

# 基于前传式网络逼近的太平洋副热带 高压活动的诊断预测\*

张 韧

(解放军理工大学气象学院海洋气象教研室, 南京 211101)

**摘 要** 基于前传式神经网络 BP 算法 (Backpropagation Neural Network) 和回归模型, 探讨了西太平洋副高面积指数同赤道东太平洋海温及赤道纬向风之间非线性分类和映射逼近的建模方法和效果比较。结果表明, 前传式网络, 特别是回归网络预报模型具有较好拟合精度和预报效果及比较实用的预报时效。

**关键词:** 前传式网络; 回归模型; 副热带高压

## 1 引言

西太平洋副高是一个重要且复杂的天气系统, 它的进退活动和异常对夏季东亚地区的天气气候和旱、涝灾害有密切的关系, 对它的预报一直是人们非常关心, 但尚未取得满意结果的课题。目前, 在长期天气和短期气候预测中, 统计方法仍是主要的研究手段, 由于常规统计模型的预报方法是建立在线性相关基础之上的, 因此在处理复杂的非线性问题时有一定的局限性。其他的一些气候预测方法, 如模糊数学方法、灰色系统理论、动力-统计模型以及各种集成预报方法<sup>[1]</sup>, 其预报效果也并不十分理想。通过计算观测资料时间序列中的分数维、李雅普洛夫指数和 Renyi 熵, 可以大体确定系统的独立变量维数、系统的复杂性及可预报时效<sup>[2,3]</sup>。但这种方法只能使我们了解系统的复杂性和稳定性以及所研究系统大致的可预报时效, 尚不能直接用于预报。

人工神经网络技术近年来得到了很快发展和广泛应用, 它是由人工建立的以有向图为拓扑结构的非线性动力系统, 通过对连续或者断续的输入作状态响应而进行信息处理<sup>[4]</sup>, 其特色在于信息的分布式存储和并行协同处理, 人工神经网络系统具有集体运算能力和自适应的学习能力, 可实现函数逼近、数据聚类、优化计算、模式识别和非线性预测等功能。基于前传多层网络算法的神经网络模型, 能够在相当精度上逼近任意非线性映射和复杂动力系统, 这一点在数学上已得到了严格的证明<sup>[5]</sup>, 大气科学中也有不少利用神经网络模型进行预报的应用研究<sup>[6,7]</sup>。

本文拟基于人工神经网络 BP 算法和回归模型, 研究和探讨利用观测资料诊断和预测西太平洋副高活动的途径方法, 建立它同环境影响因素的映射关系和预报模型, 并对网络模型的理论依据、模型拟合精度和预报效果以及它与统计回归方法的比较等问题进

1999-12-08 收到, 2000-06-21 收到再改稿

\* 国家自然科学基金资助项目 49975012 及空军司令部气象局 (司气字第 45 号) 共同资助

行讨论。

## 2 多层前传式网络

在神经网络模型中, 多层前传网络是应用最为广泛的一种。它具有 3 个基本特征: 多层结构、S 型神经元特性和回传学习算法。考虑图 1 所示的广义多层前传网络结构, 网络除输入输出节点外, 还有一层或多层的隐层节点, 同层节点间无任何联结。输入数据  $x_1, x_2, \dots, x_n$ , 从输入层节点依次经过各隐层节点到达输出节点, 从而得到输出数据  $y_1, y_2, \dots, y_m$ 。  $w_j$  表示输入层到隐层第  $j$  个神经元的权值向量,  $v_j$  表示从隐层第  $j$  个神经元到输出层的权值,  $j=1, 2, \dots, q$ ,  $q$  为隐层神经元数。由于同层节点间无任何耦合, 故每层节点的输出只影响下一层节点的输出, 每个节点表示单个神经元, 其对应的传递函数通常为 Sigmoid 型函数。

