

人工神经网络在梅雨期短期降水 分级预报中的应用

段 婧

苗春生

(北京大学大气科学系, 100871)

(南京信息工程大学大气科学系)

提 要

将人工神经网络应用于南京夏季梅雨期短期降水分级预报。根据梅雨期天气特点,用统计和动力学方法从 HLAFS (高分辨率有限区域预报系统)资料中寻找预报因子;然后分别用两种方法选取输入因子对人工神经网络进行训练,并分别利用抽取的五天做降水分级预报检验。通过对人工神经网络方法预报降水的结果与 HLAFS 降水预报以及逐步回归预报的结果对比发现:与 HLAFS 降水预报相比,降水预报准确率由原来的 66.7% 提高到 88.2%,漏报、错报明显减少;与逐步回归预报相比,大到暴雨的预报准确率得到了明显提高。

关键词: 人工神经网络 预报因子 降水分级预报

引 言

江淮梅雨是每年夏初影响长江中下游的重要天气过程^[1],做好梅雨期的降水预报对国民经济及人民生活均有重要意义。

预报实践和预报检验均表明,利用 HLAFS 有限区域模式预报降水实际效果并不理想,错报、漏报情况较多,且准确率不高^[2],这是由于数值预报产品的预报误差特征极其复杂引起的。为了有效利用数值预报产品,人们采用各种释用技术来充分挖掘其中的有用信息,力图提高预报精度。但常用的以经验为主的定性方法存在较大误差;而客观定量预报方法,如传统统计学方法、动力学方法已不能满足日常的预报精度需要^[3]。

人工神经网络方法(ANN)以其独特的优点已广泛应用于长期天气趋势预报中,并取得了一定效果。在短期预报的应用中,曾有利用探空站资料训练 BP 神经网络建立预报模型并进行短期降水预报^[4]以及用 BP 网络进行短期降水量级预报,但总的来讲神经网络在短期预报中的应用尚处起步阶段。人工神经网络擅长处理知识背景不很清楚,模

糊、随机的大通量信息;特别是可以处理非线性系统。并且具有很强的自学习能力和适应能力。正因如此,本文尝试将人工神经网络引入短期降水分级预报,特别是结合了传统统计学方法和动力学方法,以期待达到较好的预报效果。

1 资料和方法

1.1 HLAFS 资料及资料处理

根据 HLAFS 原始资料,利用 2002 年 6 月 1 日 20 时~7 月 30 日 20 时共 60 天的 24 小时预报资料(选取相同日期两个时次的 12 小时预报之和作为 24 小时降水因子,预报时段为当日 20 时至第二日 20 时)选取预报因子;选取范围 $15^{\circ}\sim 64^{\circ}\text{N}$, $70^{\circ}\sim 145^{\circ}\text{E}$;格距为 0.5 经(纬)度,共计 151×99 个格点。内容包括不同层次的涡度、散度、位势高度、温度、温度露点差、风(风向,风加权平均)、相对湿度、垂直速度、地面气压和 12 小时降水预报(详见表 1)。另外选取南京 6 月 2 日 20 时~7 月 31 日 20 时 60 天的 24 小时降水实况资料为预报对象的资料。

由于解压后,原始 HLAFS 资料存在资

料的缺省、精度和范围不足等问题,需对现有的 HLAFS 资料进行扩充和二次处理。产生降水需要充足的水汽和较强的上升运动,因此表征大气湿度的比湿和露点,以及表征水汽辐合辐散的水汽通量散度是与降水密切相

关的重要物理量。对资料进行加工和再处理,以及 HLAFS 原有的物理量产品,我们得到了可以利用的气象资料(详见表 1),为进一步寻找与降水相关密切的预报因子做了必要的准备。

