

# 基于人工神经网络的集成预报方法研究和比较<sup>\*</sup>

金 龙 陈 宁

(江苏省气象科学研究所, 南京, 210008)

林 振 山

(南京大学大气科学系, 南京, 210093)

## 摘 要

用人工神经网络方法对同一预报量的各个子预报方程进行集成预报研究, 并以同样的子预报方程进行回归、平均和加权预报集成。对神经网络集成预报模型与各个子预报方程及其它集成预报方法进行了对比分析研究。结果表明, 人工神经网络方法所构造的集成预报模型不仅对历史样本的拟合精度比各个子预报方法及其它集成预报方法更好, 独立样本的试验预报结果也显示出更好的预报准确性。并且, 采用神经网络方法进行预报集成, 可以避免以往集成预报方法难以确定权重系数的困难。

关键词: 神经网络, 预报集成, 长期预报, 比较分析。

## 1 引 言

随着统计预报方法的不断发展, 集成预报结果可以比用于预报集成的各个子预报方法获得更好的预报效果已越来越被人们所认识<sup>[1]</sup>。尤其在经济、管理和统计研究领域, 各种优性组合预报方法已成为改进、提高预报精度的重要途径。目前, 在长期预报的业务预报研究工作中, 采用的统计预报方法有许多种, 通常对于某个预报量会有多种预报工具或方法的预报结果。为了更好地得出最终的预报意见, 研究探讨各种预报子方程的综合集成预报新方法对实际业务预报具有重要意义。目前长期预报工作中, 较为常用的集成预报方法除了回归、平均和加权集成方法以外, 也有采用概率回归和典型相关等集成预报方法。然而这些常用的集成预报方法其本质上大多属于线性的顺序处理技术。本文则尝试用具有非线性准动力系统特征的人工神经网络方法<sup>[2]</sup>来进行预报集成研究。并进一步与其它集成预报方法进行比较, 从历史样本的拟合效果以及独立样本的预报能力两个方面来讨论神经网络集成预报方法与各个子预报方程及其它集成预报方法的差异。

## 2 基本原理和方法

\* 初稿时间: 1997 年 10 月 17 日; 修改稿时间: 1998 年 2 月 17 日。

资助课题: 中国气象局“九五”项目。

人工神经网络(ANN)方法是目前国际上多学科发展的竞争热点,该方法具有较好的自学习功能及处理非线性问题的能力,在大气科学研究领域越来越受到重视。美国的强风暴中心在短期预报中,进行了神经网络的雷暴业务预报系统研究<sup>[3]</sup>。作者<sup>[4]</sup>在相同条件下,通过对比分析神经网络方法与逐步回归预报方法的差异,为进一步开展神经网络方法的预报建模展示了前景。本文在尝试进行人工神经网络的集成预报研究时,采用前馈网络模型。该模型物理概念清晰,通用性好,具有高度灵活可变的拓朴结构。用人工神经网络进行集成预报建模,主要是将构成集成预报的各个子预报方法作为神经网络学习矩阵的输入。网络预测模型的大量参数是网络对输入的原始数据进行不断的学习训练来获得。其学习训练过程,主要是通过调整网络模型输入层与隐含层及隐含层与输出层之间的各连接权系数及阈值。其具体算法有很多种,本文采用的是误差反传算法,该方法的数学原理和推导方法见文献[5],网络学习矩阵的学习算法可主要归结如下:

设网络的学习样本输入和期望输出  $A_k, C_k(k = 1, 2 \dots m)$ , 为学习矩阵的模式输入对个数)。随机地给出网络从输入层到隐含层的初始连接权系数  $V_{hi}$ , 同时也随机地给出一组隐含层到输出层的连接权系数  $W_{ij}$  以及隐含层单元和输出层单元的阈值  $\theta, Y_i$ 。然后对学习样本的输入和期望输出  $A_k, C_k(k = 1, 2 \dots m)$  进行下列计算:

