

文章编号: 1671-6833(2019)05-0084-07

# 基于 BP-RBF 神经网络的组合模型预测港口物流需求研究

蔡婉贞<sup>1</sup>, 黄 翰<sup>2</sup>

(1. 汕头职业技术学院 经济管理系, 广东 汕头 515078; 2. 华南理工大学 软件学院, 广东 广州 510006)

**摘 要:** 为了准确、高效地预测港口物流需求量, 提出一种基于 BP-RBF 神经网络的组合预测模型。考虑到物流需求的非线性变化特点, 在建模过程中首先采用 BP 与 RBF 两种神经网络方法分别建立单项预测子模型, 然后依据各子模型预测结果赋予不同权重进一步构建加权组合预测模型。再以汕头港为例, 通过 MATLAB 软件对港口物流需求量进行仿真预测。结果表明, 组合预测模型较单一预测模型具有更高的预测精度, 能有效减少出现较大误差的概率, 使预测结果更接近于实际情况, 可为港口今后物流发展规划提供参考。

**关键词:** BP 神经网络; RBF 神经网络; 组合模型; 预测; 港口物流需求

中图分类号: TP183; F552.7

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2019.02.025

## 0 引言

随着粤东沿海产业带建设的快速推进, 汕头港口物流将迎来更大的发展机遇和挑战。对港口的物流需求进行精准的预测, 将为港口物流产业发展以及物流基础设施规划设计提供可靠的数据支持。目前用于物流需求预测的理论方法可分为定性和定量两大类<sup>[1]</sup>。定性预测方法主要包括德尔菲法、专家调查法、主观概率法等。定性预测法较灵活, 预测简单迅速, 但易受主观因素的影响, 难以对物流需求作数量上的精确描述。定量预测法则是利用历史数据或因素变量来预测未来物流需求的数学模型。传统港口物流需求定量预测方法主要有回归分析法<sup>[2]</sup>、移动平均法<sup>[3]</sup>、指数平滑法<sup>[4]</sup>等。然而, 物流系统是一个非常复杂的非线性系统, 物流需求受多种因素共同影响, 既存在一定的规律性, 又具有很强的随机性, 这使得传统的预测模型很难准确反映出各因素之间的复杂映射关系, 从而影响预测结果的准确性。基于黑箱理论的人工神经网络是模仿大脑神经网络的结构和功能而建立的一种数学模型, 凭借其非线性处理、自适应学习、高容错能力等特性, 可以较轻松地实现非线性映射过程, 广泛应用于非线性系统以及模型未知系统的预测控制<sup>[5-6]</sup>。BP 神经网络和 RBF

神经网络是两种常用的人工神经网络中, 两者均属于前向型神经网络, 其中 BP 神经网络是一种按照误差反向传播算法训练的多层神经网络, 属于典型的全局逼近网络, 该神经网络模型无论在网络理论还是在性能方面均比较成熟, 具有较强的非线性映射能力和柔性网络结构<sup>[7-9]</sup>。BP 神经网络也存在收敛速度慢、容易陷入局部极小值的缺点, 难以保证学习结果达到均方误差的全局最小。与 BP 神经网络不同, RBF 神经网络是一种局部逼近网络, 只要有足够多的隐层神经元, RBF 神经网络就能够以任意精度逼近任何连续非线性函数, 具有训练速度快、不易陷入局部极小值等优点<sup>[10-11]</sup>。当算例中样本数据较多时, 应用单一神经网络模型进行训练易出现过拟合问题, 影响网络预测效果。鉴于港口物流需求量具有明显的不确定性和非线性特征, 笔者拟将人工神经网络方法引入到港口物流需求预测中, 分别构建 BP 神经网络和 RBF 神经网络预测模型。考虑到单一预测方法在实际预测中预测效果并不稳定, 得出的预测结果与实际值可能存在较大偏差, 为综合利用各神经网络模型的优点提高预测精度, 笔者拟将上述单项模型预测结果按照误差平方和最小的原则计算各自的权系数, 加权构建组合预测模型, 并以汕头港为例进行实证分析。

收稿日期: 2018-09-11; 修订日期: 2018-11-12

基金项目: 国家自然科学基金资助项目(61370102)

作者简介: 蔡婉贞(1982—), 女, 广东汕头人, 汕头职业技术学院讲师, 硕士, 主要从事物流管理研究, E-mail: 47653812@qq.com.