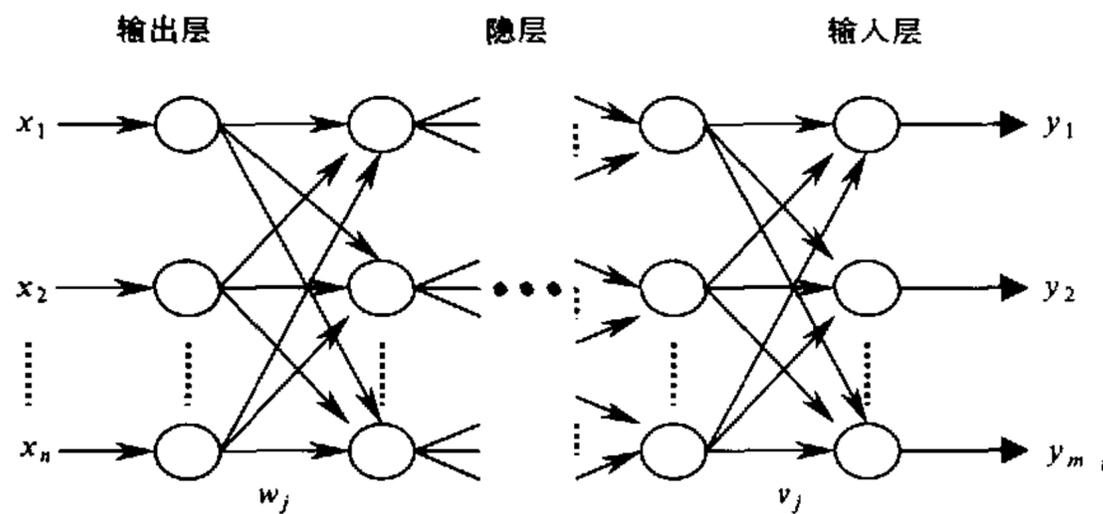


图 1 多层前传式网络结构示意图

对于样本集合: 输入  $x_i \in S^n$  和输出  $y_i \in R^m$ , 假定存在某种函数关系  $g$  (这种函数关系往往是未知的和非线性的), 使得  $g(x_i) = y_i, i = 1, 2, \dots, M$ , 其中  $M$  为样本数。定理 1、定理 2<sup>[8]</sup>表明, 可以找到一个高度非线性映射  $f: f(X) = Y, S^n \rightarrow R^m$ , 使得某种意义上,  $f$  是  $g$  的最佳逼近。定理 1 (Kolmogorov 定理): 给定任一连续函数  $f: S^n \rightarrow R^m$ ,  $f$  可精确用一个 3 层前向神经网络实现。网络第 1 层 (输入层) 有  $n$  个神经元, 中间层  $2n+1$  个神经元, 第 3 层 (输出层) 有  $m$  个神经元。定理 2: 给定任意  $\varepsilon > 0$ , 对于任意的  $L_2$  型连续函数  $f: S^n \rightarrow R^m$ , 存在一个 3 层前传神经网络, 它可以在任意  $\varepsilon$  平方误差精度内逼近  $f$ 。

图 1 所示的多层前传网络通过对简单的非线性函数进行数次迭代复合, 可映射逼近复杂的非线性函数和复杂动力系统。

## 3 副热带高压分类和映射的 BP 模型

BP 网络 (Backpropagation Neural Network) 是一种单向传播的多层前传神经网络

络, 训练学习采用误差反传算法。BP 网络结构简单、状态稳定、计算条件易于满足, 适合于复杂数据结构的分类问题和非线性映射逼近。

### 3.1 太平洋副高活动的影响因子

符淙斌等人研究发现<sup>[9]</sup>, 西太平洋副热带高压的强度和西伸程度与热带太平洋海温 (SST) 距平之间存在着明显的时滞耦合振荡, 赤道东太平洋海温增高 (降低) 时, 西太平洋副高就会增强 (减弱), 两者之间最大的滞后相关为 6 个月左右。陈烈庭<sup>[10]</sup>、藏恒范<sup>[11]</sup>等也陆续发现和揭示出了低纬东、西太平洋海温同太平洋副高之间存在的许多相关特征和影响机制。由于西太平洋副高是中、低纬天气系统, 因此近赤道环流与它亦有着密切的联系, 统计分析发现, 月平均的赤道东太平洋、西太平洋和赤道印度洋地区的纬向风变化同西太平洋副高面积指数的月变化之间均存在 3~6 个月的较为显著的时滞相关性。

### 3.2 资料选取

研究资料为 NCEP/NCAR 再分析计划及 COADS 的 1958 年 1 月~1985 年 12 月全球月平均海温时间序列和 850 hPa 纬向风时间序列。预报对象为中央气象台长期天气预报组提供的范围为 110~180°E; 10°N 以北区域的西太平洋副热带高压 500 hPa 月平均面积指数 (记为 subH); 预报因子为: (1) 赤道东太平洋 (180~90°W, 10°S~0° 海区范围平均) 的 SST 距平值 (记为 SSTe); (2) 赤道西太平洋 (120~180°E, 10°S~0° 海区平均) 的 850 hPa 纬向风距平值 (记为 Usw); (3) 赤道东太平洋 (180~90°W, 10°S~0° 海区平均) 的 850 hPa 纬向风距平值 (记为 Use); (4) 赤道印度洋 (60~120°E, 0~10°N 海区平均) 的 850 hPa 纬向风距平值 (记为 Uid)。为便于模型建立和预报效果比较, 将数据资料分为独立的两部分: 第一部分用于模型的建立, 所取数据为 1958 年 1 月~1977 年 12 月共 20 年 240 个月; 第二部分用于模型的检验和预报效果的评估, 所取数据为 1978 年 1 月~1985 年 12 月共 8 年 96 个月。

根据时滞相关分析, 取 1958 年 1 月~1977 年 9 月期间共 237 个月的赤道纬向风 (Usw、Use、Uid) 和赤道东太平洋海温 (SSTe) 作为模型的控制和预报因子, 取滞后预报因子 3 个月 (1958 年 4 月~1977 年 12 月时段) 的太平洋副高指数 (subH) 为网络模型的逼近和预报对象。第二部分资料亦作同样的时滞处理。

上述选择不仅使网络模型的映射关系有比较明确的相关依据, 而且由于预报因子超前预报对象 3 个月, 因此所建立的网络模型具有比较实用的预报意义。

### 3.3 网络结构和模型设计

网络模型的建立过程, 是通过将预报因子输入序列和预报对象输出序列之间对应关系的反复学习和训练, 不断调整网络模型输入层与隐层、隐层与输出层之间的连接权值和阈值, 找出其传递函数的最佳权值矩阵和阈值矩阵, 从而建立起两者之间的映射关系。采用 3 层 BP 网络结构及其优化算法。网络输入层同隐层之间的神经元连接采用可微的 sigmoid 型单调递增传递函数 logsig, 隐层同输出层之间神经元的连接采用线性传递函数 purelin。

### 3.4 分类模型建立

首先, 对副高面积指数进行分类划分, 取距平值介于 0 和 10 之间的数据为  $T[1; 0]$  类, 距平值大于等于 10 的为  $T[1; 1]$  类, 距平值介于 0 和 -10 之间的数据为  $T[0; 1]$

类, 距平值小于等于-10 的为  $T[0; 0]$  类。  $T[1; 0]$  表示高于平均水平的副高指数偏强状态,  $T[1; 1]$  表示远大于平均水平的副高指数异常偏强状态,  $T[0; 1]$  表示低于平均水平的副高指数偏弱状态,  $T[0; 0]$  表示远低于平均水平的副高指数异常偏弱状态。这样将副高指数的预测问题转化为对副高活动 4 种状态的识别、分类和判断问题。