(1) 根据连接权矩阵(初始时刻为给定的一组随机小量)和学习样本的输入, 计算隐含层新的激活值:

$$b_i = f\left(\sum_{h=1}^n \alpha_h U_{hi} + \theta\right) \quad (1)$$

其中  $i = 1, 2 \dots p$ , 为隐含层节点数,  $h = 1, 2 \dots n$ , 为输入层节点数, 节点的转移函数为 Sigmoid 函数:

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

(2) 计算输出层单元的激活值:

$$C_j = f\left(\sum_{i=1}^p W_{ij} b_i + Y_j\right) \quad (3)$$

其中  $j = 1, 2 \dots q$ , 为输出层节点数, 初始时刻  $W_{ij}$  为一组给定的随机小量。

(3) 计算输出层单元的一般化误差:

$$d_j = C_j(1 - C_j)(C_j^k - C_j) \quad (4)$$

其中  $j = 1, 2 \dots q$ ,  $C_j^k$  为输出层单元  $j$  的期望输出。

(4) 计算隐含层单元相对于每个  $d_j$  的误差:

$$e_i = b_i(1 - b_i) \sum_{j=1}^q W_{ij} d_j \quad (5)$$

其中  $i = 1, 2 \dots p$ 。

(5) 调整隐含层单元到输出层单元的连接权:

$$\Delta W_{ij} = \alpha b_i d_j \quad (6)$$

其中  $i = 1, 2 \dots p$  和  $j = 1, 2 \dots q$ ,  $\alpha$  为学习因子 ( $0 < \alpha < 1$ )。

(6) 调整输出层单元的阈值:

$$\Delta Y_j = \alpha I_j \quad (7)$$

其中  $j = 1, 2, \dots, q$ 。

(7) 调整输入层单元到隐含层单元的连接权:

$$\Delta V_{hi} = \beta \alpha_i e_i \quad (8)$$

其中  $h = 1, 2, \dots, n, i = 1, 2, \dots, p, \beta$  为动量因子 ( $0 < \beta < 1$ )。

(8) 调整隐含层单元的阈值:

$$\Delta \theta_i = \beta e_i \quad (9)$$

其中  $i = 1, 2, \dots, p$ 。

(9) 重复第(1)到第(1)的计算步骤,直到  $j = 1, 2, \dots, q$ , 和  $k = 1, 2, \dots, m$ , 计算实际输出与期望输出的误差。当全部样本的输出误差小于设定的收敛误差时, 训练结束。根据这些确定的连接权系数和阈值, 就可以得到神经网络的集成预报模型。

### 3 集成预报模型

#### 3.1 集成预报的子方程

在建立集成预报方法的子预报方程时, 本文是用 1965 年到 1993 年南京春季 (3~5 月) 降水量作为预报量, 计算普查前期 500 hPa 月平均高度场及月平均海温场相关区。而以 1994~1996 年样本作为独立样本的预报检验。通过相关场的普查, 取成片的大于 4 个格点以上的相关区作为一个预报因子。共获得前期 500 hPa 月平均高度场 13 个预报因子及前期月平均海温场 13 个预报因子。在 500 hPa 13 个预报因子中, 有 9 个因子达到 0.01 以上的相关显著性水平, 相关系数最高达 0.66, 超过 0.001 的显著性水平。同样, 海温场的 13 个因子中除 3 个因子达到 0.02 相关显著性水平以外, 其余均超过 0.01, 相关系数最高为 0.61。用逐步回归方法, 分别对 500 hPa 13 个预报因子, 海温场 13 个预报因子建立各自的子预报方程 (A) 和 (B), 然后将两个回归方程剔除的预报因子合并, 用以建立第 3 个逐步回归方程作为子预报方程 (C)。考虑到实际预报应用中能及时取得实时的预报因子资料, 所建立的 3 个子预报方程中均没有包括当年 1 月份的高相关因子, 所有入选方程的预报因子均为上一年 6~12 月期间的预报因子。表 1 给出了 3 个子预报方程及方程的复相关系数, 本文均以这 3 个子预报方程为基础, 分别建立神经网络集成预报模型及回归、平均和加权集成预报模型。

表 1 各个子预报方程(南京)