## 1 预测方法

### 1.1 BP 神经网络

BP 神经网络包括输入层、中间层和输出层。在整个网络中,为实现纵向全连接,横向每层的神经元间无连接,是一种按误差逆传播算法训练的前馈网络。它利用网络的实际输出和期望输出之间的误差最小对网络的多层连接权值和阈值由后向前逐层进行修正。随着这种误差逆向传播修正不断进行,神经网络对输入模式响应的正确率也不断提高。构建 BP 神经网络模型时,首先给每个连接权值和阈值赋予  $(-1, 1)$  内的随机值;然后从训练样本中随机选取一组样本输入向量  $P_k = (p_1, p_2, \dots, p_n)$  和期望输出向量  $Q_k = (q_1, q_2, \dots, q_l)$  提供给网络。接着用输入向量  $P_k$ 、连接权  $v_{ij}$  和阈值  $\theta_j$  计算隐层各单元的输入,然后利用该输入通过传递函数  $f$  计算隐层各单元的输出,

$$O_j = f\left(\sum_{i=1}^n v_{ij} p_i - \theta_j\right), \quad (1)$$

式中:  $i$  为输入层的维数 ( $i=1, 2, \dots, n$ )。然后用隐层的输出  $O_j$ 、连接权  $w_{ji}$  和  $\psi_i$  阈值计算输出层各单元的输入,然后利用该输入通过传递函数  $f$  计算输出层的响应,即网络的实际输出,

$$Y_i = f\left(\sum_{j=1}^p w_{ji} O_j - \psi_i\right), \quad (2)$$

式中:  $j$  为隐层的维数 ( $j=1, 2, \dots, p$ )。

式(1)、式(2)中,传递函数  $f$  通常选用 sigmoid 型函数,

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (3)$$

再利用网络期望输出向量  $Q_k$  和网络实际输出向量  $Y_i$  计算出输出层的校正误差,

$$d_i^k = (q_i^k - Y_i) f'\left(\sum_{j=1}^p w_{ji} O_j - \psi_i\right), \quad (4)$$

式中:  $f'$  为输出层函数的导数。接着利用该误差、连接权  $w_{ji}$  和隐层各单元的输出计算出隐层的校正误差,

$$e_j^k = \left(\sum_{i=1}^q w_{ji} d_i^k\right) f'\left(\sum_{i=1}^n v_{ij} p_i - \theta_j\right). \quad (5)$$

求得上述校正误差后,再利用该误差沿逆方向逐层修正输出层至隐层、隐层至输入层的连接权值和阈值。其校正量分别为:

$$\Delta w_{ji} = \alpha d_i^k O_j, \quad (6)$$

$$\Delta \psi_i = \alpha d_i^k, \quad (7)$$

式中:  $0 < \alpha < 1$ 。

$$\Delta v_{ij} = \beta e_j^k p_i^k, \quad (8)$$

$$\Delta \theta_j = \beta e_j^k, \quad (9)$$

式中:  $0 < \beta < 1$ 。

对所有的学习样本均按照上述计算方法对网络进行训练,通过重复执行以上过程,使实际输出不断逼近期望输出,直到网络全局误差函数  $E$  小于预先设定的极小值或学习次数大于预先设定的数值时,则完成网络的训练和收敛过程。