然后对数据资料作标准化处理, 输入目标 (预报因子), 取 SSTe、Use、Usw 和 Uid 时间序列距平的当前值和其延后的 3 个值, 共计  $4 \times 4 = 16$  个输入值 (神经元), 输入矩阵  $P$  是一个  $16 \times 237$  阶矩阵; 输出目标 (预报对象) 为滞后 3 个月的副高面积指数时间序列的分类矩阵  $T$ , 每一时次有 2 个输出值 (神经元), 代表一种状态, 预报目标矩阵  $T$  是一个  $2 \times 237$  阶矩阵。

取隐层神经元  $S_1 = 20$ , 网络学习、训练、仿真的计算程序采用 Matlab 语言自己编写, 在 PII-266 型微机上运算实现。

### 3.5 拟合状况和分类效果:

图 2 是采用 BP 网络的动量-自适应学习率调整算法 (记为 BPx) 进行 5000 次训练迭代后所建立的网络分类模型的计算值与实际值的比较。可以看出, 两者间具有较好的拟合程度, 大多数时段识别和分类正确, 识别正确率在 96% 以上, 除个别点外, 拟合误差基本控制在 10% 以内。这表明, 网络模型比较准确地建立起了输入因子和目标对象之间的拟合映射关系。图 3 是基于所建网络分类模型, 用独立的第二部分资料对滞后

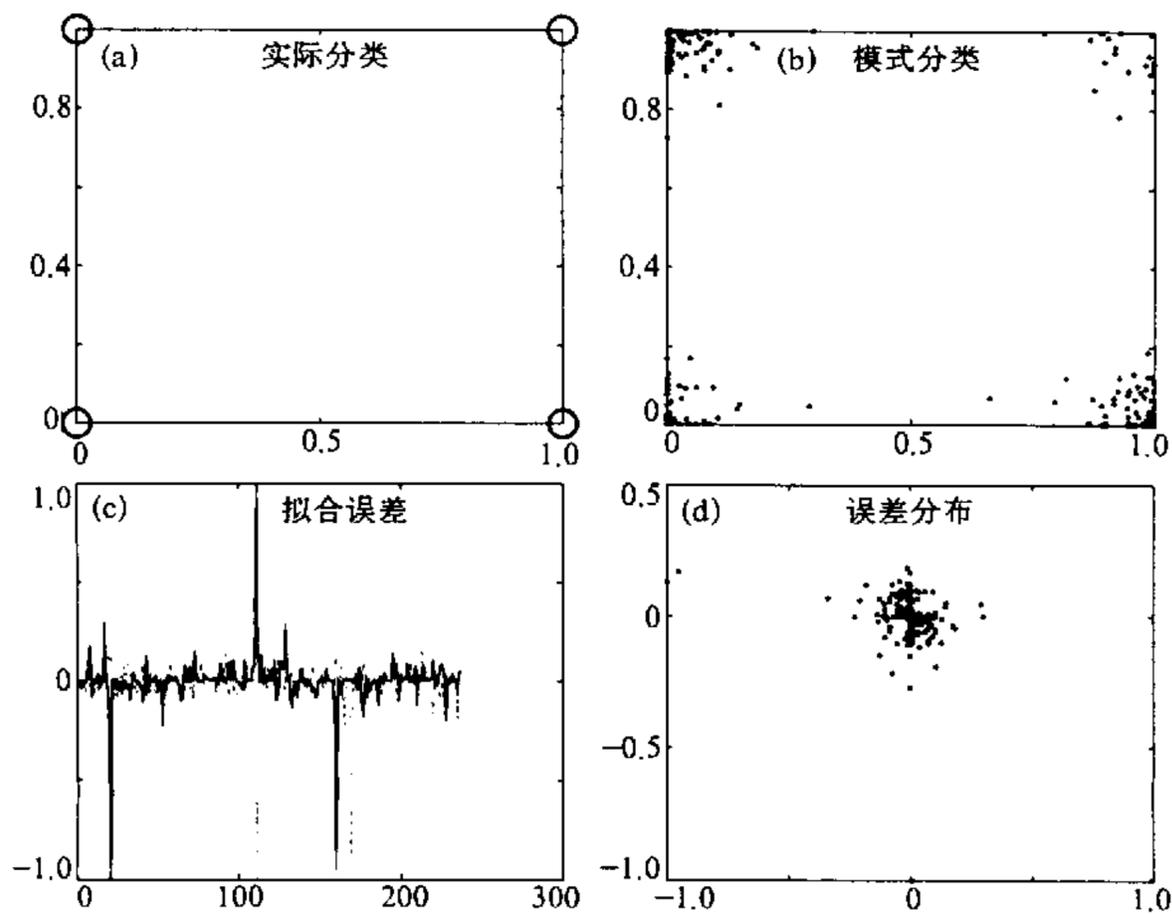


图 2 BP 网络分类模型拟合效果

(a) 实际分类; (b) 模式分类; (c) 拟合误差; (d) 误差分布  
(a)、(b)、(d) 为分类  $T$  的坐标结构, (c) 横轴为拟合时段, 纵轴为误差,  
拟合时段为 1958 年 4 月~1977 年 12 月, 共 237 个个例

