

改进型 BP 神经网络的港口吞吐量预测

陈锦文^{1,2}, 兰培真^{1,2}

(1. 集美大学海上交通安全研究所, 福建 厦门 361021;
2. 交通安全应急信息技术国家工程实验室, 福建 厦门 361021)

[摘要] 为了提高港口吞吐量预测模型的适用性, 满足港口决策的需求, 对传统时间序列 BP 神经网络预测模型进行改进, 将未来三年的吞吐量作为输出层参数, 以 tansig 函数和 logsig 函数为传递函数, 建立了改进型时间序列 BP 神经网络预测模型, 利用 trainlm 函数训练神经网络, 预测未来三年的港口吞吐量。对深圳港集装箱吞吐量进行了预测, 结果表明, 改进型时间序列 BP 神经网络模型泛化能力更强, 拟合精度更高, 且避免了传统预测模型循环预测产生的误差叠加, 具有较好的适用性。

[关键词] 港口吞吐量; 时间序列; BP 神经网络; 预测模型

[中图分类号] U 691.71

Port Throughput Prediction Based on Improved BP Neural Network

CHEN Jinwen^{1,2}, LAN Peizhen^{1,2}

(1. Maritime Traffic Safety Institute, Jimei University, Xiamen 361021, China;
2. National Engineering Laboratory for the Emergency Information Technology of Traffic Safety, Xiamen 361021, China)

Abstract: In order to improve the applicability of the port throughput prediction model and meet the requirements of port decision-making the traditional prediction model of time series based on BP neural network is improved. An improved prediction model of time series based on BP neural network is established by taking the throughput of the next three years as the output layer parameter. Meanwhile, the functions of tansig and logsig are used as the transfer function. The function of trainlm is utilized to train the neural network to predict the port throughput of the next three years. The forecasting of container throughput of Shenzhen Port indicates that the improved prediction model of time series based on BP neural network has stronger ability of generalization and higher fitting degree. As a result, it avoids the error superposition generated by the loop prediction of traditional model and has good applicability.

Keywords: port throughput; time series; BP neural network; predicting model

0 引言

港口吞吐量预测对港口的建设发展具有极其重要的意义。神经网络由于具有良好的非线性拟合能力, 被广泛应用于港口吞吐量预测。目前, 神经网络在港口吞吐量预测中的研究主要集中在时间序列和影响因素两方面^[1,2]。席申娥^[3]在灰色时间序列和 ARIMA 模型的基础上构建了 RBF 神经网络吞吐

[收稿日期] 2019-06-10

[作者简介] 陈锦文(1995—), 男, 硕士生, 从事交通信息工程及控制研究。通信作者: 兰培真(1962—), 女, 教授, 交通安全应急信息技术国家工程实验室理事, 博士, 从事交通信息工程及控制、海上交通安全保障研究。E-mail: peizlan@163.com

量预测模型。张树奎等^[4]利用灰色模型和 BP 神经网络构建了灰色神经网络模型, 提高了预测精度。刘志杰等^[5]利用径向基神经网络对灰色预测模型和三次多项式预测模型进行组合预测。唐飞^[6]根据历史数据, 利用 BP 神经网络模型对泸州港的货物吞吐量进行预测。Ruiz – Aguilar. J. J 等^[7]建立了基于 SARIMA 模型和人工神经网络的时间序列组合预测模型。Zhang P. 等^[8]分别构建了基于 BP 神经网络和 Elman 神经网络的组合预测模型。刘长俭等^[9]在历史数据的基础上利用时间序列神经网络对集装箱吞吐量进行预测。Lili Mo 等^[10]利用 BP 神经网络对港口集装箱吞吐量的子序列进行预测。Camelo H. 等^[11]分别将 ARIMA 模型和 Holt – Winters 模型与神经网络结合, 应用于时间序列的预测。Yunxuan Dong 等^[12]利用不同的策略构建并训练神经网络, 对时间序列进行预测。

然而, 上述传统的时间序列神经网络预测模型只能预测未来一期的数据, 当需要预测未来多期的数据时, 一般以预测的第一期数据作为输入值来进行循环预测, 从而造成了误差的叠加。本文对传统模型进行改进, 建立了改进型时间序列 BP 神经网络预测模型, 可避免循环预测导致的误差叠加, 既保留了 BP 神经网络良好的非线性拟合能力, 又提高了时间序列 BP 神经网络预测模型的适用性。

