

ANN 在海洋预报中的应用

冯利华

(浙江师范大学地理系, 金华市)

摘 要

人工神经网络通过神经元之间的相互作用来完成整个网络的信息处理, 具有自学习和自适应等一系列优点, 因而用它来进行海洋预报是可行的。针对海洋预报问题, 初步建立了基于神经网络的预报分析系统, 给出了应用实例。

关键词: 人工神经网络, BP 算法, 海洋预报。

海洋灾害, 尤其是台风暴雨、风暴潮、海冰等灾害与人类的生命和财产息息相关, 因此, 准确的海洋预报尤为重要。

在传统的海洋预报中, 一般是根据现有资料, 建立数学模型, 从而涉及到模式识别问题。但是, 海洋预报模型到底符合什么函数关系, 至今的研究不尽人意。由于近年来发展起来的人工神经网络 (Artificial Neural Networks, 简称为 ANN) 具有自学习、自组织、自适应和容错性等一系列优点, 在模式识别中已有成功的应用^[1, 2], 为此, 拟根据 ANN 的原理和方法^[3, 4]来进行海洋预报, 以供应商榷。

一、ANN 的原理和方法

ANN 是由大量简单神经元广泛连接而成的复杂网络。它是在现代生物学研究人脑组织的基础上提出来的, 可用来模拟人类大脑神经的思维活动^[5]。它具有并行分布的信息处理结构, 通过对非线性函数的复合来逼近输入和输出之间的映射。它不需要设计任何数学模型, 只靠过去的经验来学习, 通过神经元的模拟、记忆和联想, 处理各种模糊的、非线性的、含有噪声的数据, 采用自适应的模式识别方法来进行预报分析。

神经网络的算法包括 Hebb、Delta、Kohonen、BP 算法等。其中 BP 算法即误差反传训练算法 (Error Back Propagation), 是由 Rumelhart 等人组成的 PDP 小组于 1985 年提出来的,

*本文于 1999 年 11 月收到。

作者简介: 冯利华 (1955-), 男, 浙江建德人, 学士学位, 教授。




图 1 神经网络拓扑结构示意图

它实现了 Minsky 多层网络的设想。作为前馈式神经网络典型代表的多层感知机,通常由输入层、输出层和若干隐含层组成,其拓扑结构如图 1 所示。

采用误差反传训练算法的神经网络称为 BP 网络,其学习过程由正向传播和反向传播组成。在正向传播过程中,样本信号经过 Sigmoid 函数 $[f(x) = 1/(1 + e^{-x})]$ 的作用,逐层向前传播,每一层神经元的状态只影响到下一层神经元的状态。如果在输出层不能得到期望的输出信号,那么修改各层神经元的权值,同时使输出信号的误差沿原路返回。经过反复传播,最后使信号误差达到所要求的范围。

设网络具有 m 层,令 y_j^m 表示第 m 层中第 j 个结点的输出,而 y_j^0 就等于 x_j , 即第 j 个输入。令 W_{ij}^m 表示从 y_i^{m-1} 到 y_j^m 间的连接加权, θ_j^m 表示第 m 层第 j 结点的阈值。BP 网络训练步骤如下:

- ① 将各权值和阈值赋予 $(-1, 1)$ 间的随机数。
- ② 从训练数据组中选一数据对 (x^k, T^k) , 将输入变量加到输入层 ($m=0$), 使得式中

$$y_i^0 = x_i^k \quad (\text{对所有 } i \text{ 点}) \quad (1)$$

k 表示训练图形号。

- ③ 信号通过网络向前传播, 即利用关系式:

$$y_j^m = F(S_j^m) = F(\sum_i W_{ij}^m y_i^{m-1} + \theta_j^m) \quad (2)$$

计算从第一层开始的各层内每个结点 j 的输出 y_j^m , 直至全部完毕。其中 $F(s)$ 取 Sigmoid 函数。

- ④ 计算输出层每个结点的误差值:

$$\delta_j^m = y_j^m(1 - y_j^m)(T_j^k - y_j^m) \quad (3)$$

这个误差由实际输出值和目标要求值之差获得。

⑤计算前面各层每个结点的误差值:

$$\delta_j^{m-1} = F'(S_j^{m-1}) \sum_i W_{ij}^m \delta_i^m \quad (4)$$

这靠逐层反传误差算得 ($m = m, m - 1, \dots, 1$)。

⑥反向逐层修正权值和阈值:

$$W_{ij}^m(t+1) = W_{ij}^m(t) + \eta \delta_j^m y_i^{m-1} + \alpha [W_{ij}^m(t) - W_{ij}^m(t-1)] \quad (5)$$

$$\theta_j^m(t+1) = \theta_j^m(t) + \eta \delta_j^m + \alpha [\theta_j^m(t) - \theta_j^m(t-1)] \quad (6)$$