表 1 不同等压面预报物理量的选取和处理结果

层次 hPa	不同等压面物理量资料的选取和处理结果
500	涡度、散度、等压面上的高度、温度、温度露点差、风(风向和风的加权平均)、垂直速度、比湿*
700	涡度、散度、等压面上的高度、温度、温度露点差、风(风向和风的加权平均)、垂直速度、相对湿度、比湿*、地转风*、水汽通量散度*
850	涡度、散度、等压面上的高度、温度、温度露点差、风(风向和风的加权平均)、相对湿度、比湿*、地转风*、水汽通量散度*
地面	地面气压、12 小时降水预报

* :表示经过计算处理得出的物理量,其余未带 * 的是未处理的原始资料内容

1.2 神经网络的基本原理

本文所使用的 BP 神经网络(全称误差逆传播神经网络)在众多神经网络中属于前馈型网络。该网络模型物理概念清晰、通用性好,且具有高度灵活可变的拓扑结构。该网络进行预报的过程主要是通过自学习和训练来完成的。由于网络训练结束后,各节点的权值保持不变,从而具备了对相同或相近输入模式的识别功能。在把一个已经训练好的 BP 网络用于制作天气预报中的分类或分级预报时,只要给网络依次输入预报因子后,经过网络自动识别,其输出层输出值最大一个节点所代表的类型即为将出现的天气类型。这就是 BP 网络自动产生的预报结论。

本文利用统计和动力学方法从 HLAFS 资料中寻找到的预报因子经过分组后作为神经网络学习矩阵的输入的样本,通过网络自学习确定网络预报模型的大量参数,从而得出所需要的降水类型。

2 神经网络输入因子的选取

为了使神经网络预报方法尽快达到预期效果,选取预报因子是极为重要的工作。选取的预报因子应与预报对象有较好的相关性,而且还应具有明确的物理意义。根据一定的降水预报经验和指标,在一定的选取方法下(图 1:单站组合因子选取办法),设计了一些可供选择的初选因子 $X_1 \sim X_{13}$ (表 2)。确定物理意义明确的因子后,利用统计的方

法与预报对象求取相关系数,根据设定的信度,可通过 t 检验和相关系数检验的因子,作为最优预报因子。由检验结果(表 2)可以看出, X_1 、 X_4 、 X_6 、 X_7 、 X_9 、 X_{10} 、 X_{13} 七个因子检验结果可以同时通过至少信度为 0.05 的两种检验,其中 X_1 因子效果最好,可以通过信度为 0.001 的检验。




图 1 单站组合因子选取方法示意图 (中心 O 点为南京,周围取等间距的 8 个点,间隔约 400km)

对比高度场预选因子检验结果发现,利用单站计算的组合因子相关效果不好,而利用高度场平均值组合计算的因子效果明显优于单站组合因子,其中 X_4 、 X_6 、 X_7 优势明显,通过了 0.05 的检验。造成这种结果的原因,可能与单站因子因误差而不能代表区域气压场分布特征有关。而温度、露点组合因子检验结果表明温度组合因子 850hPa 优于 700hPa,露点组合因子 700hPa 优于 850hPa。产生这些较优因子分别各有原因。从通过检验的 500hPa 高度场因子中选取更好的 X_4 、