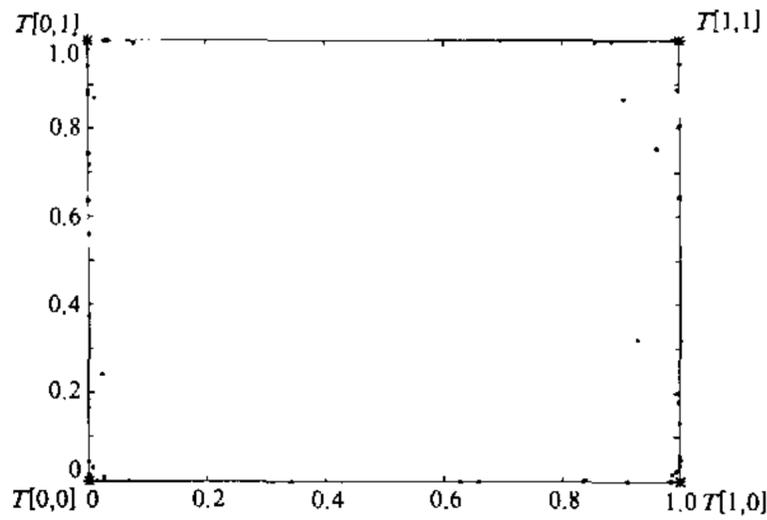


图3 BP网络分类模型预报效果。  
四个顶点：实际分类；圆点：预测分类；  
预报时段1978年4月~1985年12月，共93个个例

3个月的副高活动类型所作的分类预测。从图3的分类预报结果和误差分析(图略)中,大致可以看出这样的特点:多数的预报分类点聚集在图中代表四种实际分类的顶角点( $T[0,0]$ ,  $T[0,1]$ ,  $T[1,1]$ ,  $T[1,0]$ )附近,表明多数预测点能够正确识别和接近实际分类区域。在偏离四种标准类型的预测点中,少数分布在 $T[0,0]$ 至 $T[1,0]$ 之间(大约5个,表示处于副高异常偏弱和基本偏强状态之间)和 $T[0,1]$ 至 $T[1,1]$ 之间(约有4个,表示处于副高基本偏弱和异常偏强状态之间),属于性质识别错误;多数处于 $T[0,1]$ 至

$T[0,0]$ 之间(表示处于副高基本偏弱和异常偏弱状态之间)和 $T[1,0]$ 至 $T[1,1]$ 之间(表示处于副高基本偏强和异常偏强状态之间),属于性质识别基本正确,程度识别不足的情况。上述模型的独立分类预报结果虽然还比较松散粗糙,但大部分预报结果对于副高活动的主要性质分类和识别大体能够把握,因此有一定的参考借鉴意义。

### 3.6 副高指数时间序列的映射逼近和预测

基于所选数据和BP网络模型,直接对副高指数进行非线性映射逼近和系统预测。采用BP网络动量自适应算法训练迭代5000次后所建立的BP网络映射模型,其计算值同实际值之间达到了较高的拟合精度(相关系数 $r=0.8486$ )。图4是该网络映射模型基于第二部分资料所作的独立预测。图中可见,预报结果在细节描述上尽管还不够完善,但实际副高指数变化的主要趋势和大部分升降、转折过程基本上能够正确表现,预测值同实际值的相关系数为 $r=0.6267$ 。

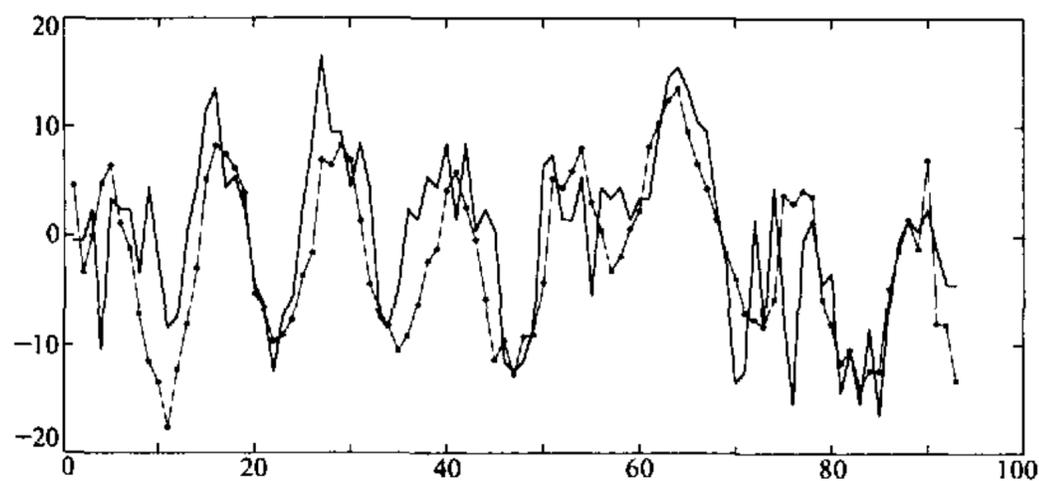


图4 BP网络映射模型预报效果  
横轴为预报时段1978年4月~1985年12月,计93个个例(单位:月),纵轴为副高面积指数距平值  
实线:实际值;点线:预报值

### 4 基于回归网络算法的副热带高压预报模型

BP 网络是当前应用最广的一种神经网络模型, 副高分类、逼近的 BP 网络模型尽管有一定的拟合精度和预报效果, 但距实用尚有一定距离。究其原因, 除预报对象(副高)本身比较复杂外, BP 网络本身也存在一些局限性, 如学习、训练速度慢, 不易摆脱误差曲面中的局地小值区域等等。此外, 普通 BP 网络还有一个固有的缺陷: 尽管它的神经元具有 S 型非线性特性, 但其输入输出基本上是一个静态映射结构, 对于一般动力系统而言, 动态特性是最基本的, 而这一点恰恰是普通 BP 网络所欠缺的。

为考虑模型的动态特性和反馈作用, 引入另一神经网络模型-动态回归网络, 图 5 是该网络的结构示意图, 图中  $P$  为实际数据输入,  $D$  为反馈环节输入,  $[w_1, b_1]$  和  $[w_2, b_2]$  分别为输入层至隐层和隐层至输出层之间的权值矩阵及阈值矩阵,  $a_1$  为隐层输出,  $a_2$  为实际输出, 输入层和隐层之间用双曲正切传递函数 (tansig), 隐层至输出层之间采用线性传递函数 (purelin)。回归网络也属前传式网络, 但同 BP 网络相比, 它多了一个反馈环节(图中  $D$ ), 其最显著特点是将输出端信号通过带时延的反馈机构回结到输入端, 因此回归网络在本质上是一个动态系统。