式中 t 为迭代次数; η 为学习速率 [$\eta \in (0, 1)$]; α 为动量因子 [$\alpha \in (0, 1)$]。

⑦返回到②, 转入下一个图形, 重复②~⑦, 直至网络全局误差:

$$E = \sum_k \sum_j (T_j^k - y_j^m)^2 / 2 \quad (7)$$

达到预设的精度为止。

神经网络训练好后, 其权值和阈值就已确定, 此时即可进行预报分析。

二、实例与比较

现以我国东南沿海地区一次登陆台风所造成的最大 24 小时暴雨量为例来说明 ANN 在海洋预报中的应用问题, 原始数据见参考文献^[6]。表 1 列出了 29 场台风暴雨资料。原文根据逐步回归周期分析, 从影响暴雨量的 7 个前期预报因子中筛选出 3 个因子: (1) x_1 ——台风暴雨中心当日 8 时 700hPa 位面的上升速度; (2) x_5 ——台风暴雨中心 5 个纬距范围内 500hPa 位面平均 24 小时变温; (3) x_6 ——台风暴雨当日 8 时 700hPa 位面佳木斯、哈尔滨、长春、延吉的温度与露点差之平均值 (表 1)。为此将 x_1 、 x_5 、 x_6 作为输入变量, 暴雨量 y 作为输出变量, 因而输入层的结点数为 3, 输出层的结点数为 1。隐含层的结点数根据 Kolmogorov 定律取为 5。由此得到用于台风暴雨量计算的神经网络的拓扑结构为 (3, 5, 1)。

为了加快收敛速度, 需要对原始数据 x_i 进行规一化, 即:

$$x'_i = (x_i - x_{\min}) / (x_{\max} - x_{\min}) \quad (8)$$

式中 x_{\max} 、 x_{\min} 为变量中的最大值和最小值。可知 x'_i 位于 $[0, 1]$ 之内。

经过规一化处理的原始数据加载到 BP 网络后, 即可选取一定的训练参数对其进行训练和学习。这里学习速率 η 取 0.85, 动量因子 α 取 0.60。为了对训练和学习过的网络进行测试, 将 1~26 号暴雨作为训练样本, 27~29 号暴雨作为测试样本。训练样本经过 180000 次的

表 1 一次登陆台风造成的最大 24 小时暴雨量及其计算结果

	序 号	台 风 编 号	x_1	x_2	x_3	暴 雨 量 (mm)	神经网络 拟 合 值 (mm)	相 对 误 差 (%)	直线回归 拟 合 值 (mm)	相 对 误 差 (%)
训 练 样 本	1	7503	14.5	-0.5	8.0	900	891.68	-0.92	656.15	-27.09
	2	6509	7.57	0.8	5.0	354	356.52	0.71	552.84	56.17
	3	6003	1.94	-0.2	1.7	566	531.32	-6.13	400.77	-29.19
	4	6521	3.04	0.2	1.5	521	564.18	8.29	451.66	-13.31
	5	7301	8.07	-0.6	2.7	333	327.26	-1.72	547.45	64.40
	6	6122	4.64	1.4	2.0	359	356.21	-0.78	537.94	49.84
	7	7412	3.02	0.6	4.6	589	464.34	-21.16	418.99	-28.86
	8	6213	6.20	0.0	2.5	416	431.47	3.72	520.02	25.01
	9	6615	2.69	1.3	15.7	289	289.19	0.06	265.50	-8.13
	10	6005	2.85	0.0	6.8	254	452.78	78.26	356.25	40.26
	11	6126	1.02	1.0	10.0	209	225.41	7.85	293.26	40.32
	12	6208	1.62	1.5	6.0	428	349.43	-18.36	392.36	-8.33
	13	6513	7.02	1.8	10.0	673	668.59	-0.66	499.18	-25.83
	14	6312	2.09	0.0	8.5	395	305.66	-22.62	307.90	-22.05
	15	5904	0.83	2.3	4.0	327	397.08	21.43	432.05	32.13
	16	6007	4.56	-0.3	4.0	829	714.50	-13.81	437.32	-47.25
	17	6306	5.43	-1.5	4.0	266	275.26	3.48	415.02	56.02
	18	7504	4.05	-0.3	2.8	653	721.39	10.47	441.07	-32.46
	19	5901	3.78	-1.0	12.2	187	185.39	-0.86	260.12	39.10
	20	6102	1.11	-0.5	14.0	178	179.67	0.94	174.57	-1.92
	21	7207	7.17	-1.0	10.6	160	162.11	1.32	383.29	139.56
	22	7123	5.00	2.7	23.3	280	283.65	1.30	270.52	-3.39
	23	7010	3.88	1.0	9.5	234	246.64	5.40	384.04	64.12
	24	5612	0.74	-2.0	9.0	264	160.03	-39.38	181.71	-31.17
	25	5622	3.05	-1.7	2.7	216	203.35	-5.85	358.09	65.78
	26	6214	0.30	-0.7	8.0	294	282.02	-4.07	235.92	-19.76
测 试 样 本	27	6911	3.44	-0.2	11.7	268	248.93	-7.12	289.75	8.12
	28	6001	5.94	-2.7	5.2	185	161.31	-12.80	363.76	96.63
	29	6906	3.12	1.0	17.3	246	264.12	7.36	241.44	-1.85