1 传统时间序列 BP 神经网络预测模型

记第 n 年 ($n \in \mathbf{N}_+$) 的港口吞吐量实际值为 F_n , 第 n 年 ($n \in \mathbf{N}_+$) 的港口吞吐量预测值为 T_n 。

传统时间序列 BP 神经网络预测模型 (以下简称传统预测模型) 将历史数据 $\{F_{n-4}, F_{n-3}, F_{n-2}, F_{n-1}\}$ 作为输入层参数, 将未来一期的港口吞吐量 $\{T_n\}$ 作为输出层参数^[9], 构建了如图 1 所示的 BP 神经网络模型。




图 1 传统时间序列 BP 神经网络预测模型
Fig.1 Traditional prediction model of time series based on BP neural network

$S_{input} = \{F_{n-4}, F_{n-3}, F_{n-2}, F_{n-1}\}, S_{output} = \{T_n\}。$

隐含层节点数由预测精度确定。

若预测未来多期港口吞吐量, 传统预测模型需不断更新 S_{input} , 进行循环预测, 最终输出各期预测结果。

2 改进型时间序列 BP 神经网络预测模型

2.1 改进依据

BP 神经网络中, 隐含层节点输出模型和输出层节点输出模型分别如式 (1) 和式 (2) 所示。

$$O_j = f(\sum W_{ij} \times x_i - q_i); \tag{1}$$

$$y_k = f(\sum V_{jk} \times O_j - q_k)。 \tag{2}$$

其中: f 为非线性作用函数; W_{ij} 是输入层节点 i 与隐含层节点 j 之间的连接权值; x_i 为输入层节点 i 的输入值; V_{jk} 为隐含层节点 j 与输出层节点 k 之间的连接权值; q 为节点阈值。

结合式 (1) 和式 (2), 可以得出输出层节点 k 的输出值 y_k 与输入层节点 i 的输入值 x_i 存在如下关系:

$$y_k = g(W_{ij}, x_i, q_i, V_{jk}, q_k)。 \tag{3}$$

其中: g 为任意线性或非线性作用函数。

神经网络反复学习训练后可确定 W_{ij}, q_i, V_{jk} 和 q_k 。因此, 神经网络可通过训练确定各输出层节点的输出值 y_k 与各输入层节点的输入值 x_i 间的线性或非线性关系。

2.2 结构设计

未来 3 年的吞吐量对于港口的规划及投资规模至关重要。为了提高模型的适用性, 本文将未来三年的港口吞吐量作为 BP 神经网络的输出层参数, 建立了改进型时间序列 BP 神经网络预测模型 (以

下简称改进型预测模型)，其结构如图 2 所示。

$$S_{\text{input}} = \{F_{n-4}, F_{n-3}, F_{n-2}, F_{n-1}\}, S'_{\text{output}} = \{T_n, T_{n+1}, T_{n+2}\}。$$

隐含层节点个数为

$$m = \sqrt{a + b} + c^{[13]}。$$

(4)

其中： m 为隐含层节点个数； a 为输入层节点个数； b 为输出层节点个数； c 为 $[1, 10]$ 之间的整数。

对于改进型预测模型， $a = 4$ ， $b = 3$ ，故 $m \in [\sqrt{7} + 1, \sqrt{7} + 10]$ ，且 $m \in \mathbf{Z}$ ，即 m 为区间 $[4, 12]$ 内的整数。最终，根据神经网络的测试精度确定隐含层节点数。

改进型预测模型通过样本学习可确定如式（5）所示的数量关系，

$$T_k = g(F_i)。$$

(5)

其中： $k \in \{n, n + 1, n + 2\}$ ； $i \in \{n - 1, n - 2, n - 3, n - 4\}$ 。

即改进型预测模型通过样本学习可确定需要预测的各年吞吐量与历史数据中各年吞吐量之间的关系。

2.3 训练函数与传递函数的确定

由于改进型预测模型的网络结构较传统预测模型更复杂，因此，为获取更好的训练效果和预测精度，网络隐含层采用 tansig 函数，如式（6）所示，其输入值可取任意值，其输出值位于区间 $(-1, 1)$ 。

$$\text{tansig}(x) = 2/(1 + e^{-2x}) - 1。$$

(6)