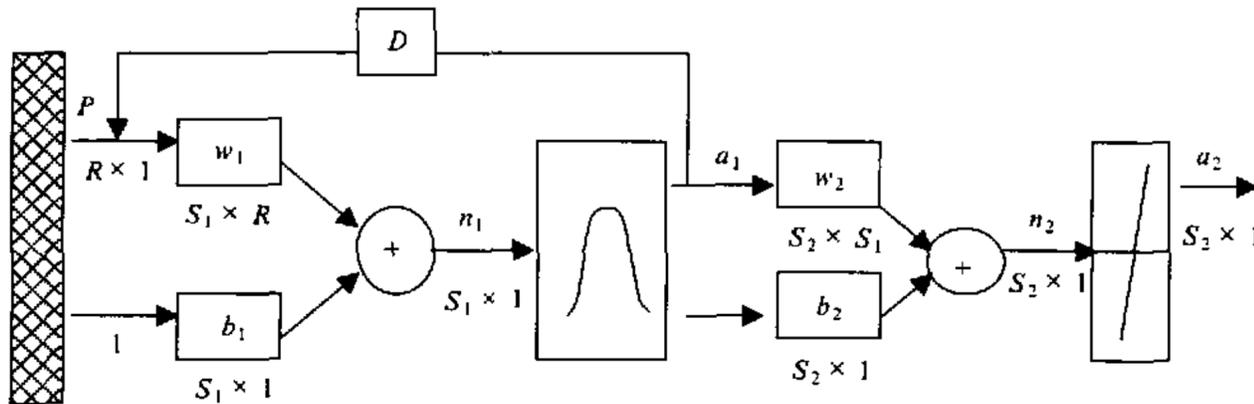


图 5 回归网络结构示意图

$S_1$  为隐层神经元,  $a_1 = \text{tansig}(w_1 \times [P; a_1], b_1)$ ,  $a_2 = \text{purelin}(w_2 \times a_1, b_2)$ ;  
 $R$  为输入样本(预报因子)数,  $n_1, n_2$  为加权后的输入序列

#### 4.1 回归网络的基本算法

回归网络的描述方程可表示为

$$\dot{x}_i = -x_i + \sum_{j=1}^n w_{ij}(t)g[x_j(t)], \quad i = 1, 2, \dots, n \tag{1}$$

其中  $g[x_j(t)] = x_j(t) + a_1[x_j(t)]$ , 为包含了反馈输入  $a_1[x_j(t)]$  和实际输入  $x_j(t)$  在内的数据输入时间序列, 初始反馈输入可表示为  $a_1[x_j(t)] = f(w_{i,j}(t) \cdot x_j(t))$ ,  $w_{i,j}(t)$  为网络权值矩阵,  $f(\cdot)$  为网络传递函数, 通常取双曲正切函数,  $i$  为输入层的数据维数,  $j$  为所取的隐层神经元数目,  $t$  为数据时间序列。显然, 回归过程通过了一个一阶积分环节。

定义网络误差:  $E_k(t) = \frac{1}{2} \sum_{j=1}^n |y'_{k,j}(t) - y_{k,j}(t)|^2$ , 代表第  $k$  个训练矢量的误差,

$y'_{k,j}$  和  $y_{k,j}$  分别是对应于第  $j$  个输入神经元  $x_{k,j}$  的输出期望值和实际输出值,  $k, j$  分别为训练矢量和神经元序号。由最速下降法, 网络神经元的权重调整可表示为<sup>[4]</sup>

$$\frac{dw_{ij}(t)}{dt} = -\eta \frac{\partial E_k(t)}{\partial w_{ij}(t)} \quad (2)$$

权重调整旨在寻找误差曲面的低值点, 学习率  $\eta$  是一个充分小的正数, 以保证网络不至于发散。

若反馈环节的隐层输出为  $x_{k,j}(t)$ , 则  $x_{k,j}(t) = f(n_{k,j})$ ,  $n_{k,j} = \sum_{i=1}^n w_{ij}(t) \cdot g[x_{k,i}(t)]$

采用链式规则:

$$\frac{\partial E_k(t)}{\partial w_{ij}(t)} = \frac{\partial E_k(t)}{\partial x_{k,j}(t)} \cdot \frac{\partial x_{k,j}(t)}{\partial w_{ij}(t)} = \frac{\partial E_k(t)}{\partial n_{k,j}} \cdot \frac{\partial n_{k,j}}{\partial w_{ij}(t)} \quad (3)$$

则

$$\frac{\partial n_{k,j}}{\partial w_{ij}(t)} = \begin{cases} g[x_j(t)], & k=i \\ 0, & k \neq i \end{cases} \quad (4)$$

网络权重的修正公式为

$$\frac{dw_{ij}(t)}{dt} = -\eta \frac{\partial E_k(t)}{\partial n_{k,j}} \cdot g[x_j(t)] \quad (5)$$

类似于 BP 算法的处理, 误差信号项可表示为<sup>[4]</sup>

$$\frac{\partial E_k(t)}{\partial n_{k,j}} = \begin{cases} (y'_{k,j} - y_{k,j})f(n_{k,j})[1 - f(n_{k,j})], & \text{对于输出层} \\ f(n_{k,j})[1 - f(n_{k,j})]\sum_i \delta_{k,i} w_{ij}, \dots, & \text{对于隐含层} \end{cases} \quad (6)$$

$\delta_{k,i}$  为误差范围。数值计算时, 可采用差分形式:

$$\Delta w_{ij}(k) = -\mu \frac{\partial E_k(k)}{\partial n_{k,j}} \cdot g[x_j(k)] \quad (7)$$

在  $k$  时刻, 网络权重值为

$$w_{ij}(k) = w_{ij}(0) - \mu \sum_{l=0}^k \frac{\partial E_k(l)}{\partial n_{k,j}} \cdot g[x_j(l)] \quad (8)$$

这里  $\mu > 0$  为学习步长, 它从某一初始权值矢量开始, 反复输入训练模式样本序列, 不断迭代, 直至误差权值使得输出误差限定于规定范围之内, 这即是多层前传回归网络的基本算法。