### 1.2 RBF 神经网络

RBF 神经网络属于单隐层的三层前馈网络,该网络输入层仅起到传输信号的作用,神经元的数目为样本中输入向量的维数;隐层是由一组传递函数为径向基函数的神经元构成的非线性映像层,能将低维输入数据映射到高维空间内,使其变得线性可分;输出层则对隐层的输出进行线性加权求和得到网络的最终输出。RBF 神经网络最常用的径向基函数是高斯函数,表达式为:

$$g_i(x) = \exp \frac{-\|x - c_i\|^2}{2\sigma_i^2}, \quad (10)$$

式中:  $g_i(x)$  为隐层中第  $i$  个神经元的输出;  $x$  为  $n$  维输入向量;  $c_i$  为高斯函数的中心;  $\sigma_i$  为高斯函数的方差;  $\|x - c_i\|$  为欧式范数。网络的输出为隐层神经元输出的线性加权求和,表达式为:

$$y_i = \sum_{i=1}^k w_{ij} g_i(x). \quad (11)$$

RBF 神经网络训练分为无教师式学习与有教师式学习两个阶段。第一阶段为无教师式学习,可用基于 K-means 聚类方法求取径向基函数的中心  $c_i$ ,然后计算出方差  $\sigma_i$ ,

$$\sigma_i = \frac{c_{\max}}{\sqrt{2k}}, \quad (12)$$

式中:  $c_{\max}$  为所选取中心之间的最大距离,  $i=1, 2, \dots, k$ 。通过上述学习求解径向基函数的中心和方差后,便进入第二阶段有教师式学习,即求解隐层和输出层之间神经元的连接权  $w_{ij}$ ,可用最小二乘法计算得到,

$$w_{ij} = \exp\left(\frac{k}{c_{\max}^2} \|x - c_i\|\right). \quad (13)$$

此处的权为网络可调参数。RBF 神经网络通过检查输出误差来调整径向基函数的中心  $c_i$  和连接权  $w_{ij}$ ,据此调整网络内部系数,然后再重新检查网络误差,重复此过程直到网络达到误差要求或者最大隐层神经元数时则完成网络训练。

### 1.3 组合模型

港口物流需求预测是一个十分复杂的非线性

问题,仅使用单一的预测方法进行预测往往具有片面性,如BP神经网络虽然具有良好的曲线拟合能力、抗干扰和学习能力,但该网络采用的是基于梯度下降的训练算法,容易陷入局部最优,应用该网络进行长期预测时,受传递函数的影响,预测精度会随着时间推移而降低。RBF神经网络可对非线性连续函数一致逼近且不存在局部极小问题,可并行高速地处理数据。RBF网络基函数中心是在输入样本集中选取的,有时难以反映系统真正的输入输出关系,且优选过程中有可能出现数据病态问题。如果可以综合利用上述网络模型的输出信息,赋予精度高的输出数据较高权重,精度低的输出数据占较低权重,最后将各网络模型的输出结果进行融合,不仅能够提高港口长期物流需求预测的精度,又能保障预测结果的稳定性。为将上述单项模型预测结果进行最优组合以提高预测效果,本研究采用的是一种“误差平方和最小”的加权组合预测模型,即通过求误差平方和最小值来确定最优权重系数,该方法综合了多种预测方法的优点,只要选择合适的组合权值就能有效提高预测精度。权重系数的大小与各单项预测方法的预测误差有关,误差大的预测方法相应权重小;反之,误差越小的预测方法对应的权重越大。应用 $n$ 种不同的预测模型对同一个预测对象进行预测时,其加权组合模型预测值可表示为,

$$Y_t = \sum_{i=1}^n w_i Y_{it}. \quad (14)$$

式中:  $Y_t$  为  $t$  时刻组合预测模型的预测值;  $Y_{it}$  为第  $i$  个预测模型的预测值 ( $i=1, 2, \dots, n$ );  $w_i$  为第  $i$  个预测模型的加权系数 ( $i=1, 2, \dots, n$ ); 设某一时段的实际值为  $C_t$ ; 欲使组合模型误差平方和达到最小,可构建以下方程组,

$$\begin{cases} \text{Min} \sum_{t=1}^n \left( C_t - \sum_{i=1}^n w_i Y_{it} \right)^2 = 1 \\ \sum_{i=1}^n w_i = 1 \end{cases}. \quad (15)$$