网络输出层采用 logsig 函数，如式（7）所示，其输入值可取任意值，其输出值位于区间 $(0, 1)$ 。

$$\text{logsig}(x) = 1/(1 + e^{-x})。$$

(7)

tansig 函数和 logsig 函数，其输出值均在有限区间内，减小了神经网络的规模，缩短了神经网络的学习时间，有效简化了模型。

由于 trainlm 函数能够根据训练误差自动调节训练参数，使神经网络实时采取适宜的训练方法，因此，本文利用 trainlm 函数训练神经网络，以获得更好的训练效果。

3 改进型预测模型验证及分析

以深圳港 1997—2018 年的集装箱吞吐量为样本数据，对改进型预测模型进行验证。样本数据如表 1 所示。

表 1 深圳港 1997—2018 年的集装箱吞吐量

Tab.1 Container throughput of Shenzhen Port from 1997 to 2018

年份	集装箱吞吐量	年份	集装箱吞吐量
Year	Container throughput/(万 TEU)	Year	Container throughput/(万 TEU)
1997	114.70	2008	2141.62
1998	195.20	2009	1825.01
1999	298.60	2010	2250.97
2000	399.40	2011	2257.08
2001	507.20	2012	2294.13
2002	761.40	2013	2327.80
2003	1065.00	2014	2403.00
2004	1365.60	2015	2421.00
2005	1619.70	2016	2398.00
2006	1846.90	2017	2520.86
2007	2110.40	2018	2573.59

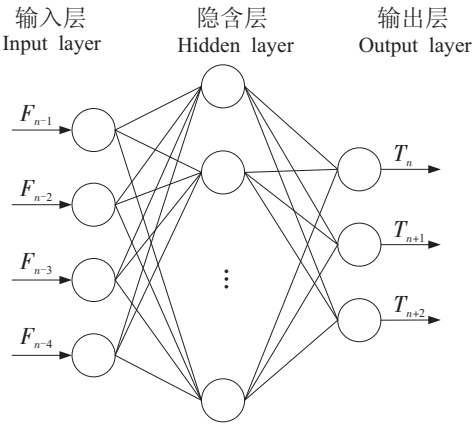


图 2 改进型时间序列 BP 神经网络预测模型
Fig.2 Improved prediction model of time series based on BP neural network

本文取深圳港连续 7 年的集装箱吞吐量为一组样本, 1997—2018 年深圳港集装箱吞吐量数据共可得到 16 组样本。为了保证神经网络的学习效果, 本文将前 15 组样本作为神经网络的训练样本, 利用最后 1 组样本测试神经网络。

由图 1 可知, 传统预测模型输入层节点个数 $a = 4$, 输出层节点个数 $b = 1$, 因此, 其隐含层节点个数 $m \in [\sqrt{5} + 1, \sqrt{5} + 10]$ 且 $m \in \mathbf{Z}$, 即 m 为区间 $[4, 12]$ 内的整数, 与改进型预测模型隐含层节点数取值范围一致。由于训练的 BP 神经网络是否具有良好的泛化能力和拟合精度主要取决于训练后网络的均方误差, 因此本文将各隐含层节点数下, 传统与改进型 BP 神经网络预测模型的训练均方误差进行对比, 如表 2 所示。

表 2 各隐含层节点数下模型改进前后均方误差对比
Tab. 2 Comparison of mean square error between traditional and improved model under different numbers of hidden layer nodes

隐含层节点数 Hidden layer nodes	传统预测模型的训练均方误差 Training mean square error of traditional prediction models	改进型预测模型的训练均方误差 Training mean square error of improved prediction models	改进型预测模型较传统预测模型训练均方误差减少百分比 Reduced percentage of mean square error of improved prediction model compared to traditional prediction model/%
4	0.013 640	0.005 920	56.60
5	0.009 248	0.007 975	13.77
6	0.009 389	0.004 449	52.61
7	0.008 817	0.007 396	16.12
8	0.009 322	0.004 615	50.49
9	0.008 109	0.002 742	66.19
10	0.006 294	0.003 999	36.46
11	0.004 108	0.000 431	89.50
12	0.009 671	0.005 941	38.57