#### 4.2 回归网络模型的拟合精度与预报效果

选择与 BP 网络模型相同的资料选取和处理方法, 在图 5 所示回归网络结构中取隐层神经元  $S_j = 30$ , 直接对副高面积指数的时间序列进行回归网络模型的非线性映射逼近和预测, 计算程序用 Matlab 语言自己编写, 在 PII 型微机上运算实现。图 6 是进行 500 次训练迭代后所建立的副高回归网络模型的计算值与实际值之间的拟合效果比较。

可以看出, 两者间达到了很好的拟合程度, 模型对副高指数的主要变化趋势和基本转折以及对局部细节均有细致的描述, 拟合相关系数达 0.9811, 拟合误差大体控制在 5% 以内, 回归网络较好地建立起了预报因子和预报对象之间的拟合映射关系。图 7 是所建回归网络基于第二部分数据资料所作的独立预测与实际情况的对比, 预报结果 (点线) 对实际副高指数 (实线) 时间序列的总体趋势预测基本上能够较好地把握, 大部分升降、转折过程和一些细节变化也基本上表现正确, 预报值与实际值的相关系数达到 0.6942, 较 BP 网络模型的预报效果有比较明显的提高, 基于 3 个月的预报时效, 所建回归网络预报模型可以认为具有一定的实用参考意义。

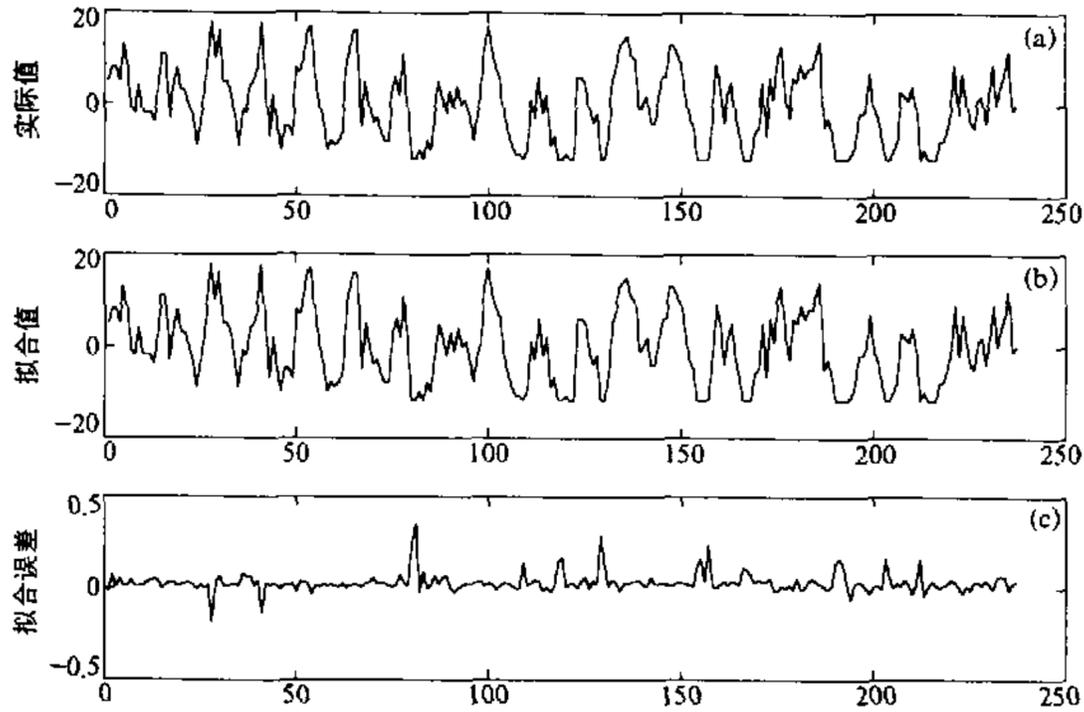


图 6 回归网络模型拟合效果

(a) 实际值; (b) 拟合值; (c) 拟合误差

横轴为拟合时段 1958 年 4 月~1977 年 12 月, 计 237 个个例 (单位: 月),

纵轴为副高面积指数距平值((a)、(b)) 和误差值((c))

