



基于 SAPSO-BP 网络模型的 港口潮汐实时预报*

张泽国¹, 尹建川¹, 柳成¹, 张心光²

(1. 大连海事大学航海学院, 辽宁 大连 116026; 2. 上海工程技术大学汽车工程学院, 上海 201620)

摘要: 为了提高港口码头潮汐预报的精度, 提出一种自适应变异的粒子群优化算法 SAPSO, 将 SAPSO 优化算法与 BP 神经网络结合, 用以潮汐水位的实时预报。SAPSO-BP 网络模型运用自适应变异的 PSO 算法优化 BP 神经网络的网络参数, 克服了传统 BP 神经网络所具有的对初始权值阈值敏感、容易陷入局部极小值的缺点, 最后选用 Isabel 港口的实测潮汐值数据进行潮汐水位的实时预报仿真试验, 用以验证 SAPSO-BP 预测模型的实用性和可靠性。

关键词: BP 神经网络; 自适应; 粒子群优化; 港口潮汐水位实时预测; 调和分析

中图分类号: U 652.3

文献标志码: A

文章编号: 1002-4972(2017)01-0034-07

SAPSO-BP network in tidal level prediction of port

ZHANG Ze-guo¹, YIN Jian-chuan¹, LIU Cheng¹, ZHANG Xin-guang²

(1. Navigation College, Dalian Maritime University, Dalian 116026, China;

2. Automobile Engineering College, Shanghai University of Engineering Science, Shanghai 201620, China)

Abstract: In order to improve the accuracy of tidal level prediction in port and wharf, we propose a self-adapting particle swarm optimization(SAPSO) algorithm to optimize the back propagation(BP) neural network model. The model is referred to as SAPSO-BP model which employs PSO to adjust control parameters of BP network. This novel model overcomes the shortcoming of traditional BP neural network, which is sensitive to the initial weight threshold and is easy to trap in local minimum. The real-measured tidal level data of Isabel port is chosen as the test database to verify the practicability and reliability of the SAPSO-BP prediction model.

Keywords: BP neural network; self-adapting; particle swarm optimization; real time tidal level forecast in port; harmonious analysis

近代以来, 潮汐对人们的生产实践活动的影响日益增大。实时精确的潮汐水位信息对于船舶在沿岸港口中的航行安全、港口码头作业以及港口码头水文勘测等方面有着重大的实践意义。随着数字化航海的出现, 现代航海对潮汐水位信息的精确度要求越来越高。超大型油轮、散货船等进出港口时, 提供高精度的潮位信息将能够大大减少船舶搁浅或者擦碰桥梁等事故的发生。

调和分析法^[1]是潮汐预报方面最传统的技术, 需要大量的长期观测潮位数据分析, 才能够得到相对较准确的调和模型。但是由于长期的现场数据观测记录成本太高, 因此一般很难得到。调和模型的平均预报误差约为 20~30 cm。另外, 调和模型仅仅考虑了天体引潮力的影响, 而忽略了潮汐受到诸多时变因素非线性部分的影响, 传统的静态结构调和模型很难进行高精

收稿日期: 2016-04-18

*基金项目: 国家自然科学基金项目(51379002, 51279106)

作者简介: 张泽国(1991—), 男, 硕士研究生, 从事海洋工程、船舶运动、智能算法的研究。

度以及实时的潮汐水位预报。

人工神经网络较强的非线性映射和自学习自适应能力使得其在工程计算领域得到了广泛的应用, 因而人工神经网络能够进行复杂的、非线性的、非平稳性的系统仿真预测。BP 神经网络 (back propagation) 是一种多层前馈神经网络, 是当今最常用的一种神经网络模型, BP 神经网络及其各种优化模型在潮汐预报方面得到广泛应用^[2-6], 且 BP 预测模型也达到了较高的预测精度。Jain 等^[7]使用神经网络进行了印度洋西海岸 New Mangalore 潮位站的提前 1 d 潮汐预报; 尹建川^[8]提出了利用序贯学习算法建立变结构的径向基于神经网络的潮汐预报模型以反映系统的时变动态。