表2 预选预报因子及检验结果

预选因子	代表符号	物理意义	计算方法(选取因子的方法见图1表中物理量标号与图中标号对应)	相关系数	相关系数检验 α_1	t 检验 α_2
X_1	RAIN	与实况降水直接相关	前日08点的12小时降水预报资料和20点的12小时降水预报资料求和,作为前日20点24小时的预报因子	0.529	0.001	0.001
X_2	Height1	南京地区地转涡度因子	$Height1 = (H_1 + H_3 + H_5 + H_7) - 4 \times H_0$ (H:500hPa高度场)	0.118	-	-
X_3	Height2	东北-西南向500hPa高空槽强度因子	$Height2 = (H_4 + H_8 - 2 \times H_0)$ (H:500hPa高度场)	0.153	-	-
X_4	Height3	表征500hPa高度场(气压场)形势因子	500hPa高度场,取河西走廊西北 $95 \sim 100^\circ E, 40 \sim 45^\circ N$ 和以福州为中心的 $120 \sim 125^\circ E, 25 \sim 30^\circ N$ 的两部分区域分别求高度场的平均值,再相减	0.291	0.05	0.01
X_5	Height4	与 X_4 相同	500hPa高度场,取长江上游 $102 \sim 107^\circ E, 27 \sim 32^\circ N$ 与长江中下游 $118 \sim 123^\circ E, 30 \sim 35^\circ N$ 两部分区域分别求高度场的平均值,再相减	0.183	-	-
X_6	Height5	与 X_4 相同	500hPa高度场,取郑州附近 $110 \sim 116^\circ E, 31 \sim 37^\circ N$ 与长江中下游 $116 \sim 125^\circ E, 25 \sim 34^\circ N$ 两部分区域分别求高度场的平均值,再相减	0.256	0.05	0.05
X_7	Height6	与 X_4 相同	500hPa高度场,取郑州为中心 $110 \sim 116^\circ E, 32 \sim 36^\circ N$ 与以福州为中心 $116 \sim 125^\circ E, 23 \sim 28^\circ N$ 两部分区域分别求高度场的平均值,再相减	0.349	0.01	0.01
X_8	ΔT_{700}	等温线密集带对应地面锋面	$\Delta T = (T_6 + T_7 + T_8) - (T_4 + T_3 + T_2)$ (T:700hPa温度)	0.214	0.1	0.1
X_9	ΔT_{850}	与 X_8 相同	$\Delta T = (T_6 + T_7 + T_8) - (T_4 + T_3 + T_2)$ (T:850hPa温度)	0.333	0.01	0.01
X_{10}	ΔT_{D700}	表征大气饱和程度,与降水密切相关	$\Delta T_D = (T_{d6} + T_{d7} + T_{d8}) - (T_{d4} + T_{d3} + T_{d2})$ (T:700hPa露点)	0.319	0.02	0.01
X_{11}	ΔT_{D850}	与 X_{10} 相同	$\Delta T_D = (T_{d6} + T_{d7} + T_{d8}) - (T_{d4} + T_{d3} + T_{d2})$ (T:850hPa露点)	0.171	-	-
X_{12}	WP700	负值越大表示南京上升运动越强,间接表明副高强度	$WP = \omega(\text{南京}) - \omega(\text{福州})$ (ω 表示垂直速度)	-0.217	0.1	0.1
X_{13}	ZH	南京地区水汽垂直输送因子	ZH=南京700hPa垂直速度+南京中低层水汽通量散度和+南京中低层水汽通量散度和(中低层量用500、700、850hPa值求和得到)	0.381	0.01	0.01

注:表中“-”表示没有通过规定信度的检验

X_7 ,它们反映了500hPa高度场的主要环流特征,表明副热带高压和西部的低值区相对稳定的形势对南京降水的影响; X_{10} 表示

700hPa露点锋区对南京降水影响,露点锋区越强表示温湿能量越大,与降水相关越大; X_9 表明850hPa等温线密集带,对应于地面

锋区位置,是降水产生的主要天气系统,相关性好; X_{13} 因子检验效果好可以用水汽的垂直输送大来解释,水汽的垂直输送越大,产生降水的可能性就越大; X_1 作为 HLAFS 资料的 24 小时降水组合因子,是与降水直接相关的物理量,相关最好是意料之中的。

针对以上检验结果,由于预选因子中产生了两个最优因子 X_4 和 X_7 ,它们都表示了 500hPa 环流特征,因此设计两组因子(表 3) 带入神经网络进行学习,避免因子的重复。