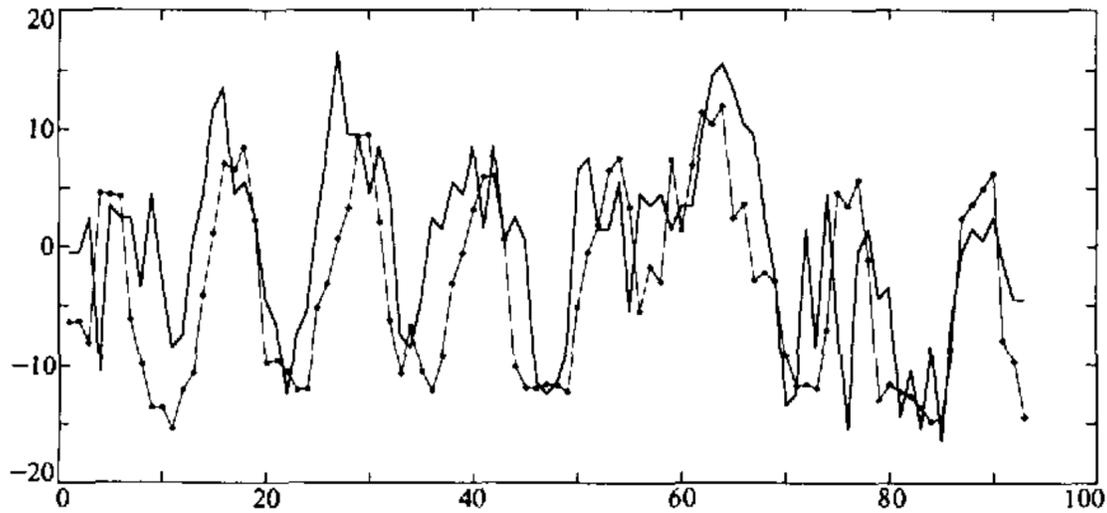


图 7 回归网络模型预报效果

横轴为预报时段 1978 年 4 月~1985 年 12 月, 计 93 个个例 (单位: 月), 纵轴为副高面积指数距平值,

实线: 实际值, 点线: 预报值

## 5 统计回归方法的预报效果比较

统计回归是气象资料分析和要素预测中常用的方法。为评估和比较神经网络方法的预报效果,我们对数据资料作完全相同于网络模型的选择和处理,用逐步回归方法建立了副高面积指数的统计回归预报模型。该统计回归模型时间序列的计算值同实际值的拟合相关系数  $r$  为 0.7783,拟合效果低于回归网络模型和 BP 网络模型。图 8 是统计回归模型的独立时段预报结果,其预报值相对而言过于平滑,对细节和小扰动的描述同样表现欠佳,尤其对峰、谷预测的逼近幅度表现不到位,但预报结果对副高时间序列总的变化趋势和几个主要的升降起伏过程大体上能够正确识别和描述,预报值同实际值的相关系数  $r=0.6189$ 。与图 4 的 BP 网络模型 ( $r=0.6267$ ) 和图 7 的回归网络模型 ( $r=0.6942$ ) 的预报效果相比较, BP 网络方法与统计回归方法的预报效果比较接近,相对而言,回归网络方法对预报对象的总体把握和描述较前两者要略为恰当和准确一些。

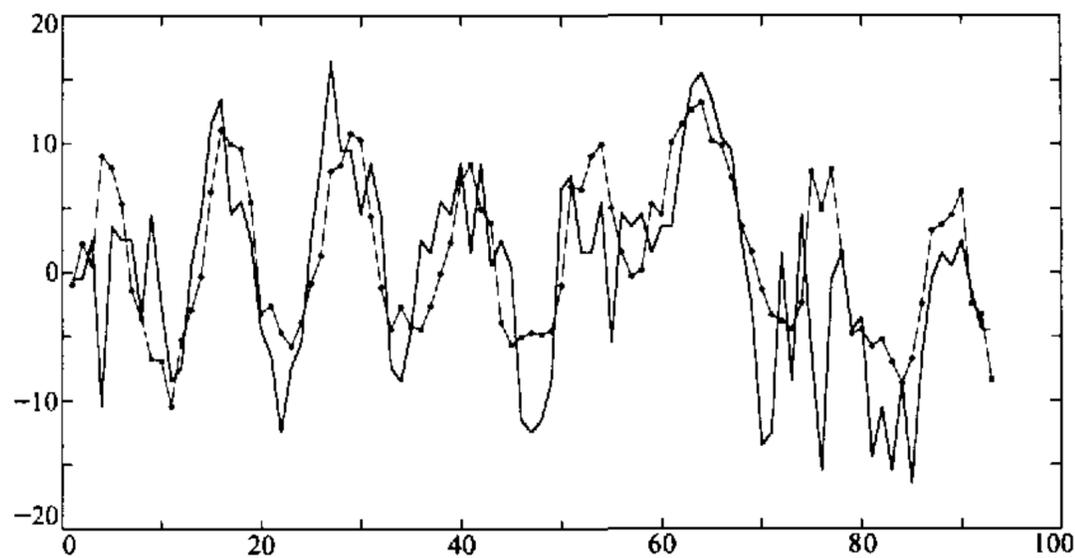


图 8 统计回归模型预报效果

横轴为预报时段 1978 年 4 月~1985 年 12 月,计 93 个个例(单位:月),纵轴为副高面积指数距平值,实线:实际值,点线:预报值

## 6 小波去噪对预报效果的改进

上述几种方法均存在共同的问题,即预报结果对局部扰动细节的描述效果欠佳,存在位相偏移,对峰、谷幅度的表现不够等。其原因,除模型本身的局限性外,预报对象过于复杂也是一个重要因素。实际上,从长期天气和气候意义上看,对副高活动的预测主要是关心其强、弱变化和异常的主要趋势,相对而言,一些幅度较小的扰动本身并没有太大的预报意义。因此,设法滤除这些小扰动既可降低网络模型的训练难度和计算量,也利于提高预报效果。传统的统计平滑方法在滤波过程中对信号的频率结构会有所破坏,其结果是在降低噪声的同时也展宽了波形,平滑掉了信号中某些可能携带重要信息的锐变峰谷成分和突变点。由于数据信号的性质可以用其小波系数来描述刻画:小波

系数较大(小)者, 携带的信号能量较多(少), 因此根据实际情况, 确定适当的小波系数阈值, 滤除阈值以下的低值信号, 这样既滤除了低能量的噪声, 又保留了高能量的主要信号。上述原理的非线性小波去噪具有两个主要特点<sup>[12]</sup>: (1) 可加性噪声几乎可完全消除; (2) 去噪后的信号可保留原信号中大部分陡峭锐变的曲线轮廓。

基于上述考虑, 我们先对预报对象(副高面积指数)进行非线性小波去噪, 作适当的平滑处理, 然后按照前述回归网络模型相同的建模过程, 资料处理和计算程序, 建立改进后的回归网络预报模型。图 9a 可以清楚看出, 小波去噪除对实际值的一些弱小扰动作了适当平滑外, 基本上保持了实际值主要的特征和大部分的陡峭锐变趋势, 两者相关系数为 0.9665, 因此用后者代替前者作为预报对象是合理可行的。图 9b 可以看出预报效果有了较大幅度的改进和提高, 预报值对实际值的逼近和描述更加合理到位, 两者间的相关系数达到 0.8123。改进后的回归网络模型预报值即使与未去噪的实际值相比, 其相关系数也达到 0.7246, 优于前面的各种模型预报效果。

