 、 $P$ 、 $T_d$ 和 $\Delta T_{24}$ 、 $\Delta P_{24}$ 、 $\Delta T_{d24}$ 、作为起报条件的判别因子。

### 1.2 影响系统

08时500hPa高空,30~40°N,80~100°E范围内有低涡或低槽或南北气流辐合线。

### 1.3 高空锋区

影响川西高原牧区的500hPa锋区,等温线密集带绝大多数为西南东北向且靠近东西向,我们取近似垂直锋区的温差表示其强度。有如下3个判据:

$$F = \sum_{i=1}^n T_i - \sum_{j=1}^m T_j \quad (1)$$

$$F_1 = T_{56046} - T_{52203} \quad (2)$$

$$F_2 = T_{52818} - T_{51463} \quad (3)$$

式中, $F$ 表示锋区强度判据; $T_i$ 表示高原东南部第 $i$ 站500hPa高空温度; $T_j$ 表示新疆地区第 $j$ 站的高空温度。

### 1.4 过程前的能量条件

选取高原东部的部分站500hPa高空温度作为能量判据指标。

$$T_\delta = \sum_{i=1}^n T_i$$

### 1.5 52区范围内的 $\Delta T_{24}$

选取52区范围内,500hPa高空的 $\Delta T_{24}$ ,表示高空冷空气强度,共有2个判据。即,52

区范围的最大降温和负变温的站数。

### 1.6 水汽条件及水汽输送

选取青藏高原中部和南部的部分站的  $T - T_d$  作为水汽条件判据。选取青藏高原南部部分站的西南气流平均风速及西南风向站数作为水汽输送的判据。

### 1.7 南支系统

普查大雪历史个例,发现大雪天气的发生,与低纬度的南支低值系统活动关系明显。当孟加拉湾一带为南支低槽时,其槽前西南气流不断地将暖湿空气输送到高原。因此南支槽的存在是重要的判据之一。

### 1.8 影响系统的强弱情况

我们选取  $30 \sim 40^\circ\text{N}$ ,  $80 \sim 100^\circ\text{E}$  范围内  $500\text{hPa}$  高空的  $\Delta H_{24}$  为判据因子,主要有两个判据条件,一是规定区域内的最大负变高,二是规定区域内负变高站数。

由于我们采用分月建立初级预报模式,因此,各月份的具体判据指标有所不同,但各月的主要判据条件差别不大。

建立初级预报模式的目的是减小网络的不必要的学习,可以大大缩小网络规模,减少网络学习次数,提高网络学习精度。

## 2 BP 网络的基本原理

BP 网络模型(见图 1),网络不仅有输入节点、输出节点、而且有一层或多层隐蔽节点。算法的学习过程由网络正向传播和误差反向传播两个过程组成,在正向传播过程中,输入信息从输入层经隐蔽单元层逐层处理,并传向输出层,每一层神经元的状态只影响下层神经元的状态,如果在输出层不能得到期望的输出,则采用误差反向传播,将误差信号返回,通过反复修改各层之间神经元的联接权重,使得总体误差趋向于最小。




图 1 BP 网络模型

## 3 BP 网络的具体算法

(1) 将套上初级预报模式的历史资料因子,利用极值标准公式处理<sup>[2]</sup>。

$$T_1 = (T - T_{\min}) / (T_{\max} - T_{\min})$$

上式中,  $T$  是历史资料因子,  $T_{\min}$  是最小值,  $T_{\max}$  是最大值,  $T_1$  是变化后的值,  $T_1$  的值在  $[0, 1]$  区间。

(2) 将初始化权值  $W$  和阈值  $\theta$  设置成较小的随机数。

(3) 提供预报因子向量  $x_1, x_2, \dots, x_n$  和规定的预期输出因子  $d_1, d_2, \dots, d_m$ 。

(4) 利用 S 型逻辑非线性函数

$$f(\alpha) = 1 / [1 + e^{-(\alpha - \theta)}] \quad (4)$$

计算隐层节点的输出值和输出层节点的输出值。假设隐层有  $n_1$  个单元,输出层有  $m$  个单元,输入层有  $n$  个单元。

隐层节点的净输入是

$$net_j = \sum_i^n W_{ij} O_i \quad (1 \leq i \leq n) \quad (5)$$

隐层节点的输出

$$O_j = f(net_j) = 1 / \{1 - \exp[-(\sum_{i=1}^{n_1} W_{ij} O_i - \theta_j)]\} \quad (1 \leq j \leq n_1) \quad (6)$$

输出层节点的输出值

$$y_k = f[\sum_{j=1}^{n_1} W_{jk} O_j - \theta_k] = 1 / \{1 - \exp[-(\sum_{j=1}^{n_1} W_{jk} O_j - \theta_k)]\} \quad (1 \leq k \leq m) \quad (7)$$