表 3 带入神经网络的两组预报因子

预报因子组	检验置信度	选中的预报因子
A 组	0.05	X_1 、 X_4 、 X_9 、 X_{10} 、 X_{13}
B 组	0.01	X_1 、 X_7 、 X_9 、 X_{10} 、 X_{13}

这些因子不仅通过了信度较高的相关系数检验,而且每个因子都有明确的物理意义,每组因子都分别表达和涵盖了梅雨天气的主要特点,不仅包括了高度场和水汽条件特点,而且考虑了 HLAFS 资料本身的降水预报,这对 HLAFS 预报降水的改进有很大的意义。因此,它们作为良好的预报因子,为运用 BP 对降水分级预报进行客观模拟提供了物理基础。

3 人工神经网络模拟预报和检验

按照神经网络特点,用于天气预报的 BP 网络多为三层:输入层、隐层、输出层。输入

层节点由所选取的预报因子数确定,因此这里取为 5;输出层节点由预报对象的分级情况确定,这里根据梅雨降水特点将降水分为三级(表 4),所以输出层节点数为 3。隐层的节点数 N 可以由经验公式得到,也可以人为地取一个相当的数,试验发现,过多的隐层节点数可能导致训练时间延长和输出不易收敛,取一个合适的隐层值对网络的性能也有很大的影响。本文隐层节点数取为 4。

表 4 降水预报分级标准

降水量级	无雨	小到中雨	大到暴雨
降雨量	$\leq 0.1\text{mm}$	0.1~25mm	$\geq 25\text{mm}$

学习的精度也是网络的一个重要参数。确定学习的精度就是确定误差范围以决定学习训练的结束时机。本文前后两轮训练网络的均方误差的差的临界值取为 0.0001,当满足此临界条件时训练结束^[8]。

3.1 网络的模拟预报

具备了良好的预报因子,在上述的 BP 网络要求下,将上述两组预报因子分别输入网络学习,依照上述流程过程运行,训练结束后,便得出对应于两组因子对降水级别拟合的不同结果(见表 5)。有鉴于数据资料有限,为了了解训练的 BP 网络的效果,需要抽出一部分资料进行检验,本文取两种方法进行抽样检验,各得到了不同的效果。

表 5 两组因子对降水级别拟合的不同结果

因子	总天数和正确率	预报降水天数和比例			晴天天数和正确率	漏报	错报
		所有降水	小到中雨	大到暴雨			
A	48(48/55) 87.3%	13(13/17) 76.5%	8(8/13) 61.5%	4(4/4) 100%	36(36/38) 94.7%	4 次;全部中雨	3 次 其中一次雨型错误
B	49(49/55) 89.1%	15(15/17) 88.2%	9(9/13) 69.2%	4(4/4) 100%	36(36/38) 94.7%	2 次;全部中雨	4 次 其中两次雨型错误
A*	49(49/55) 89.1%	12(12/16) 75%	9(9/13) 69.2%	3(3/3) 100%	37(37/39) 94.9%	4 次;全部中雨	2 次
B*	51(51/55) 92.7%	12(12/16) 75%	9(9/13) 69.2%	3(3/3) 100%	39(39/39) 100%	4 次;全部中雨	无
HLAFS 降水预报	44(44/60) 73.3%	12(12/18) 66.7%	8(8/14) 57.1%	2(2/4) 50%	34(34/42) 81%	6 次降水 5 次中雨 1 次大雨	10 次 其中两次雨型错误
逐步回归 降水预报	27(27/60) 45%	18(18/18) 100%	14(14/14) 100%	0(0/4) 0%	13(13/42) 31%	无	33 次 4 次雨型错误

注:A、B 表示利用方法一进行学习和抽样;A*、B* 表示利用方法二进行学习和抽样

方法一取所选60天资料的最后5天进行检验。这样选取学习日期,既包含了所有梅雨天气的资料进行学习,而且学习过程比较完整。缺点是检验因子并不理想。通过核对实况资料可以发现这是因为,最后5天只有7月27日(最后5天的第一天)有0.1mm的降水,而训练网络主要针对的是梅雨时期的降水天气进行预报,这里检验因子本身就降水很少,而且,7月底也不是普遍意义的梅雨天气范畴,估计检验效果不是十分可靠。