由表 2 可以看出, 各隐含层节点数下, 改进型预测模型的训练均方误差均小于传统预测模型, 平均减少了 46.70%, 其中, 当隐含层节点数为 11 时, 减少了 89.50%, 因此具有更强的泛化能力和更高的拟合精度。

神经网络训练完成后, 将 2012—2015 年深圳港集装箱吞吐量输入神经网络, 预测 2016—2018 年的集装箱吞吐量。

将不同隐含层节点数下的输出值 $\{T_{2016}, T_{2017}, T_{2018}\}$ 与实际值 $\{F_{2016}, F_{2017}, F_{2018}\}$ 进行比较, 并根据式 (8) ~ 式 (10) 计算相对误差, 具体如表 3 所示。

$$\varepsilon_n^l = |T_n^l - F_n| / F_n \times 100\%;$$

(8)

$$\bar{\varepsilon}_n = (\sum_{l=4}^{12} \varepsilon_n^l) / 9;$$

(9)

$$\bar{\varepsilon}^l = (\sum_{n=2016}^{2018} \varepsilon_n^l) / 3.$$

(10)

其中: ε_n^l 为隐含层节点数为 l 时, 第 n 年的预测误差; T_n^l 为模型的隐含层节点数为 l 时, 第 n 年集装箱吞吐量的预测值; $\bar{\varepsilon}_n$ 为模型在各隐含层节点数下, 第 n 年预测误差的平均值; $\bar{\varepsilon}^l$ 为模型在隐含层节点数为 l 时, 各年份预测误差的平均值, 即测试样本的误差均值。

不同隐含层节点数下测试样本验证误差如表 3 所示。从表 3 可知, 不同隐含层节点数下 2016—2018 年预测的误差平均值分别为 1.31%, 1.89%, 2.48%。

不同隐含层节点数下测试样本预测误差的平均值最大为 2.92%, 最小为 1.38%, 均在合理范围之内。

表 3 不同隐含层节点数下测试样本验证误差
Tab.3 Test sample verification error under different numbers of hidden layer nodes

隐含层节点数 Hidden layer nodes	预测值(万 TEU) Predictive value(Ten thousand TEU)	相对误差 Relative error/%			测试样本预测 误差平均值 The average error of test sample prediction
		2016	2017	2018	
4	{2408.46,2467.62,2532.42}	0.44	2.11	1.6	1.38
5	{2369.99,2477.62,2508.35}	1.17	1.72	2.54	1.81
6	{2466.43,2468.05,2553.48}	2.85	2.1	0.78	1.91
7	{2395.19,2462.73,2624.15}	0.12	2.31	1.96	1.46
8	{2363.28,2515.18,2501.68}	1.45	0.23	2.8	1.49
9	{2389.29,2431.93,2491.60}	0.36	3.53	3.19	2.36
10	{2437.87,2433.33,2480.38}	1.66	3.47	3.62	2.92
11	{2367.01,2526.40,2475.13}	1.29	0.22	3.83	1.78
12	{2340.29,2554.07,2625.42}	2.41	1.32	2.01	1.91

在相同隐含层节点数下，基于时间序列 BP 神经网络传统预测模型与改进型预测模型的误差分别如图 3 和图 4 所示。




图 3 传统预测模型各隐层节点数下的误差
Fig.3 The error of traditional prediction model under different numbers of hidden nodes




图 4 改进型预测模型各隐层节点数下的误差
Fig.4 The error of improved prediction model under different numbers of hidden nodes

由图 3 可以看出，传统预测模型预测相对误差满足 $\varepsilon_{2016}^l \in [0\%, 3\%]$, $\varepsilon_{2017}^l \in [1\%, 6\%]$, $\varepsilon_{2018}^l \in [5\%, 10\%]$, 且 $\varepsilon_{2018}^l > \varepsilon_{2017}^l > \varepsilon_{2016}^l$ (其中 $l = 4, 5, 6, \dots, 12$)。由于传统预测模型预测未来多年的吞吐量，需将本次预测的输出值作为下次预测的输入值，造成了误差的叠加，导致预测误差不断增大，从而降低了整体预测精度。