然而, BP 神经网络本身尚有一些缺陷^[9-10]: 网络模型参数的选择随机性比较大; 优化过程可能陷入局部最优; 对网络参数的选择比较敏感, 训练的收敛速度相对较难控制等。相关研究人将粒子群优化算法与 BP 网络结合起来^[11], 以改进 BP 网络的非线性映射能力, 但仍易出现早熟收敛、搜索效率较低等现象。本文提出了一种自适应粒子群优化算法, 建立了 SAPSO-BP 混合预报模型, 加入自适应变异算子的粒子群优化算法 SAPSO (self-adapting particle swarm optimization algorithm), 结合了 PSO 算法的全局搜索寻优能力和自适应变异算法的跳出局部最优解的能力, 使得 BP 网络模型能够迅速跳出局部最优并能快速找到全局最优解。采用该混合预报模型对 Isabel 港口的实测潮汐值数据进行实时预报的仿真, 经仿真试验训练, 与传统的调和模型和传统单一的 BP 网络预测模型进行对比, 可以得出结论: SAPSO-BP 预测模型相对具有更精确的预测结果。

1 调和分析法

潮汐是海平面周期性的上升和下降运动。潮汐产生的原动力是天体的引潮力, 即天体的引力和地球-天体相对运动所需的惯性离心力的向量和。实际应用中最通用的一种方法就是调和分析法, 它将复杂的潮汐分解成若干周期性变化的部

分, 根据实际观测的潮位数据进行分析, 可以求得潮汐调和模型中的各个常数。然后再根据得到的潮汐调和常数计算分潮波组成的大小, 并且可以用来推算潮汐。理论上, 潮汐的组成部分是复杂的, 潮汐的分潮数量是众多的, 但是在工程计算上, 当分潮汐的平均振幅相对较小和分潮的格林尼治迟角相对较长时, 有相当一部分的潮汐分潮成分是可以忽略的。在实际应用计算中, 某地实际潮位高度可表示为:

$$h(t) = H_0 + \sum_{k=1}^n h_k \cos(\omega_k t - \phi_k) \quad (1)$$

式中: H_0 为分析期间的平均海面高度; n 为潮汐分潮数量; h_k 为分潮的振幅; ω_k 和 ϕ_k 分别是分潮的频率和相位。

2 SAPSO-BP 算法的实现

2.1 BP 神经网络算法

BP 算法本质是将样本仿真的输入输出映射为非线性优化问题, 也就是将网络的连接权值作为变量, 将网络训练的误差函数作为目标函数的多元变量求极值问题, 传统的 BP 网络模型通常由输入层、输出层和隐含层构成, 网络的仿真试验使用选定的训练样本进行学习训练, 从而确定训练模型的模型参数。BP 网络模型仿真训练过程包括输入信息正向传播和误差信息反向传播, 在一定的迭代循环条件下, 两个过程反复执行, 直到模型结果收敛。输入信息正向传播: 即输入数据经输入层进入隐含层, 经隐含层节点激活函数计算进入输出层, 得到正向传播结果。网络模型的第 j 个神经元的输出可表示为:

$$y_j^k = \left(f \sum_{i=1}^{k-1} w_{ij}^{k-1} y_i^{k-1} - \theta_j^k \right) \quad (2)$$

式中: $j=1, 2, \dots, n; k=1, 2, \dots, m; f(x)$ 为隐含层的激活函数; w_{ij}^{k-1} 为第 $k-1$ 层第 i 个神经元到第 k 层神经元的连接权; θ_j^k 为阈值。输出信息反向传播过程: 由预测输出值与实际输出值的差值构成误差函数 $E(wk)$, 反向传播过程采用梯度下降法调节网络模型的权值阈值, 使得误差函数值最小。为了避免仿真训练过程中出现数值震荡, 加入动