方法二将典型梅雨期(6月中旬~7月中旬)每隔一候抽取一天,共5天进行检验。使用这种方法检验因子比较理想。是由于所抽取的五天中包含了对梅雨降水分级的三类情况(无雨、小到中雨、大到暴雨),这种抽取方法从对网络的检验来看,理论上检验效果比较可信。但同时由于抽取了部分有降水的预报因子资料,可能会对预报因子的网络学习能力有所影响。

同时为了比较神经网络预报效果,利用初选预报因子以及实际降水量(y)进行逐步回归运算,得到了 $F = 2.5$ 的回归预报方程如下:

$$y = -9.987 + 0.266X_1 + 0.191X_8 + 1.62X_{13}$$

复相关系数 0.637。预报结果见表 5。

根据 BP 网络经过学习后对降水级别拟合的结果可以看出,无论抽取学习资料采取方法一或是方法二,拟合效果 B 组因子优于 A 组因子。其主要结论可概括为:第一,根据表 5 检验结果,B 组因子中表现高度场的 X_7 因子的相关系数以及通过检验的信度本身就高于 A 组因子中的 X_4 。从物理意义上可以解释为:B 组因子 X_7 表示以郑州为中心和以福州为中心的高度场平均值的组合因子,相较于 X_4 表示以河西走廊西北和福州为中心的高度场平均值的组合因子, X_7 所表示的高度场环流形势在位置上更接近南京,对于本文针对第二天进行的预报而言,同时考虑系统的移速,选取 X_7 因子应该更合理。实际证明,结果确实如此。第二,同时可以看

出,选用 B 组因子的学习结果,其中拟合预报降水级别总准确率方法二优于方法一(B^* 优于 A^*),预报降水准确率方法一优于方法二。分析原因是由于方法一选取了梅雨期的所有降水资料进行学习,与方法二相比加大了降水学习的机会,其降水预报的能力必然比方法二强。第三,另外值得一提的是本文通过对 HLAFS 资料的预报结果二次处理,预报大、暴雨的准确率显著提高,预报降水的准确率最好提高了 20 多个百分点。第四,通过人工神经网络方法预报降水的结果与 HLAFS 降水预报的结果对比,可以发现:降水预报准确率由 HLAFS 原来的 66.7% 提高到最好 88.2%;大到暴雨的预报准确率有了明显提高。从所分的降水等级来看,每个级别的预报准确率都有大幅度提高。漏报、错报明显减少,达到了很好的预期效果。第五,由于逐步回归在考虑因子综合效果上有缺陷,因此比较结果体现了神经网络对大到暴雨的预报的优越性。

3.2 预报效果检验

对网络学习结果分别用以上用两种方法进行检验(表 6)。方法一所选用的检验资料没有代表性,因此 A、B 的检验结果十分理想,但不可靠。这里主要分析运用方法二进行检验的结果。 A^* 检验结果预报降水,两天实况降水漏报一天,但漏报当天的降水量小于 1mm,检验总预报准确率为 60%; B^* 漏报

表 6 两种方法进行检验(试预报)结果比较

检验因子	检验日期	实况降水	检验预报结果	检验预报 1 类概率	检验预报 2 类概率	检验预报 3 类概率
A^*	6/21	大、暴雨(36.4)	小、中雨	0.001	0.555	0.458
	6/26	晴	晴	1.000	0.000	0.000
	7/1	晴	晴	0.977	0.101	0.000
	7/6	小、中雨(0.4)	晴	0.666	0.475	0.000
	7/11	晴	晴	1.000	0.000	0.000
B^*	6/21	大、暴雨(36.4)	大、暴雨	0.001	0.214	0.897
	6/26	晴	晴	1.000	0.000	0.047
	7/1	晴	晴	0.899	0.128	0.017
	7/6	小、中雨(0.4)	晴	0.841	0.189	0.019
	7/11	晴	晴	1.000	0.012	0.000