改进型预测模型在不同隐含层节点数下，各年份预测的相对误差均值分别为 $\bar{\varepsilon}_{2016} = 1.31\%$, $\bar{\varepsilon}_{2017} = 1.89\%$, $\bar{\varepsilon}_{2018} = 2.48\%$ 。结合图 4 可知，改进型预测模型各隐含层节点数下，2016—2018 年集装箱吞吐量的预测误差均小于 4%，同时不存在误差的叠加。当隐含层节点数为 4 时，测试样本预测误差最小，即 $\bar{\varepsilon}^l|_{\min} = \bar{\varepsilon}^4 = 1.38\%$ 。此时， $\varepsilon_{2016}^4 = 0.44\%$, $\varepsilon_{2017}^4 = 2.11\%$, $\varepsilon_{2018}^4 = 1.60\%$ 。

综上所述，改进型预测模型可提高网络的泛化能力和预测精度，对于港口吞吐量预测具有更好的适用性。

4 结 语

本文对传统时间序列BP神经网络预测模型进行改进,将 $\{T_n, T_{n+1}, T_{n+2}\}$ 作为输出层参数,以tansig函数和logsig函数为传递函数,建立了改进型时间序列BP神经网络预测模型,并利用trainlm函数训练神经网络,既保留了BP神经网络良好的非线性拟合能力,同时提高了网络泛化能力和拟合精度,且避免了传统预测模型循环预测导致的误差叠加,可预测未来3年的港口吞吐量,为港口吞吐量的中短期预测提供了一种精度较高的新方法,具有更好的适用性。

[参 考 文 献]

- [1] 孔琳琳,刘澜,许文秀,等. 基于时间序列分析的港口集装箱吞吐量预测分析[J]. 森林工程, 2016, 32(5): 106-110.
- [2] 查茜. 港口集装箱吞吐量时间序列预测方法研究[D]. 重庆:重庆大学, 2016.
- [3] 席申娥. 基于双时间序列-RBF神经网络的沿海港口吞吐量预测研究[J]. 智能城市, 2016(9): 157-159.
- [4] 张树奎,肖英杰,鲁子爱. 基于灰色神经网络的港口集装箱吞吐量预测模型研究[J]. 重庆交通大学学报(自然科学版), 2015, 34(5): 135-138.
- [5] 刘志杰,季令,叶玉玲,等. 基于径向基神经网络的集装箱吞吐量组合预测[J]. 同济大学学报(自然科学版), 2007, 35(6): 739-744.
- [6] 唐飞. 基于BP神经网络的泸州港货物吞吐量预测[J]. 物流工程与管理, 2015, 37(9): 58-59.
- [7] RUIZ-AGUILAR J J, TURIAS I J, JIMÉNEZ-COME M J. Hybrid approaches based on SARIMA and artificial neural networks for inspection time series forecasting[J]. Transportation Research Part E, 2014, 67(7): 1-13.
- [8] ZHANG P, CUI Y. Research on combination forecast of port container throughput based on elman neural network[C] // 2011 IEEE 3rd International Conference on Communication Software and Networks. Xian: IEEE, 2011: 567-570.
- [9] 刘长俭,张庆年. 基于时间序列BP神经网络的集装箱吞吐量动态预测[J]. 水运工程, 2007, 33(1): 4-11.
- [10] LILI MO, LING XIE, XIAOYI JIANG, et al. GMDH-based hybrid model for container throughput forecasting: Selective combination forecasting in nonlinear subseries[J]. Applied Soft Computing, 2018, 62(1): 478-490.
- [11] CAMELO H, LUCIO P, JUNIOR J. et al. Innovative hybrid models for forecasting time series applied in wind generation based on the combination of time series models with artificial neural networks[J]. Energy, 2018, 151(10): 347-357.
- [12] YUNXUAN DONG, JIANZHOU WANG, ZHENHAI GUO. Research and application of local perceptron neural network in highway rectifier for time series forecasting[J]. Applied Soft Computing, 2018, 64(2): 656-673.
- [13] 飞思科技产品研发中心. 神经网络理论与MATLAB7实现[M]. 北京:电子工业出版社, 2005: 102-103.

(责任编辑 陈 敏 英文审校 周云龙)