

缺失风浪数据补足的神经网络模型

蒋学炼^{1,2}, 李炎保¹

(1. 天津大学 建筑工程学院, 天津 300072; 2. 天津城市建设学院 天津市软土特性与工程环境重点实验室, 天津 300384)

摘要: 基于波浪数据的完备性对于海岸海洋工程设计而言非常关键, 详细阐述了风浪观测数据补足神经网络模型的建立方法, 构建了两个网络模型, 以已有观测资料为样本进行了验证。结果表明, 两个网络的训练效果均很好, 且单输出目标的分层模拟要优于多输出目标的单层模拟。表明了利用人工神经网络推导缺失波浪条件的可行性。

关键词: 波浪观测; 缺失; 补足; 人工神经网络

中图分类号: TV139.2

文献标识码: A

文章编号: 1000-3096(2009)02-0060-08

1 风浪模型的发展现状

由于港湾设施及海岸结构物的主要外部荷载来自于波浪, 所以, 风浪预报历来是海岸海洋工程领域的热点研究主题。

现有的风浪预报模型主要是通过建立风场资料与海面波浪特性之间的风浪关系式来推算风浪条件的, 从表示形式上一般分为特征波法和波谱法两类。随着人类对风浪生成机理的深入研究和计算机技术的快速发展, 近几十年来, 风浪预报模型逐渐从各种经验半经验公式法发展到精度更高、通用性更好的风浪数值模型。目前最先进的第三代风浪模式主要包括两种: 近岸风浪模式-SWAN^[1]和远场风浪模式-WAM^[2], 二者均是在一定风场条件下对波浪作用平衡方程式^[3]进行简化求解的。由于现有的风浪预报数值模型对于水文、地形等环境数据的完备性及应用人员的理论水平要求较高, 在工程中应用受到一定限制。因此, 找到一种精度较高、使用简便的风浪预报模型就成为工程实践中的现实问题。

近 20 年来, 随着生物神经系统研究的深入, 人工神经网络在沉寂了数十年之后再度成为信息处理领域的研究热点, 广泛应用于信息工程、智能控制、模式识别等领域。最近十年, 人工神经网络方法也逐渐应用于工程领域, 如河川径流预测、洪水实时预报、混凝土性能预估、水库优化调度分析等^[4]。Balas 等^[5]曾采用多层前馈神经网络法获得 Dalamann 测站缺少的波浪数据, 其做法是找到波浪条件的时间序列规律, 即利用一段较长时期的波浪测量数据来获得神经网络参数, 然后利用前一采样时刻的最大有效波高、最小有效波高和平均有效波高来推算后一

时刻的相应值。作者则采用因果分析的方式, 利用神经网络建立已有水文测量数据与波浪条件之间的关系, 从而可以根据相应的水文条件来推导缺失的波浪条件。

2 分层前向人工神经网络

2.1 网络结构及逼近能力

目前在工程领域, 普遍采用的是分层前向神经网络, 本文也采用此网络建立风浪预报模型。在分层前向网络中, 各层神经元只接受前一级的输入, 然后单向输出到下一层神经元, 无反馈。图 1 给出了一个典型的三层前向人工神经网络结构。

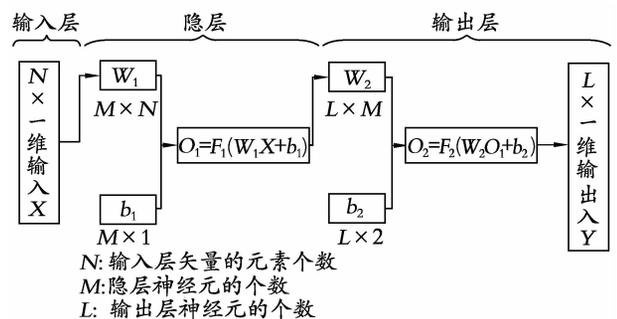


图 1 三层前向人工神经网络结构

Fig. 1 Three-layer feedforward network

由图 1 可以看出, 前向人工神经网络实质上完

收稿日期: 2006-05-19; 修回日期: 2008-09-29

基金项目: 国家自然科学基金项目(50779045)

作者简介: 蒋学炼(1975-), 男, 湖南桃源人, 讲师, 博士, 主要从事港口海岸及近海工程研究, 电话: 022-25990751, E-mail: jiangxuelian99@163.com