注: * 号表示用方法二学习和抽样

一天降水,漏报当天降水小于 1mm,但暴雨的预报十分准确,检验总预报准确率为 80%。

综合对结果的分析 and 检验结果, B* 综合预报效果最理想, B 降水预报效果最好。为了更好地对学习网络进行检验,可以取更多的梅雨期资料来测试网络的性能。本文由于资料有限,对 B 训练的网络的检验存在不足,有待以后进一步的检验结果。实际上,理想的网络模型,输入预报因子应该使用梅雨期的所有资料进行学习(上述方法一),而利用新的梅雨期资料进行检验,这样既保持了学习的完整性,也可以选取有代表性的资料检验(上述方法二),才能真正保证结果的完整性和可靠性。

4 结语

本文的资料拟合结果和试预报结果表明了应用神经网络进行短期预报的可行性。为了改进 HLAFS 预报降水结果不理想的现状,本文运用统计方法和动力学方法从 2002 年梅雨期 HLAFS 资料中寻找预报因子,用人工神经网络方法建立了梅雨期降水分级预报的网络模型。结果证明网络的预报特别是大到暴雨的预报能力较 HLAFS 降水预报以及逐步回归方法预报均有显著的提高,并且所选因子具有明确的动力学、热力学意义。

然而,由于资料有限,对网络选取学习资料和试预报资料的方法仍有所欠缺,因而网络的性能有待利用更丰富的资料进行检验;另外,也可以通过进一步调整网络的各项参数(如调整隐层节点数)逐步提高网络的预报能力,使此次网络模型在预报短期梅雨降水中能发挥一定的作用。

致谢: 文章的修改得到了北京大学毛节泰老师、朱元竞老师的指导,在此表示感谢。

参考文献

- 1 朱乾根,林锦瑞,寿绍文,等. 天气学原理与方法. 北京:气象出版社,2000:637~638.
- 2 戴泽军. 湖南省有限区域数值预报系统的实现和初步数值模拟试验(硕士研究生论文). 南京:南京气象学院,2003.
- 3 中国气象局科教司. 省地气象台短期预报岗位培训教材. 北京:气象出版社,1998:75~77.
- 4 艾艳,汤志亚,王敏. 基于 BP 神经网络的短期降水预报. 河南教育学院学报(自然科学版),2004,13(3):60~62.
- 5 朱官忠,黄景华. 用人工神经网络作西南涡降水量级预报. 山东气象,15(1):24~27.
- 6 金龙,陈宁,林振山. 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 施丹平. 人工神经网络方法在降水量级中期预报中的应用. 气象,2001,27(6):40~42.
- 8 孙照渤,谭桂容,赵振国. 人工神经网络方法在夏季降水预报中的应用. 南京气象学院学报,1998,21(1):47~52.

Application of Artificial Neural Network to Categorical Forecast of Short-term Precipitation in Meiyu Period

Duan Jing

(Department of Atmospheric Sciences, Peking University, Beijing 100871)

Miao Chunsheng

(Department of Atmospheric Sciences, Nanjing University of Information Science & Technology)

Abstract

Artificial neural network (ANN) is applied to make categorical forecasting of short-term precipitation in Meiyu period of Nanjing. At first, based on the weather characteristics of Meiyu period, in terms of the statistical and dynamic method, the predictors are searched in data of HLAFS. Secondly, utilizing import predictors that are selected by two methods trains the ANN, and then five days precipitation data are taken out in order to test the level forecast of precipitation. The results show that the simulating effect is very well and the ability of short-term precipitation forecast is obviously improved.

Key Words: artificial neural network predictor categorical forecast of precipitation