通过计算组合模型误差平方和的最小值,求各个预测模型加权系数  $w_i$  的值。在建模过程中,先通过分别构建BP神经网络和RBF神经网络预测模型,采用训练效果最佳时的预测结果作为单项模型的最终预测值,将其与实测值一起代入式(15)计算得到各单项模型的加权系数,再将各预测模型的权值代入式(15)中进一步计算得到加权组

合模型的最终预测值,组合模型具体构建流程如图1所示。

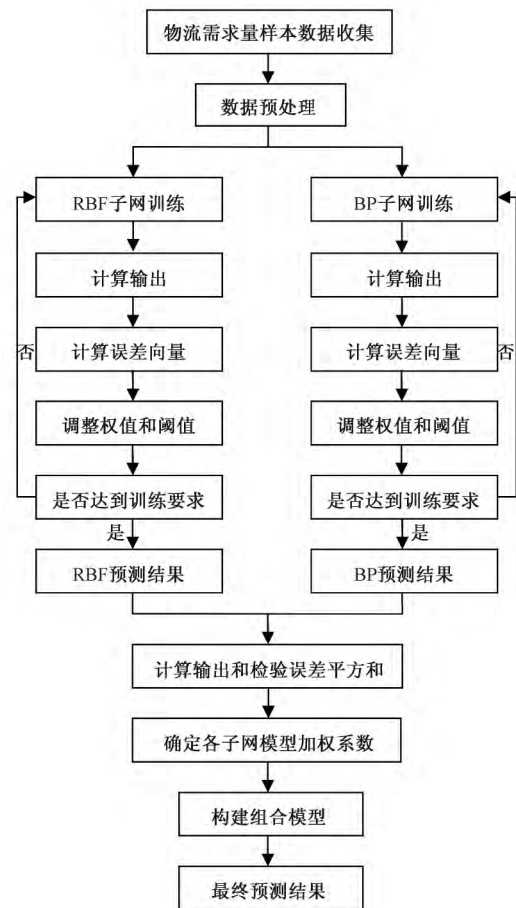


图1 算法流程图

Fig.1 Algorithm flowchart

## 2 实证分析

为了测试上述模型对港口物流需求的预测效果,笔者以汕头港为例进行实证分析。样本数据如表1所示。实证数据以2000~2017年汕头港直接经济腹地三次产业产值、进出口总额、社会消费品零售总额、固定资产投资额作为物流需求的影响因素,港口货物吞吐量作为物流需求指标。2000~2016年数据来源于广东省统计年鉴,2017年数据来自汕头港直接经济腹地各市的国民经济和社会发展统计公报。表1中,符号  $x_1$  为第一产业产值,亿元;  $x_2$  为第二产业产值,亿元;  $x_3$  为第三产业产值,亿元;  $x_4$  为进出口总额,亿美元;  $x_5$  为社会消费品零售总额,亿元;  $x_6$  为固定资产投资额,亿元;  $y$  为港口货物吞吐量,万吨。将表1中的数据分成训练集和测试集两部分,训练集为2000~2012年各项数据,测试集为2013~2017年各项数据,训练集用来数据建模,测试集用来对建立的模型