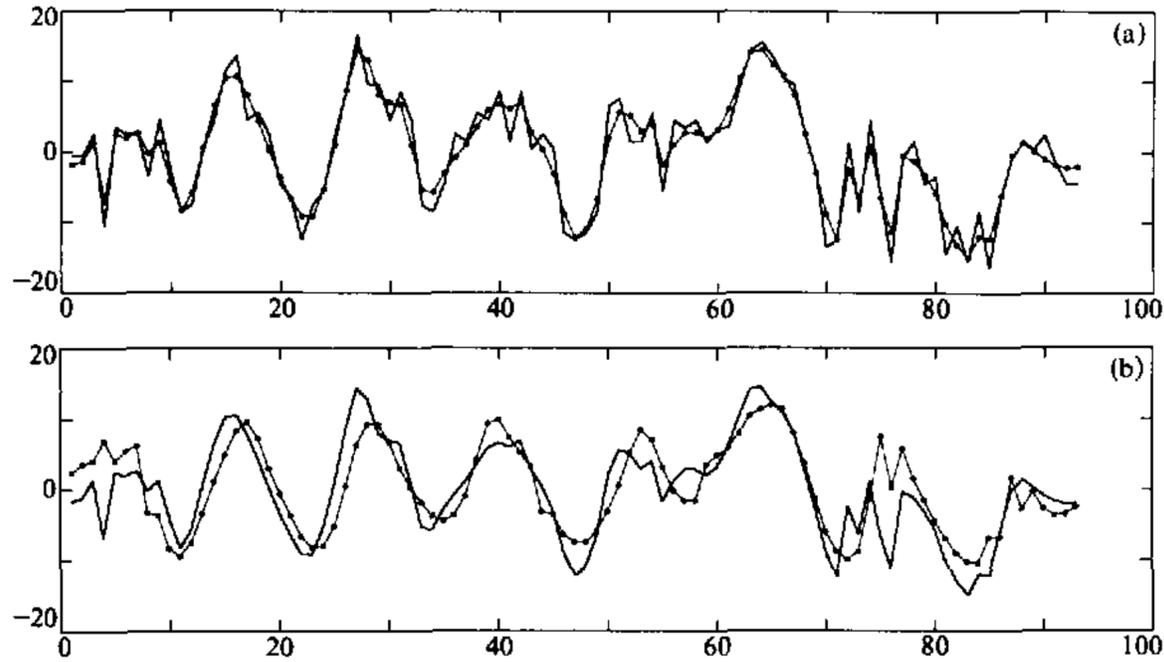


图 9 改进后的回归网络模型预报效果

(a) 副高面积指数的实际值(实线)和小波去噪后的值(点线)的比较; (b) 改进后的回归网络模型的独立预报结果(点线)与去噪后的实际值(实线)的比较

横轴为预报时段 1978 年 4 月~1985 年 12 月, 计 93 个个例(单位: 月), 纵轴为副高面积指数距平值

上述结果表明, 对资料作合理的预处理和简化有利于提高建模效率, 改进预报效果。对 BP 网络模型和统计回归模型, 我们也作了类似计算, 其预报效果均程度不同地有所改进, 但总体效果还是以回归网络模型为佳。

## 7 小结

在西太平洋副高指数的预测中, 基于前传式神经网络模型, 尤其是基于回归网络模型的诊断预测方法是一种比较有效、实用的手段和途径。理论上已证明, 多层前传神经网络模型能够在相当精度上逼近任意复杂的非线性函数和映射<sup>[5]</sup>, 但实际应用中, 要受到许多因素制约, 包括模型设计的好坏、具体算法的运用、数据资料的处理、预报因子

的选择等等。因此,设计更合理的网络模型,更充分地做好数据资料的前期处理和预报因子的优选,将有助于进一步深入挖掘和开发神经网络方法的预报优势和潜力,以达到更高、更准确的预报效率。

### 参 考 文 献

- 1 叶笃正、曾庆存、郭裕福,当代气候研究,北京:气象出版社,1991,164~177.
- 2 严绍瑾、彭永清,非平衡态理论与大气科学,北京:学苑出版社,1993,288~318.
- 3 林振山,非线性力学与大气科学,南京:南京大学出版社,1993,107~153.
- 4 沈清、胡德文、时春,神经网络应用技术,长沙:国防科技大学出版社,1993,3~33,77~86.
- 5 Hornik, K., M. Stinchcombe and H. White, Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks, *J. Neural Networks*, 1990, 3, 551~560.
- 6 金龙等,基于人工神经网络的集成预报方法研究和比较,气象学报,1999,57(2),198~207.
- 7 唐洵昌等,应用天气雷达识别强对流天气的神经网络方法,气象科学,1997,17(4),393~399.
- 8 王士同,神经模糊系统及其应用,北京:北京航空航天大学出版社,1998,38~41.
- 9 符淙斌等,热带海洋对副热带高压长期变化的影响,科学通报,1977,21,313~317.
- 10 陈烈庭,北太平洋副热带高压与赤道东部海温的相互作用,大气科学,1982,6,148~156.
- 11 戴恒范、王绍武,赤道东太平洋水温对低纬大气环流的影响,海洋学报,1984,6(1),16~24.
- 12 赵松年、熊小芸,子波变化与子波分析,北京:电子工业出版社,1997,134~137.

## A Diagnosis/ Prediction of the Movement of the Western Pacific Subtropical High Based on the Neural Network Approximation with Forth-Propagation Style

Zhang Ren

(Institute of Meteorology, PLA University of Science and Technology, Nanjing 211101)

**Abstract** Based on the BP arithmetic and regression model of the neural network with forth-propagation style, discussed are a modeling method and effect comparison of non-linear classification and mapping approximation between the western Pacific subtropical high area index and the equatorial eastern Pacific SST / the equatorial zonal winds. The results show that the neural network models with forth-propagation style (especially, the regression network model) are able to forecast with better fitting-precision and timely forecasting effectiveness.

**Key words:** neural network with forth-propagation style; regression model; subtropical high