## (5) 用下列公式调整权值

$$W_{ij}(t+1) = W_{ij}(t) + \eta \delta_j O_i$$

上式中,  $W_{ij}(t)$  是  $t$  时间由隐层或输入层节点  $i$  到下一层节点  $j$  的权值,  $\eta$  是增益系数,  $\delta_j$  是节点  $j$  的误差值,  $O_i$  是节点  $i$  的输出或输入。若节点  $j$  是一个输出节点, 则

$$\delta_j = y_j(1 - y_j)(d_j - y_j)$$

其中:  $y_j$  是实际计算所得到的输出值,  $d_j$  是节点  $j$  的预期输出。

若  $j$  是一个内部节点

$$\delta_j = O_j(1 - O_j) \sum_k \delta_k W_{jk}$$

其中,  $k$  是遍取节点  $j$  前层中的结点。

## (6) 转(2)。

## 4 样本训练(网络学习)

首先, 依据天气学理论, 分别就影响系统、高空锋区、能量条件、水汽条件、变温、变高等与大雪天气有关的物理意义明确的因子, 同时满足初始条件(即套上初级预报模式)的历史资料构成因子库, 将各因子分组, 组与组之间无大联系, 让网络学习, 这样可以缩小网络规模。

我们用 1980~1996 年共 17 年的历史资料为样本(套上初级预报模式的样本共 101 个), 进行训练, 选用 25 个因子(即输入层节点数)。将隐层节点数定为 3 个, 训练到 800 次就达到目的, 训练结束后, 机器自动存储各层间的权值和阈值。

通过历史回代, 其概括率、拟合率分别为 96.6% 和 96.4%。

对 1998 年大雪天气, 进行了逐一试报, 其检验情况如表 1。

表 1 1998 年试报情况

日期/月·日	3.7	3.20	3.22	4.4	4.10
实况	有	无	有	有	有
预报	有	有	有	有	有
定性结论	正确	错	正确	正确	正确

由表 1 可见, 1998 年系统试报的概括率为  $4/4=100\%$ , 定性准确率为  $4/5=80\%$ 。

## 5 网络的自学习功能

为了进一步提高预报准确率, 使系统运行更加稳定, 只有让网络不断学习, 新增学习样本。为此, 我们增加了网络自学习功能。而网络自学习功能主要是利用现代化通信设备, 由计算机自动完成。具体做法如下。

## 5.1 新增样本的自动采集

利用 9210 工程接收到的数据, 由微机自动套用初级预报模式, 对套上初级预报模式的天气过程自动采集、分类因子, 写入训练因子库。

## 5.2 网络再次学习

对新写入训练因子库的因子, 由网络再次学习, 达到精度后, 存储各层权值。这样, 在今后业务使用中, 网络就会不断学习, 使之运行稳定, 提高预报能力。

## 6 系统的优点

## (1) 对异常天气的学习能力

所谓异常天气, 指的是在影响系统、高空锋区、能量条件、水汽条件、要素场特征等方面异常情况下产生的大雪天气。用常规天气学方法建立的预报模式, 对异常天气缺乏学习能力, 而网络通过对异常天气的学习, 会提高对它的认识, 从而提高对异常天气的预报能力。

## (2) 修改预报模式简单易行

用常规天气学方法建立的预报模式, 修改比较麻烦, 往往通过重新增减因子或修正具体因子判据量值来优化模式, 修改后还需反查历史个例和逐月历史回代。而网络具有自学习功能后, 较好地解决了这方面的问题。

## (3) 客观定量

由于系统运行都是由计算机自动完成, 减少了人为因素对影响系统等认识上的差异所造成的不利因素。

## 参考文献

- 曹焕光. 人工神经网络原理. 北京: 气象出版社, 1992.
- 汤子东等. BP 人工神经网络在春季降水量预报中的应用. 气象, 1997, 23(8): 34~37.

(下转第 15 页)

# The Short-range Weather Forecast for Heavy Snow in Chuanxi Plateau by BP Artificial Neural Network

Chen Xiaogang Guo Bing Zhang Zheng

(Aba Prefecture Weather Office, Sichuan Province 624000)

## Abstract

The weather forecast system for heavy snow over Chuanxi Plateau in Sichuan province was developed by using the historical weather records of heavy snow on Aba grass land and combining an elementary model with BP artificial neural network. The system is automated to collect the interrelated factors and output the conclusion by using the data information from the Project 9210. Then new factors were automatically added to the data base, and the forecast accuracy for heavy snow of the forecast system was improved.

**Key Words:** heavy snow short-range forecast artificial neural network back propagation