量项:

$$w(k+1) = w(k) - \eta \partial E / \partial W(k) + \alpha \Delta w(k) \quad (3)$$

式中: η 为学习效率; α 为动量项系数。

网络模型使用训练样本进行学习训练, 使得模型的权值阈值与训练样本之间匹配, 经误差信息反向传播调整后的权值阈值也为非线性函数的隐含形式。经过一定次数的迭代仿真训练学习得到与样本匹配的网络模型即可用于进行预测。BP 网络具有很好的非线性映射能力, 但收敛速度较慢, 如果初始的网络参数选择不当, BP 模型的仿真训练将会陷入局部最优。

2.2 粒子群优化算法

粒子群优化算法 PSO (particle swarm optimization)^[12] 的理论源于对鸟群捕食的行为研究: 鸟群在寻找食物的过程中, 每只鸟通过搜寻当前距离食物最近的鸟的周围而高效地获取食物。PSO 算法便是从鸟群捕食行为中获得启发而产生的。PSO 求解时, 问题的解就是种群空间中每只鸟的位置, 每只鸟称为一个“粒子”。首先随机初始化一群粒子(随机解), 每个粒子在搜寻空间中初始化自己位置和速度, 且每个粒子都有一个适应度函数值, 适应度函数由所优化的问题决定。每一次迭代循环过程中, 每个粒子以一定的速度通过跟踪个体极值和群体极值来更新自身的位置, 个体极值是粒子在寻优过程中自身所寻找到的最优值, 而群体极值则是整个种群在寻优过程中获得的最优值(也称为全局最优值)。

设搜寻空间中有 d 个粒子, 其中第 i 个粒子可用一个 D 维向量表示, 第 i 个粒子的位置表示为 $X_i = (X_{i1}, X_{i2}, \dots, X_{iD})$, $i = 1, 2, \dots, d$, 速度为 $v_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ 。记第 i 个粒子搜索到的最优位置为 $P_i = (P_{i1}, P_{i2}, \dots, P_{iD})$, 整个粒子群搜索到的最优位置为 $P_g = (P_{g1}, P_{g2}, \dots, P_{gD})$ 。粒子状态更新操作如下:

$$v_{i_d} = wv_{i_d} + c_1 r_1 (P_{i_d} - X_{i_d}) + c_2 r_2 (P_{g_d} - X_{i_d}) \quad (4)$$

$$X_{i_d} = X_{i_d} + v_{i_d} \quad (5)$$

式中: $i = 1, 2, \dots, m$; $d = 1, 2, \dots, D$; w 为惯性因子; 学习因子 c_1 和 c_2 是非负常数, 通常 $c_1 = c_2 = 2$;

r_1 和 r_2 是介于 $[0, 1]$ 的随机数; 为了提高粒子的搜寻效率, 一般将每个粒子的位置和速度限定在规定的范围之内, $X_{i_d} \in (-X_{\max}, X_{\max})$, $V_{i_d} \in (-v_{\max}, v_{\max})$, X_{\max} 和 v_{\max} 均为常数。

PSO 优化算法是一种全局迭代寻优的工具, 寻优开始时, 算法将每个粒子初始化为一组初始随机解, 根据优化问题选择适应度函数, 设定迭代寻优次数, 根据适应度函数计算每个粒子的适应度值从而进行迭代寻优, 搜寻到最优粒子(即最优解)。