表 1 样本数据  
Tab.1 Sample data

年份	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$y$
2000	195.22	509.00	415.39	61.65	429.22	256.06	1 284.00
2001	195.39	514.48	438.03	40.87	456.88	261.04	1 309.00
2002	200.02	544.68	462.01	46.31	497.34	289.30	1 380.00
2003	205.36	611.02	500.86	57.36	540.22	330.10	1 470.00
2004	223.73	707.29	575.83	73.04	625.33	388.29	1 576.00
2005	220.85	812.99	626.03	86.06	722.86	464.55	1 736.00
2006	214.13	964.90	693.20	98.62	841.51	543.18	2 014.60
2007	240.56	1 140.01	819.32	109.00	1 007.69	655.71	2 301.04
2008	285.61	1 362.07	946.04	117.53	1 233.11	796.00	2 806.47
2009	298.09	1 469.07	1 071.70	125.87	1 479.20	1 011.35	3 101.80
2010	339.93	1 732.62	1 233.18	159.87	1 841.55	1 304.04	3 509.30
2011	392.45	2 005.35	1 449.31	185.59	2 206.18	1 492.82	4 005.00
2012	427.22	2 247.46	1 607.57	188.11	2 271.41	1 729.73	4 562.79
2013	455.61	2 543.16	1 770.54	196.06	2 519.36	2 144.42	5 037.90
2014	484.51	2 798.22	1 950.29	206.18	2 840.89	2 817.05	5 160.91
2015	516.36	2 923.35	2 183.54	219.24	3 225.41	3 596.43	5 180.90
2016	578.04	3 043.47	2 488.75	209.53	3 608.99	4 170.05	4 985.05
2017	582.69	3 306.96	2 812.43	206.17	3 985.80	4 981.53	4 889.70

进行检验.

## 2.1 BP 神经网络模型构建及仿真分析

由于数据存在不同的量纲,必须先对数据进行标准化处理,归一化公式

$$X_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}, \quad (16)$$

对样本输入进行归一化处理,使数据归一到  $[0, 1]$ . 其中  $X_i$  和  $x_i$  分别为转换前、后的值,  $x_{\max}$  和  $x_{\min}$  分别为样本的最大值和最小值. 数据归一化处理后,构建三层 BP 网络,包括一个输入层(6 个神经元),一个隐含层和一个输出层(1 个神经元). 网络隐含层神经元传递函数为  $\text{tansig}$ , 输出层神经元传递函数为  $\text{logsig}$ , 训练函数采用  $\text{trainlm}$ . 训练周期为 1 000 次,训练精度为 0.000 001. 根据 Kolmogorov 定理,当输入层的神经元为 6 个时,网络中间层的神经元可初步确定为 13 个,考虑本例的实际情况,解决该问题的网络隐含层神经元应当在 13~20 个,将它们的训练结果进行比较,如表 2 所示. 当网络隐层的神经元为 14 个时,网络的训练效果最佳,此时网络模型的平均绝对百

分误差(MAPE)最小,MAPE 表达式如下:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{\hat{Y}_t - Y_t}{Y_t} \right| \times 100\%. \quad (17)$$

使用该网络模型对 2013~2017 年的港口物流需求量进行预测,以检验网络的预测性能,即应用归一化后的测试集样本对上述训练好的网络进行仿真. 经过多次反复训练(训练结果见图 2),得到 BP 神经网络的最终预测值,再进行反归一化后便可得到 2013~2017 年的物流需求预测结果.

表 3 为预测结果. 如表 3 所示, BP 神经网络模型的预测值与真实值较为一致,除 2017 年预测结果的相对误差偏大,其余 4 年的预测值与真实值的相对误差均低于 5%. BP 神经网络模型由于初始连接权值和阈值的随机性,即使是在同一个训练集下训练,每次训练的结果也很难保证完全一致,这意味该网络训练得到的预测结果存在较大的波动<sup>[12]</sup>,因此,需经过多次反复训练才能得到精度比较理想的预测结果.