成了一个从 N 维空间 X^N 到 L 维空间 Y^L 的映射。关于这一网络的非线性逼近能力, 1989 年 Robert Hecht-Nielson 证明了如下定理^[4]: 令 $\Phi(x)$ 为非常量有界单调增连续函数, K 为 R^n 的紧致子集, $f(X) = f(x_1, x_2, \dots, x_n)$ 为 K 上的实值连续函数, 则对任意 $\epsilon > 0$, 存在整数 N 和实常数 $c_i, b_i, W_{ij} (i=1, 2, \dots, N; j=1, 2, \dots, N)$, 使得 $\hat{f}(x_1, x_2, \dots, x_n) = \sum_{i=1}^N c_i \Phi(\sum_{j=1}^N W_{ij} x_j - b_i)$ 满足 $\max |f(x_1, x_2, \dots, x_n) - \hat{f}(x_1, x_2, \dots, x_n)| < \epsilon$ 。

上述定理很清楚地表明: 对任意 $\epsilon > 0$, 总存在一个三层前向网络, 其隐层神经元的激发函数为 Φ , 输入及输出层神经元的激发函数为线性函数, 使得任何一个实值连续函数 $f(X)$ 均可用其逼近。

2.2 误差反向传播算法

分层前向人工神经网络的权值和阈值学习规则一般采用误差反向传播算法 (Back Propagation, BP)^[6]。这一算法实质上是基于最速下降原理的 Widrow-Hoff 算法^[7] 在多层前向人工神经网络中的推广。作者以三层前向人工神经网络为例, 给出 BP 算法的计算原理, 更多层的前向人工神经网络算法与之相似。

参考图 1 的网络结构, 假定输入层为 N 个神经元, 中间隐层为 M 个神经元, 输出层为 L 个神经元。输入层神经元的激发函数采用线性函数, 即 $F(x) = x$, 隐层神经元的激发函数为 F_1 , 输出层神经元的激发函数为 F_2 。

取输入层各神经元的输入为 x_1, x_2, \dots, x_N , 由于其激发函数为线性函数, 故其输出仍为 x_1, x_2, \dots, x_N 。输入层的输出传递到隐层后, 经求和和运算得到隐层的输入为:

$$I_m^{2,1} = \sum_{n=1}^N w_{mn}^{2,1} x_n + b_m^{2,1}, m = 1, 2, \dots, M \quad (1)$$

上式中的 $w_{mn}^{2,1}$ 为输入层神经元 n 和隐层神经元 m 之间的连接权值, $b_m^{2,1}$ 为隐层神经元 m 的阈值, 上标 2, 1 表示信息由第一层 (输入层) 传递到第二层 (隐层)。将上式代入隐层的激发函数 F_1 中, 可以得到隐层神经元的输出为:

$$y_m = F_1(I_m^{2,1}), m = 1, 2, \dots, M \quad (2)$$

同理可得输出层的输入为

$$I_l^{3,2} = \sum_{m=1}^M w_{lm}^{3,2} y_m + b_l^{3,2}, l = 1, 2, \dots, L \quad (3)$$

输出层的输出为:

$$z_l = F_2(I_l^{3,2}), l = 1, 2, \dots, L \quad (4)$$

预先给定 $w_{mn}^{2,1}, b_m^{2,1}$ 和 $w_{lm}^{3,2}, b_l^{3,2}$ (作者采用 Nguyen-Widrow 法^[8] 确定初始权值和阈值)。

因为信息的传递是由输入层逐层传递到输出层的, 没有反馈, 所以根据 (1)~(4) 式计算网络输出的过程称为正向运算。

设网络的期望输出为 $T = \{t_l\}, l = 1, 2, \dots, L$ 。定义网络的输出误差为:

$$d_l = t_l - z_l, l = 1, 2, \dots, L \quad (5)$$

网络的误差函数为:

$$e = \frac{1}{2} \sum_{l=1}^L d_l^2 \quad (6)$$

为了便于以下的推导, 定义连接权向量 $\mathbf{W} = (w_{mn}^{2,1}, b_m^{2,1}, w_{lm}^{3,2}, b_l^{3,2})$ 。

反向传播算法是沿着误差函数随权值和阈值变化的负梯度方向对权值和阈值进行修正的。即:

$$\mathbf{W}_{\text{new}} = \mathbf{W}_{\text{old}} + \Delta \mathbf{W} \quad (7)$$

综合式 (5) 和 (6), 有

$$\Delta \mathbf{W} = -\eta \frac{\partial e}{\partial \mathbf{W}} = \eta \sum_{l=1}^L d_l \frac{\partial z_l}{\partial \mathbf{W}} \quad (8)$$