训练和学习，网络全局误差 $E=0.1$ ，小于预设精度，故网络收敛。由网络输出的拟合值及其相对误差 e 列于表 1。从表中可以看到，拟合值的平均相对误差 \bar{e} 只有 10.75%，最大相对误差 e_{\max} 也只有 78.26%，故拟合情况良好。

由于训练过的网络已“模拟”并“记忆”了输入变量和输出变量之间的“函数”关系，因而可以用它来进行暴雨量预报。测试结果也列于表 1，27 ~ 29 号暴雨的平均相对误差 \bar{e}

只有 9.09%，最大相对误差 e_{\max} 也只有 -12.80%，可见预报结果是好的。

为了进行比较，根据 1～26 号暴雨资料，利用逐步回归周期分析法，建立常用的直线回归模型：

$$\hat{y}=378.66+29.04 x_1+39.63 x_5-15.46 x_6 \tag{9}$$

其相关系数 $R=0.60$ ，剩余标准差 $S_y=171.33$ 。由直线回归模型计算的拟合值和预报值也列于表 1。可以看到，拟合值的 $\bar{e}=37.36\%$ ， $e_{\max}=139.56\%$ ；预报值的 $\bar{e}=35.53\%$ ， $e_{\max}=96.63\%$ ，可见神经网络模型的计算结果优于直线回归模型的计算结果。

三、讨论与展望

前已述及，神经网络不需要设计任何数学模型，它能够通过对非线性函数的复合来逼近输入和输出之间的映射。表 2 是海面平均浪高～风速关系、风力等级～风速关系（蒲福风力等级表^[7]）的拟合结果。这里，神经网络的拓扑结构为（1，4，1），训练和学习次数为 200 万次。可以看到，由神经网络确定的拟合值是比较满意的。

就风力等级 $F \sim$ 风速（中值） V 关系而言，蒲福（1805）给出了如下的近似公式：

$$F \approx 1.1233 V^{2/3} \tag{10}$$

表 2 海面平均浪高、风力等级的拟合结果

风级名称	风速（中值） （m/s）	海面平均浪高 （m）	拟合值 （m）	风力等级 （级）	拟合值 （级）
软 风	0.9	0.1	0.14	1	1.19
轻 风	2.5	0.2	0.23	2	1.89
微 风	4.4	0.6	0.50	3	3.02
和 风	6.7	1.0	1.09	4	4.04
清 风	9.4	2.0	1.98	5	4.98
强 风	12.3	3.0	2.95	6	5.96
劲 风	15.5	4.0	4.07	7	7.02
大 风	19.0	5.5	5.45	8	8.05
烈 风	22.6	7.0	7.06	9	8.96
狂 风	26.5	9.0	8.93	10	9.96
暴 风	30.6	11.5	11.55	11	11.10
台 风	34.8	14.0	13.86	12	11.85