回 归 方 程	复相关系数 (R)
$\hat{y}_1 = 961.19 - 2.01x_2 - 1.14x_4 - 0.64x_5 + 0.45x_6 - 0.78x_7 - 0.54x_9 - 1.07x_{10}$	(A) 0.9136
$\hat{y}_2 = -744.71 + 0.72x_1 - 0.31x_5 + 0.39x_6 + 0.73x_{12}$	(B) 0.7921
$\hat{y}_3 = -39.62 + 0.39x_1 - 0.31x_5 + 0.67x_7 + 0.59x_{10} - 0.85x_{12} - 1.57x_{13}$	(C) 0.8759

### 3.2 神经网络集成预报

在进行神经网络的预报集成时, 本文采用了一个三层的前馈网络模型, 该模型包括一个输入层和一个输出层, 其中间为一个隐含层。以 3 个子预报方程的历史拟合样本作为神经网络集成预报模型学习矩阵输入, 相应的预报量序列作为学习矩阵的期望输出。为了满足前馈网络节点函数的条件, 首先对学习矩阵的训练样本作标准化处理:

$$K_i = \frac{z_i - s}{t - s} \quad (10)$$

其中  $K_i$  为前馈网络的标准化输入数据,  $z_i$  为原始观测数据,  $s, t$  为待定系数。由于所取的 Sigmoid 节点函数是一种可微非递减函数, 该函数的值域为  $[0, 1]$ , 考虑到已获得的观测样本有限性, 并为了有效提高网络训练速度, 本文将学习矩阵的原始数据标准化在  $0.1 \sim 0.9$  之间, 因此公式 (10) 中的待定系数  $s, t$  可由以下公式计算:

$$\begin{cases} a - s = 0.1(t - s) \\ b - s = 0.9(t - s) \end{cases} \quad (11)$$

其中  $a, b$  分别为各样本序列中的最小值和最大值。根据式 (10) 计算得到前馈网络的标准化学学习矩阵, 隐含层的隐节点取 7, 学习因子为 0.7, 动量因子为 0.9。利用第 2 节给出的公式 (1) ~ (9), 对标准化学习矩阵作反复的学习训练, 当学习矩阵训练达 5000 次时, 误差函数趋于稳定。由网络模型所确定的连接权系数及阈值便可以得到相应的集成预报模型。并以此确定的参数和网络结构作为未来独立样本和实际预报的模型参数。

### 3.3 其它预报集成

由于用神经网络方法作集成预报是一种新的尝试, 因此, 必须对该方法的性能作一比较客观的分析、评价。为此, 再利用 3.1 节中的同样 3 个子预报方程分别进行回归、平均和加权预报集成。其相应的预报模型为:

$$\hat{y} = -95.69 + 0.71\hat{y}_1 + 0.25\hat{y}_2 + 0.14\hat{y}_3 \quad (12)$$

$$\hat{y} = (\hat{y}_1 + \hat{y}_2 + \hat{y}_3) / 3 \quad (13)$$

$$\hat{y} = \sum_{i=1}^3 w_i \hat{y}_i \quad (14)$$

在加权集成预报模型中,  $w_i$  为第  $i$  种子预报方程加权系数, 并且应满足:

$$\sum_{i=1}^3 w_i = 1 \quad (15)$$

加权集成预报的系数可以用如下的计算公式确定:

$$w_1 = \frac{v_2 + v_3}{2(v_1 + v_2 + v_3)} \quad (16)$$

$$w_2 = \frac{v_1 + v_3}{2(v_1 + v_2 + v_3)} \quad (17)$$

$$w_3 = \frac{v_1 + v_2}{2(v_1 + v_2 + v_3)} \quad (18)$$

其中  $v_i$  为某个子预报方程对建模历史样本的拟合平均相对误差。用公式 (16) ~ (18) 确定

加权集成预报的权重系数, 它表示了当某个子预报方程对历史样本的拟合误差越小, 则在预报集成时其权重系数越大, 反之则权重系数越小。

## 4 集成预报方法的对比分析

### 4.1 神经网络集成预报与各子预报方程的比较

一般集成预报的根本目的是要能够客观地综合所有子预报方程对预报量的预报信息。而考察集成预报方法的有效性, 首先应当比较分析集成预报模型历史样本拟合率是否好于各个子预报方程。为此, 首先在图 1 中比较了神经网络集成预报模型和拟合精度最高的子预报方程历史样本拟合值及实际降水量的变化曲线。从图 1 上可以看出, 神经网络集成预报模型的历史样本拟合效果要好于子预报方程, 并且对历史上少见的 1977 年春季多雨年也有很好的拟合效果。




图 1 南京春季降水量变化曲线

(实线为实测值, 短虚线为 ANN 拟合值, 长虚线为最佳子预报方程拟合值)

为了进一步作对比分析, 再利用以下 3 种统计评价指标:

(1) 平均绝对百分比误差:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{|y_t|} \quad (19)$$

(2) 均方误差:

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 \quad (20)$$

(3) 平均绝对误差:

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (21)$$

对神经网络集成预报模型与各个子预报方程的历史样本拟合效果作定量比较。表 2 给出了神经网络集成预报模型和各个子预报方程的 3 种统计评价指标计算结果。

表 2 神经网络集成预报模型与各子预报方程的 3 种评价指标的比较

评价指标	ANN 集成	子方程(A)	子方程(B)	子方程(C)
MAPE	0.0913	0.1231	0.1661	0.1344
MSE	29.8236	33.6330	50.5010	39.9267
MAE	22.4918	27.1821	42.3205	31.4964

由表 2 的比较可以看到,神经网络集成预报模型 3 种统计量指标明显优于各个子预报方程。神经网络预报模型的平均绝对百分比误差(MAPE)为 9.13%,分别比 3 个子预报方程低 3.18%,7.48%和 4.31%。如果以逐年的拟合值相对误差绝对值小于 20%为拟合正确,则 3 个子预报方程的拟合准确率为 82.7%,58.6%和 82.7%,其平均准确率为 74.8%,而神经网络集成预报的拟合准确率为 89.6%(表略)。

以上的计算讨论主要是对神经网络预报集成与各个子预报方程的拟合效果进行了比较,而一般的统计预报方法往往拟合效果较好,实际预报能力有时并不一定与拟合效果一致。因此,为了进一步考察神经网络预报集成的实际预报能力,再对 1994~1996 年 3 a 的独立样本进行独立样本的预报检验。为了使独立样本的预报检验更为客观,采用类似于 C. Kung<sup>[6]</sup>提出的方法,首先用 3 个子预报方程(A),(B)和(C)分别进行 1994 年的预报,然后再将 1994 年的实况资料加入样本集,重新建立回归方程,预报 1995 年,以此类推。3 个子预报方程均对未来 3 a 进行独立样本的预报试验。对于神经网络的集成预报也同样进行 3 a 独立样本(1994~1996 年)的预报试验,并且为了客观的对比分析,神经网络集成预报所采用的网络结构、参数在 3 a 的独立样本试验预报中,与前面根据 29 个样本(1965~1993 年)建立的集成预报模型一致。这样就使得独立样本的预报试验与实际预报是类似的。表 3 同时给出 1994~1996 年 3 a,神经网络集成预报和 3 个子预报方程的独立样本预报结果。

表 3 各种子预报方程独立样本的预报结果与 ANN 集成预报的比较(南京)

年份	观测值	预报方程(A)		预报方程(B)		预报方程(C)		ANN 集成	
		预报	相对误差(%)	预报	相对误差(%)	预报	相对误差(%)	预报	相对误差(%)
1994	228.9	256.2	11.9	334.2	46.0	366.9	60.2	277.3	21.1
1995	260.0	307.2	18.1	285.6	9.8	288.6	10.9	287.7	10.7
1996	246.0	293.4	19.2	283.2	15.1	286.5	16.4	271.0	10.2
平均			16.5		23.6		29.2		14.0