2.3 自适应粒子群优化算法

PSO 算法的寻优收敛速度较快, 但也存在着在寻优过程中容易早熟收敛、搜索准确度低、循环后期迭代效率较低等缺点。仿照遗传算法 GA (genetic algorithm) 中的变异操作, 在 PSO 算法中加入变异算子, 对初始随机变量再一次重新随机初始化。引入的变异算子将初始随机变量再次随机初始化, 扩展了在寻优中不断缩小的种群搜寻空间, 使得已寻优得到的粒子跳出之前寻优得到最优位置, 从而在更大的搜寻空间中进行迭代寻优, 增加了算法寻找到更优值的概率。因此, 在传统 PSO 算法的基础上加入变异算子, 实质就是在每次粒子迭代更新之后, 将迭代更新后的粒子再以一定的概率随机初始化。其中自适应变异算子公式表示如下:

$$pop(j, pos) = \lambda \text{rands}(1, 1) \quad \text{if } rand > c \quad (6)$$

式中: j 为粒子种群规模; pos 是一个离散的均匀随机正整数; λ 为粒子种群位置最大值; C 是一个正的常数, 通常小于 1。

种群迭代进化过程中最优个体适应度函数值变化见图 1。由图 1 可知, SAPSO-BP 混合预测模型的适应度函数值明显小于 PSO-BP 模型, 而且其误差递减速率更快。也就是说, SAPSO-BP 模型可以自适应地跳出局部极小值点并能快速搜索到一个更优的结果。其中适应度函数的方程如下:

$$error = |Y_k - O_k| \quad (7)$$

式中: Y_k 为网络模型的预测输出值; O_k 为网络模型的实际输出值。

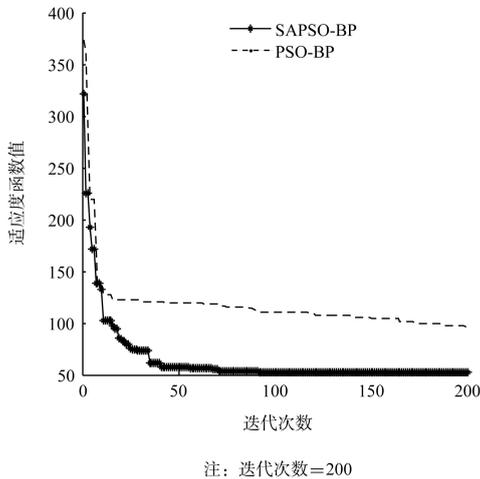


图 1 适应度函数曲线比较

2.4 SAPSO 优化算法训练 BP 神经网络

采用 SAPSO 算法对 BP 神经网络的权值和阈值进行优化, 以提高神经网络预测模型的收敛性。本文提出的 SAPSO-PB 预测模型是基于短期的时间序列预测模型, 一般可进行一个月之内的时间序列预报。本次仿真试验的数据可从网站 <http://co-ops.nos.noaa.gov> 下载。仿真试验表明, 进行相对精确的潮汐预报, 需要选取至少 15 d 即半个月以上的潮汐观测数据进行仿真训练, 本文选取 20 d 的观测数据进行预测模型的仿真训练。试验进行 5~10 d 的潮汐水位预报, 结果表明前 20 d 的训练数据用于预报约 6 d 的潮汐水位可以得到较准确的预测结果, 因此本文得选取 640 组共 27 d 的 Isabel 港口实测潮汐值数据进行仿真试验, 实测数据值采用等间隔采样, 采样时间为 1 h。其中前 480 组实测潮汐数据用于 SAPSO-BP 模型的仿真训练, 后 160 组数据则用于 SAPSO-BP 模型的仿真预测。选用 480 组潮汐水位的实测数据计算数据的自相关性值, 与 t 时刻相邻的不同时刻观测数据和 t 时刻观测数据的相关性由自相关标准值限定, 自相关标准值取值较小可以得到更多的相邻时刻观测数据, 进而可以得到更精确的结果。因此选取 0.095 自相关值为标准来决定模型的输入结构, 由图 2 可知, 在时间 t 时刻的数据与其前 5 s 的数据具有较大的相关性。因此确定将整个网络预测模型设置为 5 个输入节点、1 个输出节点。预测模型的输入潮汐实测时间序列数据值表示为 $y_{IN}(t)$,