式中, η 为学习速率, 一般取 0~1 之间的数。综合式 (1)~(4) 可得到 $\Delta \mathbf{W}$ 的各元素:

$$\left. \begin{aligned} \Delta w_{mn}^{2,1} &= \eta \sum_{l=1}^L d_l \frac{\partial z_l}{\partial (w_{mn}^{2,1})} = \eta \frac{\partial F_1}{\partial (I_m^{2,1})} x_n \sum_{l=1}^L d_l w_{lm}^{3,2} \frac{\partial F_2}{\partial (I_l^{3,2})} \\ \Delta b_m^{2,1} &= \eta \sum_{l=1}^L d_l \frac{\partial z_l}{\partial (b_m^{2,1})} = \eta \frac{\partial F_1}{\partial (I_m^{2,1})} \sum_{l=1}^L d_l w_{lm}^{3,2} \frac{\partial F_2}{\partial (I_l^{3,2})} \\ \Delta w_{lm}^{3,2} &= \eta d_l \frac{\partial z_l}{\partial (w_{lm}^{3,2})} = \eta d_l \frac{\partial F_2}{\partial (I_l^{3,2})} F_1(I_m^{2,1}) \\ \Delta b_l^{3,2} &= \eta d_l \frac{\partial z_l}{\partial (b_l^{3,2})} = \eta d_l \frac{\partial F_2}{\partial (I_l^{3,2})} \end{aligned} \right\} \quad (9)$$

利用 (9) 求得 $\Delta \mathbf{W}$ 的各个元素后, 代入 (7) 式即可得到修正后的权值和阈值。从 (1)~(9) 式可以看出, 这一算法是先正向计算求出网络的输出, 再逆着正向计算过程将输出误差信息层层向前传递, 因此称为误差反向传播算法。

以上计算过程是针对一个样本的, 如果训练样本有 S 个, 则按照上述过程计算所有的学习样本, 每次都对连接权向量 \mathbf{W} 进行修正, 最后得到经过所有样本数据训练的权值和阈值。为了衡量网络的精度, 利用训练后的连接权向量 \mathbf{W} 计算所有样本的输出, 求出其均方误差函数:

$$E = \frac{1}{S} \sum_{i=1}^S 2e_i \quad (10)$$

e_i 为每个样本对应的误差函数, 由式 (6) 得到。如果均方误差函数 E 满足精度要求时, 就认为网络已经达到训练要求, 停止计算, 将各个网络参数存储起来, 用于网络预测。

2.3 改进的误差反向传播算法

由于梯度下降算法的局限性,传统的误差反向传播算法具有收敛速度慢、易陷入局部极小点等缺点。克服这些缺点主要有三个途径:一是采用批处理的方法修正权值和阈值,即计算出所有样本对应的权阈值修正值,利用这些修正值的均值对连接权向量进行一次修正,而不是每个样本修正一次;二是采用启发式学习方法,如动量梯度下降算法、自适应学习速率动量梯度下降算法、弹性反向传播算法等^[9];三是采用更有效的数值优化方法,如共轭梯度算法、Gauss-Newton 算法以及 Levenberg-Marquardt 算法等^[10]。近年来,有些研究人员将遗传算法、模糊理论引入到神经网络中,得到了更为优化的算法和网络结构^[4]。

本文主要将批处理方法和自适应学习速率动量梯度下降算法结合起来进行网络的学习训练,分别介绍如下。

当式(10)对应的误差函数曲面为窄长形时,传统的梯度下降算法将导致连接权向量的修正值在窄长形谷的两壁之间回弹,这将减慢网络的收敛速度,为克服这一缺点,可在式(8)中增加动量项:

$$\Delta W(k+1) = -\eta m_c \frac{\partial e}{\partial W} + m_c \Delta W(k) \quad (11)$$

表 1 实例研究的样本数据

Tab. 1 Sample data for case study

| 样本序号 | 时间(年-月) | 风向(°) | 平均风速(m/s) | 平均波周期(s) | 温差(°C) | 有效波高(m) |
|------|---------|--------|-----------|----------|--------|---------|
| 1 | 2000-01 | 227.54 | 9.69 | 7.12 | -2.82 | 3.78 |
| 2 | 2000-02 | 158.00 | 6.64 | 8.64 | -1.11 | 3.74 |
| 3 | 2000-03 | 160.77 | 8.34 | 8.05 | -0.75 | 3.99 |
| 4 | 2000-04 | 173.69 | 6.64 | 6.41 | -0.57 | 2.25 |
| 5 | 2000-05 | 205.62 | 5.44 | 6.02 | -0.33 | 1.68 |
| 6 | 2000-06 | 157.88 | 5.86 | 6.34 | -0.53 | 1.91 |
| 7 | 2000-07 | 224.75 | 5.69 | 5.45 | -0.42 | 1.39 |
| 8 | 2000-08 | 245.69 | 6.29 | 5.82 | -0.26 | 1.85 |
| 9 | 2000-09 | 215.14 | 7.47 | 6.27 | -0.67 | 2.39 |
| 10 | 2000-10 | 218.29 | 8.12 | 6.71 | -1.10 | 2.96 |
| 11 | 2000-11 | 185.54 | 8.45 | 7.64 | -0.46 | 3.76 |
| 12 | 2000-12 | 166.14 | 9.51 | 7.72 | -0.52 | 4.12 |
| 13 | 2001-01 | 174.75 | 10.17 | 8.10 | -0.78 | 4.69 |
| 14 | 2001-02 | 201.53 | 8.37 | 7.42 | -0.62 | 3.45 |
| 15 | 2001-03 | 198.77 | 8.44 | 7.40 | -1.28 | 3.66 |