由表 3 可以看出,神经网络的集成预报对这 3 a 的独立样本预报精度令人满意,3 a 预报结果的相对误差绝对值平均为 14.0%,而 3 个子预报方程相应的预报结果分别为 16.5%,23.6%和 29.2%。3 个子预报方程总共 9 次预报,除子预报方程(A)对 1994 年的预报精度高于神经网络的集成预报和子预报方程(B)对 1995 年的预报精度略好于神经网络的集成预报以外,其余 7 次预报结果误差均明显偏大。3 个子预报方程对 3 a 的独立样本预报相对误差绝对值的平均为 23.1%,其误差水平约比神经网络的集成预报结果大 9%。

#### 4.2 神经网络集成预报与其它集成预报方法的比较

为了进一步分析人工神经网络集成预报模型的性能,再将表 1 中的 3 个子预报方程进行回归、平均和加权集成预报试验。并同样用公式(19)~(21)的 3 种统计评价指标分别对这 3 种集成预报模式作计算分析,其结果见表 4。为了比较,表 4 中还同时给出了拟合精度最高的子预报方程(A)的 3 种统计评价指标。通过表 4 的比较可以看到,回归、加权和平均预报集成方法的 3 种统计量指标均比最好的子预报方程有所改进,这与以往一些集成预报的研究结果是一致的。但是这 3 种集成预报方法的 3 种统计评价指标均明显差于神经网络集成预报模型的计算结果。而在回归集成、平均和加权集成预报 3 种方法之间相比较而言,其总体差异不大,回归集成的效果稍好些,平均和加权集成预报方法十分接近。从总体结果分析可以看出,神经网络的预报集成不仅比子预报方程有较大的改进,也比其它 3 种集成预报方法有明显提高。当然,表 4 的统计分析结果主要说明了神经网络集成预报模型对历史样本的拟合精度是优于其它集成预报方法的。而神经网络集成预报模型对独立样本的预报能力与其它集成预报方法的比较也同样是需要更为关注的问题,为此,在表 5 中给出了神经网络集成预报模型及其它集成预报方法对 1994~1996 年,3<sub>a</sub> 独立样本的预报结果对比分析。结果表明,神经网络集成预报模型对 3<sub>a</sub> 独立样本的预报效果最佳,分别比回归、平均、加权集成预报模型的预报相对误差平均下降了 6.8%,9.1% 和 8.9%。而回归集成、平均及加权集成这 3 种方法之间的独立样本预报精度总体差异不大,相对而言回归集成预报方法略好一些。作者进一步利用神经网络的集成预报模型进行了实际预报服务,预报 1997 年南京春季(3~5 月)的降水量为 210 mm,属于正常级,而实况为 228 mm。

表 4 各集成预报方法的统计评价指标比较(南京)

评价指标	ANN 集成	回归集成	平均集成	加权集成	子预报方程(A)
MAPE	0.0913	0.1016	0.1107	0.1098	0.1231
MSE	29.8236	30.5657	33.9825	33.5700	33.6330
MAE	22.4918	23.1240	26.4907	26.1352	27.1821

表 5 各集成预报方法独立样本的预报结果比较(南京)

年份	实况	回归集成	相对误差 (%)	平均集成	相对误差 (%)	加权集成	相对误差 (%)	ANN 集成	相对误差 (%)
1994	228.9	291.6	27.4	319.1	39.4	317.7	38.7	277.3	21.1
1995	260.0	304.5	17.1	293.8	13.0	294.3	13.2	287.7	10.7
1996	246.0	290.1	17.9	287.6	16.9	287.8	17.0	271.0	10.2
平均			20.8		23.1		22.9		14.0

以上采用南京春季降水量作为预报对象,从多方面对神经网络的集成预报模型进行了比较分析,其结果均表明,神经网络的集成预报模型具有更好的拟合和预报精度。但是,由于旱涝长期预报的实际预报检验需要较长的时间,且独立样本的预报个例不多,用人工神经网络方法进行集成预报研究也是一种新的尝试。因此,这里再进一步将苏州春季(3~5 月)降水量作为预报对象,采用与以上相同的方法,首先建立 500 hPa 月平均高度场预报因子的预报子方程以及海温场、混合预报因子等 3 个子预报方程(见表 6)。以这 3 个子