由自相关分析可知 $y_{IN}(t)$ 由 $y(t)$ 、 $y(t-1)$ 、 $y(t-2)$ 、 $y(t-3)$ 、 $y(t-4)$ 组成。预测模型的输出值表示为 $y_{OUT}(t+1)$ 。其中 y_{IN} 、 y_{OUT} 均为潮汐数据值。该算法的实现步骤如下:

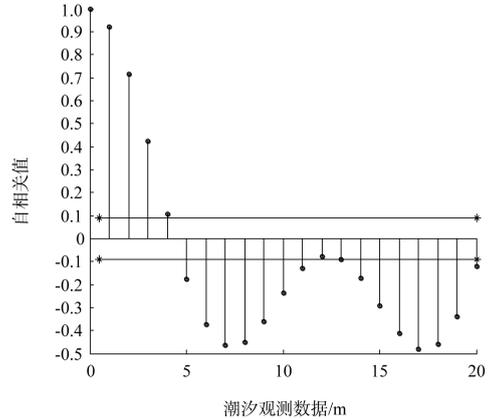


图 2 潮汐实测数据自相关分析

第 1 步: 载入实测潮汐数据, 并将数据归一化处理。创建 BP 神经网络并设置 SAPSO 优化算法, SAPSO-BP 网络模型的网络参数 $c_1 = c_2 = 1.55$, 迭代寻优次数为 200, 种群规模为 20, 每个例子的初始速度限制在 $[-3, 3]$, 每个粒子的初始位置限制在 $[-5, 5]$ 。

第 2 步: 将 BP 神经网络的网络参数初始化为 SAPSO 优化算法的粒子位置, BP 神经网络的网络参数包括: 输入层与隐含层之间的权值、隐含层阈值、隐含层与输出层之间的权值以及输出层阈值。根据适应度函数公式计算粒子初始适应度值。

第 3 步: 在每一次迭代过程中, 粒子根据更新公式更新自身的速度和位置, 并根据误差函数计算新的适应度函数值, 然后在 PSO 算法中引入自适应变异操作, 根据自适应变异公式计算并更新粒子个体极值和群体极值。

第 4 步: 判断最优个体适应度函数值是否满足误差设置要求, 或者迭代寻优次数是否达到设置要求, 如果满足要求则执行下一步, 否则返回第 3 步继续进行循环迭代寻优。

第 5 步: 结束 SAPSO 优化算法的迭代寻优, 将寻优得到的最优网络参数赋值给 BP 神经网络进行仿真试验。

第 6 步: 设置 BP 神经网络的网络参数, 迭代

次数为100、学习率为0.1、学习目标为0.00001。然后将最优网络参数赋给BP神经网络进行潮汐实时预测仿真试验。

3 仿真结果与讨论

为了定量计算出不同预测模型的预测精度,引入均方根误差(RMSE)和相关系数(CC),公式如下:

$$RMSE = \sqrt{\frac{\sum_{k=1}^n (y_k - \hat{y}_k)^2}{N}} \quad (8)$$

$$CC = \frac{\sum_{k=1}^n (y_k - \bar{y}_k)(\hat{y}_k - \bar{\hat{y}}_k)}{\sqrt{\sum_{k=1}^n (y_k - \bar{y}_k)^2 \sum_{k=1}^n (\hat{y}_k - \bar{\hat{y}}_k)^2}} \quad (9)$$

式中: N 为样本的数目; y_k 和 \bar{y}_k 分别代表观测值和观测值的平均值; \hat{y}_k 和 $\bar{\hat{y}}_k$ 分别代表预测值和预测值的平均值。

3.1 调和分析模型的潮位预报

如图3所示,预测值与实测值之间的变化趋势基本是吻合的,但是两者之间的误差也是相当明显的,引起潮汐水位变化的原因是很复杂的,然而调和分析模型仅仅考虑了天体引潮力线性影响部分,而忽略了由时变因素非线性部分引起的潮汐水位变化。调和分析模型预测值与观测值之间的比较见图4,两者的相关系数 $CC=0.9618$ 。