式中 $\Delta W(k+1)$ 和 $\Delta W(k)$ 分别为第 $k+1$ 和第 k 次迭代时的连接权向量修正值, m_c 为动量因子,一般取 0.9~1。

另外,由于学习速率 η 越大,网络收敛越快,但 η 过大却会使网络不稳定。为此,本文采用自适应学习速率法来自动调整 η 值。其原理为:比较第 $K+1$ 次和第 K 次迭代计算得到的均方误差函数 $E(K+1)$ 和 $E(K)$, 如果 $E(K+1)$ 更接近目标精度,则将 η 增大一个小量,反之则将 η 减小一个小量。

3 风浪数据补足神经网络模型

3.1 样本数据

本文建立风浪数据补足神经网络模型的资料来自美国国家数据浮标中心(NDBC, <http://www.ndbc.noaa.gov>)的 46001 测站(位于 $56^{\circ}17'44''N, 148^{\circ}10'19''W$)。经过分析和整理,作者采用 2000~2004 年间的观测数据用于模型示例(因仪器完全损坏,缺少 2004 年 2~4 月的数据),由于日观测值波动太大,因此均采用月平均值,共 57 组(前 47 个用于网络结构训练,后 10 个用于校核模型预测的准确性),见表 1。

表 1 续

| 样本序号 | 时间(年-月) | 风向(°) | 平均风速(m/s) | 平均波周期(s) | 温差(°C) | 有效波高(m) |
|------|---------|--------|-----------|----------|--------|---------|
| 16 | 2001-04 | 183.94 | 7.22 | 6.70 | -0.70 | 2.64 |
| 17 | 2001-05 | 160.13 | 6.53 | 6.18 | -0.52 | 2.17 |
| 18 | 2001-06 | 156.43 | 5.36 | 5.49 | -0.23 | 1.38 |
| 19 | 2001-07 | 227.14 | 5.60 | 5.82 | -0.51 | 1.60 |
| 20 | 2001-08 | 183.31 | 6.10 | 5.91 | -0.55 | 1.73 |
| 21 | 2001-09 | 190.64 | 6.52 | 6.50 | -0.50 | 2.39 |
| 22 | 2001-10 | 223.96 | 9.69 | 6.86 | -1.91 | 3.43 |
| 23 | 2001-11 | 154.10 | 6.75 | 7.49 | -1.97 | 3.15 |
| 24 | 2001-12 | 210.57 | 10.18 | 7.62 | -2.76 | 4.29 |
| 25 | 2002-01 | 207.09 | 9.78 | 7.64 | -1.03 | 4.25 |
| 26 | 2002-02 | 188.82 | 9.79 | 7.46 | -1.26 | 4.07 |
| 27 | 2002-03 | 188.36 | 7.38 | 6.83 | -0.97 | 2.83 |
| 28 | 2002-04 | 189.10 | 7.16 | 6.08 | -0.59 | 2.11 |
| 29 | 2002-05 | 177.66 | 5.68 | 6.22 | 0.07 | 1.63 |
| 30 | 2002-06 | 163.52 | 5.86 | 6.12 | -0.12 | 1.74 |
| 31 | 2002-07 | 176.56 | 5.32 | 5.86 | -0.26 | 1.49 |
| 32 | 2002-08 | 210.21 | 6.78 | 5.86 | -0.20 | 1.72 |
| 33 | 2002-09 | 229.28 | 7.77 | 6.27 | -0.53 | 2.38 |
| 34 | 2002-10 | 179.62 | 8.39 | 7.09 | -0.24 | 3.25 |
| 35 | 2002-11 | 150.49 | 8.81 | 7.65 | -0.54 | 3.81 |
| 36 | 2002-12 | 200.75 | 8.00 | 7.34 | -2.20 | 3.21 |
| 37 | 2003-01 | 140.63 | 9.36 | 7.41 | -0.66 | 3.67 |
| 38 | 2003-02 | 170.30 | 7.50 | 7.35 | -0.42 | 2.98 |
| 39 | 2003-03 | 187.27 | 8.18 | 7.12 | -2.07 | 3.10 |
| 40 | 2003-04 | 212.69 | 6.37 | 6.79 | -0.51 | 2.40 |
| 41 | 2003-05 | 185.38 | 7.15 | 6.12 | -0.09 | 2.09 |
| 42 | 2003-06 | 157.37 | 5.86 | 5.96 | -0.12 | 1.69 |
| 43 | 2003-07 | 182.68 | 5.74 | 5.73 | -0.19 | 1.52 |
| 44 | 2003-08 | 221.16 | 6.55 | 6.03 | -0.77 | 1.91 |
| 45 | 2003-09 | 183.94 | 7.69 | 6.08 | -0.53 | 2.31 |
| 46 | 2003-10 | 163.12 | 8.29 | 6.85 | -0.72 | 2.96 |
| 47 | 2003-11 | 244.60 | 9.75 | 7.07 | -2.54 | 3.47 |
| 48 | 2003-12 | 210.08 | 9.67 | 7.87 | -2.43 | 4.23 |
| 49 | 2004-01 | 184.63 | 8.74 | 7.08 | -2.20 | 3.30 |
| 50 | 2004-05 | 177.57 | 6.09 | 6.31 | -0.38 | 1.97 |
| 51 | 2004-06 | 150.02 | 6.01 | 6.21 | -0.22 | 1.79 |
| 52 | 2004-07 | 175.35 | 6.00 | 5.78 | -0.81 | 1.52 |
| 53 | 2004-08 | 164.68 | 6.80 | 5.88 | -0.58 | 1.74 |
| 54 | 2004-09 | 229.42 | 8.07 | 6.18 | -1.48 | 2.41 |
| 55 | 2004-10 | 224.93 | 9.50 | 6.79 | -1.18 | 3.22 |
| 56 | 2004-11 | 203.55 | 10.31 | 7.65 | -0.92 | 4.25 |
| 57 | 2004-12 | 201.30 | 10.26 | 7.65 | -1.20 | 4.27 |