预报方程为基础, 再分别建立神经网络的集成预报模型及回归、平均和加权集成预报。同样以 1994 ~ 1996 年样本作为预报检验的独立样本。表 7 给出了由公式(19) ~ (21) 计算得到的神经网络集成预报模型、回归集成、平均和加权集成及 3 个子预报方程各自 3 个统计量评价指标。其结果仍然可以十分清楚地看出, 用人工神经网络方法作预报集成可以很好地综合各种子预报方法的预报信息, 使得集成预报模型比子预报方法有了十分明显的改进。其优越性也显著地好于回归、平均和加权集成预报的效果。再进一步同样采用类似于 C. Kung<sup>[6]</sup> 提出的“刀切法”, 将各种子预报方法、回归、平均和加权集成预报方法以及神经网络集成预报模型, 分别对 1994 ~ 1997 年的独立样本预报结果进行了比较分析(见表 8)。结果发现, 人工神经网络集成预报模型对 4 a 独立样本的预报精度最高, 并且由表 8 可以看到, 回归集成预报以及平均和加权集成预报方法对独立样本的预报精度比子预报方法提高并不十分显著。而神经网络集成预报模型的预报精度平均而言比各个子预报方法及其它集成预报方法均有明显提高。当然, 这也是总体平均情况, 对于个别年份, 如 1996 年, 回归集成和神经网络集成预报模型的预报效果也有不如子预报方程及平均和加权集成预报方法的情况。

表 6 各个子预报方程(苏州)

回 归 方 程	复相关系数 (R)
$\hat{y}_1 = -309.33 - 0.47x_2 + 0.41x_3 + 1.13x_8 + 2.28x_{10} + 0.62x_{12} + 0.53x_{13}$ (E)	0.9074
$\hat{y}_2 = -503.05 + 1.38x_4 - 0.65x_5 + 0.34x_6 + 0.54x_7 - 0.47x_{10} + 0.54x_{11}$ (F)	0.7903
$\hat{y}_3 = 179.58 + 0.33x_2 + 0.34x_4 + 0.42x_6 - 1.15x_7 - 1.73x_9 + 0.54x_{12}$ (G)	0.8408

表 7 统计评价指标的比较(苏州)

评价指标	ANN 集成	回归集成	平均集成	加权集成	子方程(E)	子方程(F)	子方程(G)
M A P E	0.0661	0.0759	0.0807	0.0815	0.0823	0.1092	0.1060
M S E	77.6061	87.0819	101.1355	101.6062	96.1457	140.1688	123.8518
M A E	57.9271	68.3159	74.7917	75.5752	75.5838	102.3176	98.8683

表 8 独立样本的预报结果比较(苏州)

方法与实况	1994 年		1995 年		1996 年		1997 年		平均相对误差 (%)
	预报	相对误差 (%)	预报	相对误差 (%)	预报	相对误差 (%)	预报	相对误差 (%)	
ANN 集成	278.24	18.7	365.85	-6.9	314.60	45.6	211.83	13.3	21.1
回归集成	293.26	27.7	344.54	12.3	315.33	45.9	282.09	50.9	34.2
平均集成	312.76	33.4	338.61	13.8	294.47	36.3	304.54	62.9	36.6
加权集成	312.95	33.5	338.06	-14.0	293.58	35.9	304.91	63.1	36.6
子方程(E)	281.42	41.4	336.20	-14.5	311.83	44.4	267.44	43.0	35.8
子方程(F)	336.13	43.4	352.91	-10.2	298.94	38.4	328.96	75.9	41.9
子方程(G)	320.74	36.8	326.71	-16.9	272.65	26.2	317.22	69.6	37.4
实 况	234.39		393.00		216.00		186.99		