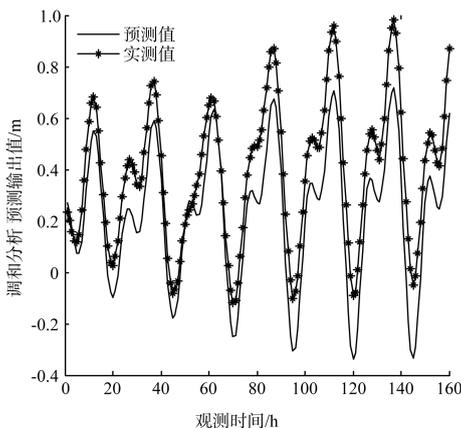


图3 调和分析预测模型

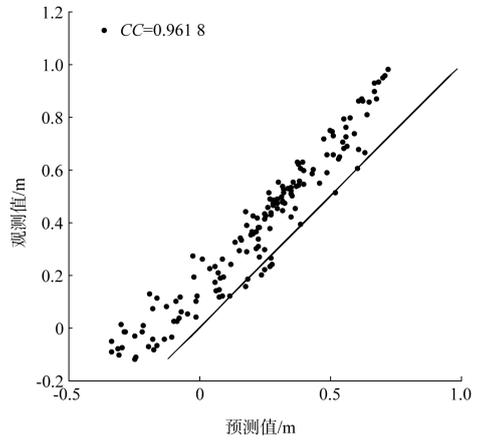


图4 调和模型预测值和实测值之间的比较

3.2 BP模型的潮位预报

如图5所示,BP预测模型的预测值和实测值之间的吻合情况明显要优于调和分析预测模型,因为BP网络模型考虑了引起潮汐水位变化的非线性时变因素部分,而且BP神经网络对于非线性拟合有着更强的映射能力。图6所示的BP模型预测值和实测值比较,两者的相关系数 $CC=0.9870$ 。

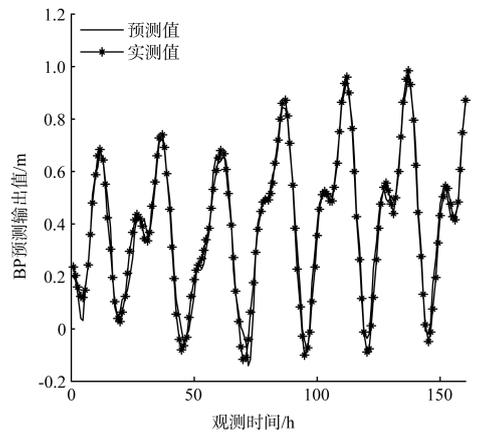


图5 BP预测模型

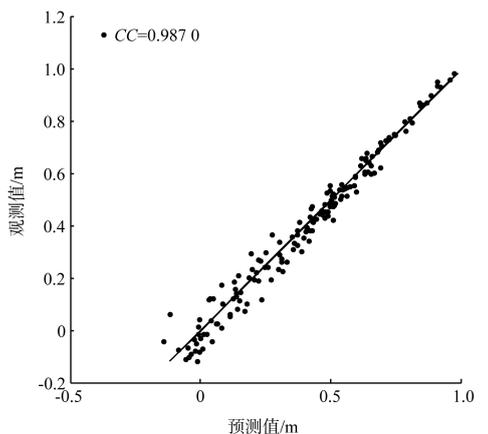


图6 BP模型预测值和实测值之间的比较

3.3 SAPSO-BP 模型的潮位预报

如图 7 所示, 改进的预测模型预测值与实测值之间的吻合情况非常好, 明显优于调和模型和 BP 模型。图 8 为 SAPSO-BP 模型预测值和实测值之间的比较, 两者之间的相关系数 $CC = 0.9989$, 说明两者之间的相关性很强。由图 8 同时可以分析出, 预测值与观测值之间的偏差非常小。