注:风向以正北向为参考;温差为大气温度与海面温度之差

考虑到误差反向传播算法需要对激发函数求导,所以本文隐层和输出层神经元的激发函数均采用连续型的对数 Sigmoid 函数,其表达式为:

$$F_1(x) = F_2(x) = \frac{1}{1 + e^{-x}} \quad (12)$$

函数图形如图 2。

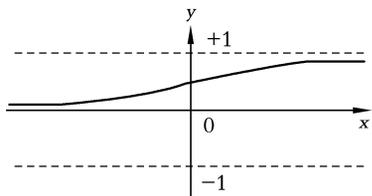


图 2 对数 Sigmoid 函数图形

Fig. 2 Log-Sigmoid transfer function

由图 2 可以看出,对数 Sigmoid 型函数具有两个良好特性:一是当输入值 X 较小时,也有输出值 Y 对应,这样可避免丢失微弱的信息;二是当输入值 X 很大时,输出值 Y 趋于 1,不会出现“溢出”。

为了充分利用对数 Sigmoid 型函数特性,应对学习样本(包括输入和目标数据)进行归一化处理^[4],使其落入 0~1 区间,归一化公式为:

$$X = \frac{X - \min\{X\}}{\max\{X\} - \min\{X\}} \quad (13)$$

网络对归一化之后的输入数据学习后,得到的输出值需要利用公式(13)逆运算还原为真实值。

表 2 神经网络的结构

Tab. 2 The structures of neural networks

| 神经网络 | 影响因子 | 目标因子 | 神经元数目 | | |
|-------------|-----------------|----------|-------|-----------|-----|
| | | | 输入层 | 隐层 | 输出层 |
| 网络 1 | 风向、平均风速、温差 | 平均周期有效波高 | 3 | 45×42 双隐层 | 2 |
| 网络 2 的第一层网络 | 风向、平均风速、温差 | 有效波高 | 3 | 45×42 | 1 |
| 网络 2 的第二层网络 | 风向、平均风速、温差、有效波高 | 平均周期 | 4 | 45×45 | 1 |

其中,网络 2 是网络 1 的改进,为两层网络的串联,构建理由详见第四节“计算结果分析”。其基本原理是首先利用 3 个影响因子(风向、平均风速、温差)第一层网络,用于预报有效波高。然后将第一层网络得到的有效波高和风向、平均风速、温差一起作为影响因子来建立第二层网络,用于预报平均波周期,如图 3。

利用表 1 前 47 个样本数据对表 2 的两个网络进行了训练,结果如图 4 和表 3。

3.2 隐层及隐层神经元数的确定

分层前向神经网络的输入层(输出层)神经元数与输入样本(输出目标)的维数一致,隐层及隐层神经元数需要通过试算确定。本文确定隐层数的方法为:首先采用三层神经网络,限定输出精度和迭代循环次数,如果在规定的迭代次数内网络的输出未达到精度要求,则增加一个隐层,直到网络收敛。关于隐层神经元,卢世浪^[11]提出参考感知器型神经网络中间层神经元数目的确定方法:

$$\left. \begin{aligned} M &\leq S - 1 \\ M &= \sqrt{N + L} + A \\ M &= \ln(2^N) \end{aligned} \right\} \quad (14)$$