从以上苏州春季降水量的神经网络集成预报模型进一步的综合对比分析可以发现,该集成预报模型的总体效果与南京春季降水量的神经网络集成预报模型是十分相似的。研究结果均表明,用人工神经网络方法进行旱涝长期预报的预报集成,无论是历史样本的拟合效果或者是对独立样本的预报精度均明显优于供预报集成的各个子预报方程和回归、平均、加权等集成预报方法。并且,在神经网络的集成预报建模过程中,没有人为地确定各个子预报方法的集成预报权重系数,因此这种预报集成是比较客观的。同时,由前面的计算过程知道,本文在利用南京和苏州春季降水量的神经网络集成预报模型进行独立样本的预报试验时,网络模型的结构参数均保持不变,这完全类同于实际预报。因而这为采用人工神经网络进行集成预报的业务应用提供了可能。

## 5 小 结

在大气科学的长、中、短期天气预报中,很多都涉及到多种预报结果的综合意见问题,因此,开拓新的集成预报方法对近代天气业务预报和研究具有重要的实际意义,尤其对于目前仍较多地依赖于统计预报方法的长期预报问题。本文采用神经网络进行了集成预报的有益尝试,其结果无论是历史样本的拟合情况或独立样本试验预报以及实际预报结果,确是令人鼓舞的。由于人工神经网络方法具有较好的自适应学习能力和非线性映射能力,因此,利用前馈网络模型在多种预报子方程与最终预报值之间建立了一种非线性映射关系,较好地实现了在输入和输出之间的非线性识别和推广能力,并且这样的预报集成避免了使用常规集成预报难以确定权重系数的困难问题。然而,本文在进行神经网络的集成预报建模时,对网络模型的学习矩阵是采用梯度下降法来进行学习训练,这有时会出现误差函数收敛于局部最小点附近,或产生振荡问题。该问题不仅与预报系统本身的非线性复杂程度有关,同时也与所取的网络模型结构和参数有关,目前在理论上对此问题尚没有很好的解决。本文主要是通过误差函数收敛的图示分析及调整网络的拓扑结构来进行集成预报模型的调试。为此,作者正在考虑采用进化计算的遗传算法对此作进一步的深入研究。

## 参考文献

- 1 Leslie L M, Holland G J. Predicting regional forecast skill using single and ensemble forecast techniques. *Mon Wea Rev*, 1991, 119(2): 425—435
- 2 勒蕃, 范俊波, 谭永东. 神经网络与神经计算机. 成都: 西南交通大学出版社, 1992. 146 ~ 157
- 3 Mccann D W. A neural network short-term forecast of significant thunderstorms. *Weather and Forecasting*, 1992, 7: 525—534
- 4 Jin Long, et al. Comparison of long-term forecasting of June-August rainfall over Changjiang-Huaihe valley. *Advances In Atmospheric Sciences*, 1997, 14(1): 87—92
- 5 Jin Long, et al. Study on mixed model of neural network for farmland flood/drought prediction. *Acta Meteorological Sinica*, 1997, 11(3): 364—373
- 6 Kung C, Sharif A. Long-range forecasting of Indian summer monsoon onset and rainfall with upper air parameters and surface temperature. *J meteor Soc Japan*, 1982, 60(2): 672—681

# STUDY AND COMPARISON OF ENSEMBLE FORECASTING BASED ON ARTIFICIAL NEURAL NETWORK

Jin Long    Chen Ning

*(Jiangsu Research Institute of Meteorological Science, Nanjing, 210008)*

Lin Zhenshan

*(Department of Atmospheric Sciences, Nanjing University, Nanjing, 210093)*

## Abstract

In terms of an artificial neural network(ANN), an ensemble forecasting for a number of submodels of the same predictand is established, and consensus forecast expressions of the regressing, average and weighted mean are formulated with the aid of the same submodels. Results show the ANN is superior in fittings and predictions compared to the submodels and other consensus forecast due to its self-adaptive learning and non-linear mapping. The ANN's ensemble forecasting is easy application in such a way to ascertain weighting coefficient, thus providing a new line for the research of prediction integrated on long-term forecasting of flood and drought.

**Key words:** Neural network, Consensus forecast, Long-term forecasting, Comparative analysis.