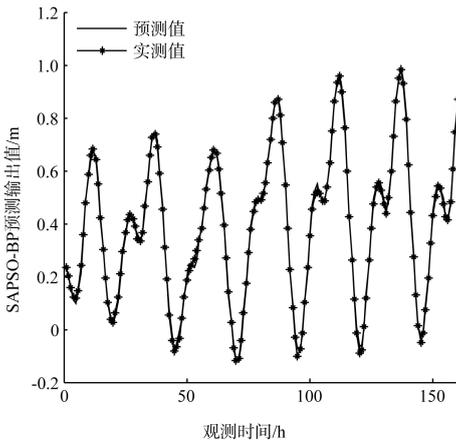


图 7 SAPSO-BP 预测模型

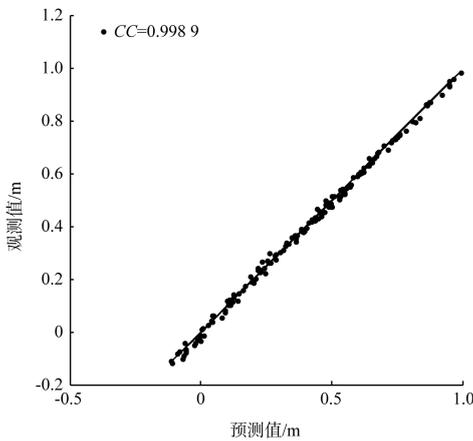


图 8 SAPSO-BP 模型预测值和实测值之间的比较

3.4 仿真结果

仿真试验使用相同的实测潮汐数据进行网络训练, 得到的调和模型、BP 模型以及 SAPSO-BP 模型的均方误差分别为 0.178 7、0.044 6 和 0.013 1。经计算分析, SAPSO-BP 预测模型的预报精度相对于调和模型和 BP 预测模型分别提高了 92.6%、70.6%。可见经改进的自适应变异粒子群优化算法训练的 BP 神经网络混合预报模

型的预测精度有了很大的提高。

3.5 SAPSO-BP 预测模型的泛化能力和实用性

为了进一步验证改进预测模型的泛化能力和实用性, 选择美国 3 个港口的实测潮汐水位数据作为测试数据库, 在相同的仿真条件以及相同的仿真试验环境下分别运用调和模型和 SAPSO-BP 模型进行仿真试验, 试验结果见表 1。

表 1 预测结果对比

潮汐观测站	调和模型		SAPSO-BP 模型	
	RMSE/m	CC	RMSE/m	CC
Charleston	0.756 6	0.972 2	0.177 2	0.996 4
Pilots Station	0.740 1	0.674 3	0.158 3	0.966 8
Honolulu	0.300 8	0.790 4	0.071 7	0.982 9

4 结论

1) 采用 SAPSO 优化算法应用于传统 BP 神经网络模型的网络参数优化中, 克服了传统 BP 网络模型对初始权值阈值敏感、容易陷入局部极小值的缺点, 同时也克服了传统 PSO 算法的容易早熟收敛、搜索准确度低、迭代效率较低等缺点。提高了 PSO 算法的全局搜索能力, 拓展了种群搜索的空间范围。

2) 将 SAPSO-BP 混合预测模型应用于 Isabel 港口的实测潮汐值数据预测仿真, 仿真试验将该混合算法预测模型与传统的 BP 预测模型和调和模型预测模型进行比较, 验证了 SAPSO-BP 混合预测模型预测精度较高、收敛速度也相对较快、同时也具有良好的泛化性能。它为潮汐水位的实时预报提供了一种有效途径。

3) 本文仅仅使用 SAPSO-BP 模型进行潮汐水位的较短期预报, 即一个月之内的潮汐水位预报。使用 SAPSO-BP 预测模型进行长期的潮汐观测数据预测值与实测数据比较, 并进一步提高预测模型的精度, SAPSO-BP 预测模型可以在一定程度上取代传统调和模型。因此使用该模型进行潮位水位的长期预报将是接下来的主要研究工作和研究方向。

参考文献:

[1] 郭禹, 张吉平, 戴冉.航海学[M].大连: 大连海事大学出版社, 2014.