表 2 BP 神经网络训练误差

Tab.2 Training errors of BP neural network

神经元个数	13	14	15	16	17	18	19	20
网络平均绝对百分误差/%	3.11	2.85	4.94	3.66	3.09	3.55	3.08	3.14




图 2 误差性能曲线

Fig.2 Error performance curve

2.2 RBF 神经网络模型构建及仿真分析

RBF 神经网络模型输入层、输出层的确定同 BP 神经网络.利用 newrb 函数创建一个精确的神经网络,该函数在创建网络时,将自动选择隐含层的数目,使得误差为 0. MATLAB 调用程序为: net = newrb ( X \_ train , Y \_ train , SPREAD ) , SPREAD 为径向基函数的分布密度.本研究应用归一化后的训练集样本进行多次反复训练,预测曲线如图 3 所示.当 SPREAD=0.55 时,网络预测性能最佳.




图 3 不同 SPREAD 的预测曲线

Fig.3 Prediction curves with different SPREAD values

应用训练好的 RBF 神经网络模型对 2013 ~ 2017 年的物流需求进行预测,与 BP 神经网络模型预测结果相仿,RBF 神经网络模型的预测值与实际值均较为接近,其相对误差均低于 5%.由于该网络基函数中心是在输入样本集中选取的,样本数量较多时需要比 BP 神经网络更多的隐层神经元才能达到预期的训练目标,易出现过拟合现象<sup>[13-14]</sup>.因此,RBF 神经网络部分预测结果仍存在较大波动,如 2014 年预测值与实际值之间的相对误差仍高达 4.42%.

2.3 组合模型构建及仿真分析

根据上述两种神经网络模型预测结果,按照公式(15)建立方程组,求解方程组可得到 BP 网络模型加权系数为 0.377 1,RBF 网络模型加权系数为 0.622 9,按照此加权系数进行组合预测,可得到 2013 ~ 2017 年汕头港货物吞吐量的预测结果.如表 3 所示.与单项模型不同,组合模型的预测值能更好地贴合实际货物吞吐量,预测值与实际值的相对误差均低于 3%.从 2013 ~ 2017 年 5 组测试集的预测结果来看,BP 和 RBF 神经网络均存在部分年份的预测结果波动较大的问题,且 BP 神经网络预测结果波动有随时间推移逐渐增大的趋势,组合模型通过最优加权组合法将上述两种预测模型的结果进行融合,既结合 BP 与 RBF 神经网络的预测优点,又充分利用各个单项子模型的有效预测信息,经过加权处理有效降低单项模型对组合预测模型预测效果的影响,使预测结果更为稳定和可靠.

2.4 模型精度评价

笔者采用 MAPE 和误差均方根(RMSE)作为 3 种预测模型精度评价指标

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}. \quad (18)$$

表 3 组合模型预测结果

Tab.1 Simulation results

年份	真实值/万吨	BP 神经网络模型		RBF 神经网络模型		组合模型	
		预测值/万吨	相对误差/%	预测值/万吨	相对误差/%	预测值/万吨	相对误差/%
2013	5 037.90	5 065.98	-0.91	5 089.64	1.03	5 080.72	0.85
2014	5 160.91	5 148.09	-0.01	5 388.87	4.42	5 298.08	2.66
2015	5 180.90	5 177.37	-0.13	5 299.81	2.30	5 253.64	1.40
2016	4 985.05	5 180.15	3.79	5 074.40	1.79	5 114.27	2.59
2017	4 889.70	5 180.22	5.73	4 853.67	-0.74	4 976.80	1.78

预测精度比较如表 4.由表 4 可以看出,BP、RBF 神经网络模型及其组合模型预测结果精度较高.在 3 种预测模型中,组合模型的 MAPE 和

RMSE 均低于单项模型,说明使用 BP-RBF 神经网络组合模型进行预测可以有效地提高预测精度.