式中 M 为隐层神经元数, N 为输入层神经元数, L 为输出层神经元数, S 为样本数, A 取 0~10 之间的常数。如果是多隐层神经网络,也可参考式(14)确定各隐层的神经元数。例如,当网络增加一个隐层,前一隐层的神经元数固定不变,式(14)中的 M 为本隐层神经元数, N 为上层神经元数, L , S 和 A 不变。

3.3 模型训练结果

根据上述理论,建立了两个风浪数据分析神经网络,经试算得到网络结构如表 2。

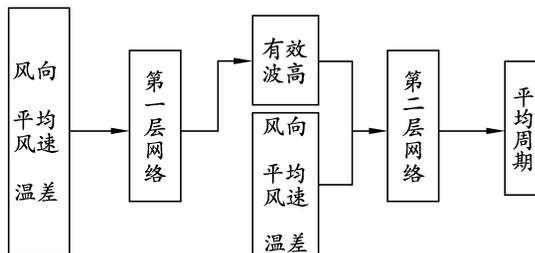


图 3 网络 2 结构示意图

Fig. 3 The structure of network 2

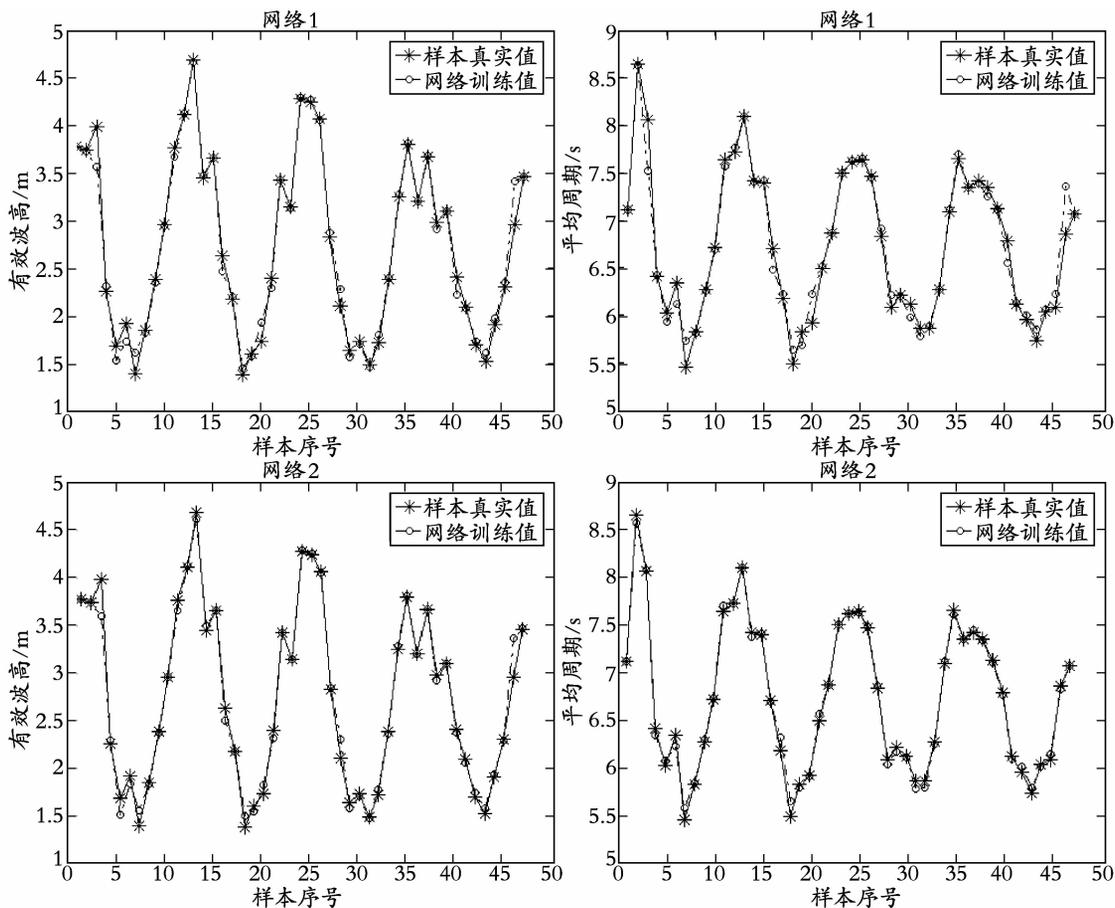


图4 网络训练结果

Fig. 4 Training results of network 1 and network 2

表3 神经网络训练结果比较

Tab. 3 The comparisons among the training results of two networks

| 神经网络 | 相对误差均值(%) | | 相对误差标准差(%) | |
|------|-----------|------|------------|------|
| | 有效波高 | 平均周期 | 有效波高 | 平均周期 |
| 网络1 | 3.20 | 1.32 | 4.07 | 1.79 |
| 网络2 | 2.57 | 0.61 | 3.47 | 0.66 |