以上计算表明，不论是（9）式的线性函数关系和（10）式的非线性函数关系，还是海面平均浪高～风速之间至今难以用具体模型描述的函数关系，神经网络对这些输入变量和

输出变量之间的复杂关系均具有较强的逼近能力和拟合能力。事实上,海洋预报中的其它许多复杂关系也能利用神经网络技术来进行分析,主要如下:

(1) 台风暴潮预报。这里输入变量包括进入防区的台风中心最大风速、台风中心最低气压和预报站气压之差等,输出变量为预报站的最大增水值。

(2) 感潮河段水位预报。此时输入变量包括上游站 $t - \tau$ 时刻的水位 (τ 为洪水传播时间)、下游站 $t - \tau'$ 时刻的高(低)潮位 (τ' 为潮波上溯时间)、下游站的相应潮差等,输出变量为预报站 t 时刻的水位。也可选择长程相关的前期预报因子进行预报,如上海市黄浦公园站的水位预报^[8]。

(3) 台风登陆次数预报。这里输入变量为前期预报因子,输出变量为台风登陆次数,如华南沿海地区的台风登陆次数预报^[9]。

(4) 海冰预报。此时输入变量包括天文、大气、海洋等因子,输出变量包括气温、初冰日、盛冰日、融冰日、终冰日、月冰量、年冰量、年度冰情等级等。

此外,台风登陆时的最大风速、最低中心气压等要素也可以用神经网络技术来进行分析。针对以上问题,收集了大量数据,对多种要素进行了预报研究,结果都是比较满意的。当然,所选择的前期预报因子应有明确的物理意义,并与预报量具有较好的相关性,这可以利用逐步回归周期分析和灰色关联度分析等方法来进行。计算也表明,预报量与预报因子的相关性越好,那么预报越准确。因此可以相信,神经网络技术在海洋预报中具有广阔的应用前景。

四、结 语

从上面的分析可以看到,人工神经网络的最大特点在于不需要设计任何数学模型,它通过神经元之间的相互作用来完成整个网络的信息处理,根据对非线性函数的复合来逼近输入和输出之间的映射,具有自学习、自组织、自适应和容错性等一系列优点,因而用它来进行海洋预报是可行的,计算结果也表明了这一点。

本文针对海洋预报问题,初步建立了基于 ANN 的预报分析系统,开发了实用的功能软件。这是海洋预报的一种新的尝试,如果把它与其它计算方法结合起来,那么可望提高海洋预报的精度和水平。

参 考 文 献

- [1] 夏元友,朱瑞赓,李新平. 基于神经网络的岩质边坡稳定性评估系统研究. 自然灾害学报, 1996, 5 (1): 98 ~ 104.
- [2] 李祚泳, 邓新民. 人工神经网络在台风预报中的应用初探. 自然灾害学报, 1995, 4 (2): 86 ~ 90.
- [3] 周继成, 周青山, 韩飘扬. 人工神经网络——第六代计算机的实现. 北京: 科学普及出版社, 1993, 47 ~ 51.
- [4] 陈天平. 神经网络及其在系统识别中的逼近问题. 中国科学, 1994, 24 (1): 1 ~ 7.
- [5] Lippmann R P. An introduction to computing with neural nets. IEEE ASSP Magazine, 1987, 4 (2): 4 ~ 22.
- [6] 张超, 杨秉康. 计量地理学基础. 北京: 高等教育出版社, 1993, 124 ~ 129.
- [7] 吴和康, 张志明. 气象学. 北京: 水利电力出版社, 1986, 23 ~ 24.
- [8] 庄一令, 林三益. 水文预报. 北京: 水利电力出版社, 1986, 50 ~ 51.
- [9] 曹鸿兴, 陈国范. 模糊集方法及其在气象中的应用. 北京: 气象出版社, 1988, 146 ~ 147.

APPLICATION OF THE NEURAL NETWORK IN MARINE FORECAST

Feng Lihua

(Department of Geography, Zhejiang Normal University, Jinhua)

Abstract

The artificial neural network can complete the news treatment of the whole network by means of a mutual function between the neural units, and has a lot of merits of self-learning, self-adjusting and such like. Therefore it is feasible that marine forecast is completed by the neural network. The forecast system based on the neural network is initially set up and the applied example is put forward in the light of the problem of marine forecast.

key words: artificial neural network, back-propagation algorithm, marine forecast.