[2] TSAI C P, LEE T L. Back-propagation neural network in tidal-level forecasting [J]. Journal of waterways, port, coastal, and ocean engineering, 1999, 125(4): 195-202.

[3] LEE T L. Back-propagation neural network for long-term tidal prediction [J]. Ocean engineering, 2004, 31 (2): 255-238.

[4] LI M C, LIANG S X, SUN Z C. Application of artificial neural networks to tide forecast [J]. Journal of Dalian University of Technology, 2007, 47(1): 101-105.

[5] YU S, ZHU K, DIAO F. A dynamic all parameters adaptive BP neural networks model and its application on oil reservoir prediction[J]. Applied mathematics and computation, 2008, 195(1): 66-75.

[6] LI G, HAO Y L, ZHAO Y X. Research of neural network to tidal prediction [C]. Proceedings of International Joint Conference on Computational Science and Optimization, 2009: 282-284.

[7] JAIN P, DEO M C. Real-time wave forecasts off the western Indian coast [J]. Applied ocean research, 2007, 29(1): 72-79.

[8] YIN J C, ZOU Z J, XU F. Sequential learning radial basis function network for real-time tidal level predictions [J]. Ocean engineering, 2013, 57(2): 49-55.

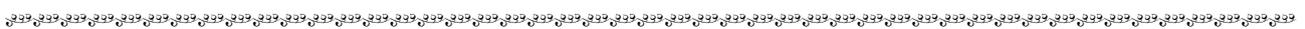
[9] LIN Y J. Prevention of transient instability employing rules based on back propagation based ANN for series compensation [J]. International journal of electrical power & energy systems, 2011, 33(10): 1 776-1 783.

[10] BASERI H. Modeling of spring-back in V-die bending process by using fuzzy learning back-propagation algorithm [J]. Expert systems with application an international journal, 2011, 38(7): 8 894-8 900.

[11] 贾嵘, 薛建辉, 张文宇, 等. 基于邻域粒子群优化神经网络的异步电动机振动故障诊断 [J]. 西安石油大学学报: 自然科学版, 2010, 25(2): 73-75.

[12] KENNEDY J, EBERHART R. Particle swarm optimization [C]. Proceedings of the 1995 IEEE International Conference on Neural Networks, 1995: 1 942-1 948.

(本文编辑 武亚庆)



· 消 息 ·

中国交建多家子公司入选中国承包商 80 强和工程设计企业 60 强

由《建筑时报》和美国《工程新闻记录》(ENR)合作举办的 2016ENR/建筑时报“中国承包商 80 强和工程设计企业 60 强”颁奖典礼于 11 月 25 日在福州隆重举行, 该评选活动今年已进入第十三届。公规院以工程承包营业收入 40 003 603. 50 万元位列“中国承包商 80 强”第三名, 入选 2016 中国工程设计企业 60 强的公司有: 公规院、二公院、一公院、水规院、四航院、三航院、中咨公司、一航院。

今年的中国承包商 80 强榜单显示, 2015 年的总营业收入为 3. 59 万亿元, 年度增长率是 1. 89%。前十强的营业收入之和为 23 759 亿元, 占 80 强总营业额的 66. 18%, 相较 2014 年的 62. 34%有所上升, 其中 9 家企业营业收入均超过 500 亿元。

今年的中国工程设计企业 60 强榜单显示, 2015 年的总体设计营业收入是 1 113 亿元, 比 2014 年的 1 117 亿元略有下降; 只是由于 2015 年总承包营业收入达到了 1 008 亿元, 比 2014 年 786 亿元有了较大增长, 使得 2015 年中国工程设计企业 60 强的总体营业收入(设计营业收入+总承包营业收入)达到了 2 121 亿元, 同比上升 11. 46%。