表4 网络1模拟结果

Tab. 4 Simulating results of network 1

| 样本序号 | 样本波高实测值(m) | 样本波高预测值(m) | 样本波高预测值相对误差(%) | 样本周期实测值(s) | 样本周期预测值(s) | 样本周期预测值相对误差(%) |
|------|------------|------------|----------------|------------|------------|----------------|
| 48 | 4.23 | 2.90 | 31.43 | 7.87 | 6.71 | 14.64 |
| 49 | 3.30 | 2.52 | 23.65 | 7.08 | 6.85 | 3.29 |
| 50 | 1.97 | 1.78 | 9.81 | 6.31 | 5.84 | 7.52 |
| 51 | 1.79 | 1.76 | 1.67 | 6.21 | 6.03 | 2.79 |
| 52 | 1.52 | 2.02 | 32.73 | 5.78 | 6.98 | 20.84 |
| 53 | 1.74 | 2.41 | 38.81 | 5.88 | 6.54 | 11.27 |
| 54 | 2.41 | 2.97 | 23.23 | 6.18 | 7.02 | 13.55 |

3.4 模型预报结果

利用上述学习训练后获得的网络参数,对表1的后10个样本数据进行了模拟预测,结果分别列于表4和表5。

表 4 续

| 样本序号 | 样本波高实测值(m) | 样本波高预测值(m) | 样本波高预测值相对误差(%) | 样本周期实测值(s) | 样本周期预测值(s) | 样本周期预测值相对误差(%) |
|------|------------|------------|----------------|------------|------------|----------------|
| 55 | 3.22 | 4.00 | 24.32 | 6.79 | 7.57 | 11.57 |
| 56 | 4.25 | 4.58 | 7.73 | 7.65 | 8.07 | 5.38 |
| 57 | 4.27 | 4.21 | 1.43 | 7.65 | 7.26 | 5.11 |
| 均值 | 2.87 | 2.92 | 19.48 | 6.74 | 6.89 | 9.60 |
| 标准差 | 1.06 | 0.97 | 12.73 | 0.74 | 0.63 | 5.50 |

表 5 网络 2 模拟结果

Tab. 5 Simulating results of network 2

| 样本序号 | 样本波高实测值(m) | 样本波高预测值(m) | 样本波高预测值相对误差(%) | 样本周期实测值(s) | 样本周期预测值(s) | 样本周期预测值相对误差(%) |
|------|------------|------------|----------------|------------|------------|----------------|
| 48 | 4.23 | 4.16 | 1.79 | 7.87 | 7.90 | 0.45 |
| 49 | 3.30 | 3.58 | 8.55 | 7.08 | 7.31 | 3.21 |
| 50 | 1.97 | 1.87 | 5.40 | 6.31 | 6.14 | 2.75 |
| 51 | 1.79 | 1.91 | 6.44 | 6.21 | 6.27 | 1.00 |
| 52 | 1.52 | 1.68 | 10.78 | 5.78 | 5.87 | 1.56 |
| 53 | 1.74 | 2.52 | 44.66 | 5.88 | 6.59 | 12.11 |
| 54 | 2.41 | 1.89 | 21.66 | 6.18 | 5.63 | 8.83 |
| 55 | 3.22 | 3.34 | 3.86 | 6.79 | 6.64 | 2.21 |
| 56 | 4.25 | 4.55 | 6.94 | 7.65 | 7.85 | 2.61 |
| 57 | 4.27 | 4.25 | 0.42 | 7.65 | 7.58 | 0.96 |
| 均值 | 2.87 | 2.97 | 11.05 | 6.74 | 6.78 | 3.57 |
| 标准差 | 1.06 | 1.07 | 12.53 | 0.74 | 0.79 | 3.62 |

4 计算结果分析

两个网络的训练效果均很好。从图 4 可以看出,网络训练值与样本真实值非常吻合。从表 3 可以看出,网络 1 和网络 2 的有效波高训练值相差很小,但网络 2 对于平均周期的训练结果明显优于网络 1。

单目标分层模拟优于多目标单层模拟。表 4 说明网络 1 的有效波高和平均周期预测值与真实值均有较大的偏差,尤其在真实值的最大和最小两端,这种趋势更明显。这可能有 3 个原因:一是利用 3 个影响因子风向、平均风速、温差来预测两个目标因子波高和周期,影响因子偏少,难以更准确地反映出波高和周期的变化规律;二是波高和周期之间存在一定的固有关系,而这在模型中没有考虑,应在模型中加入反映波高和周期内在关系的子模型;三是隐层

和输出层神经元的激发函数采用对数 Sigmoid 型函数,从图 2 可以看出,在 y 接近 0 或 1 的区域时,函数值对自变量 x 非常不敏感(称饱和平台),这使得神经元的输出对样本最大和最小两端的数据响应不准确,应改进激发函数的形式,使之对样本变动更敏感,如 $F(x) = \frac{1}{B + Ce^{-Dx}}$ 。

为了解决影响因子偏少和在神经网络模型中反映出波高-周期的内在关系,网络 2 将网络 1 分解为两层串联网,减少了目标因子数量,并在网络结构中隐含了波高-周期的关联关系,得到的结果明显比网络 1 有很大改进,详见表 5。虽然从表 5 可以看出预报结果仍然偏差较大,但与网络 1 一样,很可能是影响因子数量不足导致,而非网络结构本身的缺陷。要解决这一问题,需要纳入更多合理的影响因子(如风时、风区、水深等)。

由以上分析可以看出,在工程中完全可以利用神经网络自适应学习和联想的能力,建立人工神经网络型的风浪数据分析模型,从而在一定精度条件下,以已有水文测量数据为基础推导出缺失的波浪条件。这一模型的要点在于准确选取足够多的影响因子和建立合适的网络结构。另外,如果在网络中加入延迟和反馈,则理论上可对风浪条件的实时变化进行更为详细的预测,这需要更深入的研究。

参考文献:

[1] Booij N, Holthuijsen L H, Ris R C. The SWAN wave model for shallow water[A]. American Society of Civil Engineers (ASCE). Proceedings of 24th International Conference on Coastal Engineering (Vol. 1) [C]. Orlando: ASCE, 1996. 668-676.

[2] WAMDI Group. The WAM model-a third generation ocean wave prediction model [J]. **Journal of Physical Oceanography**, 1988, 18: 1 775-1 810.

[3] Bretheron F P, Garrett C J R. Wave trains in inhomogeneous moving media [J]. **Proc Roy Soc**, 1968, A302: 529-554.

[4] 赵林明, 胡浩云, 魏德华, 等. 多层前向人工神经网络[M]. 郑州: 黄河水利出版社, 1999.

[5] Balas C E, Koc L. Risk assessment of vertical breakwaters-a case study in turkey[J]. **China Ocean Engineering**, 2002, 16(1): 123-134.

[6] Rumelhart D E, Hinton G E, Williams R J. Learning internal representations by error propagation [A]. Rumelhart D E, McClelland J L. *Parallel Data Processing (Vol. 1)* [C]. Cambridge, MA: The MIT Press, 1986. 318-362.

[7] Widrow B, Hoff M E. Adaptive switching circuits [A]. IRE. 1960 IRE WESCON Convention Record [C]. New York: IRE, 1960. 96-104.

[8] Nguyen D, Widrow B. Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights [A]. IJCNN. Proceedings of the International Joint Conference on Neural Networks (3) [C]. Orlando: IJCNN, 1990. 21-26.

[9] Vogl T P, Mangis J K, Rigler A K, *et al*. Accelerating the convergence of the backpropagation method [J]. **Biological Cybernetics**. 1988, 59: 256-264.

[10] 周志华. 神经网络及其应用 [M]. 北京: 清华大学出版社, 2004.

[11] 卢世浪. 神经网络与模糊集理论在实时洪水预报中的应用研究[D]. 大连: 大连理工大学, 2002.

An artificial neural network (ANN) model for supplement of deficient wave observation

JIANG Xue-lian^{1,2}, LI Yan-bao¹

(1. School of Civil Engineering, Tianjin University, Tianjin 300072, China; 2. Tianjin Key Laboratory of Soft Soil Characteristics & Engineering Environment, Tianjin Institute of Urban Construction, Tianjin 300384, China)

Received: May, 19, 2006

Key words: wave observation; deficiency; supplement; artificial neural network (ANN)

Abstract: The complete wave observation is very important for the design of coastal and ocean structures. First, the process of establishing a wave prediction model based on artificial neural network (ANN) technique is described in detail. Then, two models are established and verified by employing historical observation data. Comparisons between the results of two models show that the training results of two networks match the samples well and network with single output is better than network with multiple outputs. Owing to its simplicity and acceptable accuracy, this model can be used as a new tool to obtain the lost wave data in observation.

(本文编辑:刘珊珊)