表 4 预测精度比较

Tab.4 Comparison of prediction accuracy

模型	平均绝对百分误差 (MAPE) / %	误差均方根 (RMSE)
BP 神经网络	2.11	157.12
RBF 神经网络	2.05	124.95
组合模型	1.86	100.23

## 2.5 汕头港未来五年的物流需求预测

使用构建好的组合模型对未来五年(2018~2022 年)汕头港货物吞吐量进行预测,首先要推测未来五年汕头港直接经济腹地三次产业产值、进出口总额、社会消费品零售总额、固定资产投资额的值作为模型的输入变量,笔者采用年均增长率对其进行大致预估。为了测试上述自变量的预估值对组合预测的仿真效果,先将表 1 中 2000~2012 年各项数据作为训练集,2013~2017 年 6 个自变量的预估值作为测试集的输入变量,接着按照此前建立组合模型的方法对数据进行预测,测试结果见表 5。组合模型的 MAPE 和

RMSE 分别为 1.62% 和 103.06。

表 5 测试结果

Tab.5 Test result

年份	真实值/万吨	组合模型	
		预测值/万吨	相对误差 / %
2013	5 037.90	5 080.72	0.30
2014	5 160.91	5 298.08	2.77
2015	5 180.90	5 253.64	0.16
2016	4 985.05	5 114.27	-1.50
2017	4 889.70	4 976.80	-3.35

由此可见,应用年均增长率求得的预估值作为输入变量进行组合预测同样具有较高的预测精度,可以用来对未来五年的港口物流需求进行组合预测。

因此,采用 2000~2017 年上述自变量各值( $x_1-x_6$ )的年均增长率来推测 2018~2022 年各项相应数据的值,然后将预测出来的各自变量的值作为输入变量输入到此前已构建好的组合模型进行预测,便可得到汕头港货物吞吐量( $y$ ) 2018~2022 年预测值(见表 6)。

表 6 预测结果

Tab.6 Forecasting results

年份	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$y$ 预测值
年均增长率 / %	6.64	11.64	11.91	7.36	14.01	19.08	—
2018	621.40	3 691.78	3 147.33	221.34	4 544.09	5 931.81	5 502.16
2019	662.69	4 121.37	3 522.11	237.63	5 180.58	7 063.38	6 401.19
2020	706.72	4 600.96	3 941.51	255.12	5 906.23	8 410.79	6 961.21
2021	753.67	5 136.36	4 410.86	273.90	6 733.51	10 015.25	7 138.03
2022	803.74	5 734.05	4 936.09	294.06	7 676.67	11 925.77	7 208.32

由表 6 可以看出,在保持经济增速相对稳定的前提下,汕头港未来五年的物流需求仍会持续增长,尤其是 2018 年至 2020 年这段时间,其物流需求量会有较大增幅。因此,汕头未来的港口物流业将有较好的发展前景,需要加大港口基础设施建设力度,进一步优化与整合现有港口资源,提高港口服务质量和效率以应对未来物流需求的迅猛增长。

## 3 结论

本研究分别建立了基于 BP 神经网络和 RBF 神经网络的港口物流需求预测模型以及基于上述两种模型的组合预测模型。结果表明,BP 神经网络和 RBF 神经网络均可用来预测港口的物流需求,其预测结果与实际数据较为接近,但仍有部分预测结果存在较大误差。将上述两种模型的预

测结果进行组合后,可以有效减少较大误差的出现,从而提高预测精度,说明应用该组合模型对港口物流需求进行预测是切实可行的,其预测结果更加稳定可靠,因此更适合于实际预测。

## 参考文献:

- [1] 张璐,木仁. 物流需求预测方法概述[J]. 物流科技, 2015, 38 (7): 104-106.
- [2] 徐志刚. 基于自回归模型的上海港港口吞吐量的预测[J]. 武汉交通职业学院学报, 2011, 13 (1): 71-74.
- [3] 李琦. 物流需求预测中移动平均法应用分析[J]. 中国商贸, 2011 (2): 139-140.
- [4] 关克平, 齐梦雅. 基于指数平滑法的宁波-舟山港港口吞吐量预测研究[J]. 中国水运(下半月), 2013, 13 (12): 28-29.
- [5] RUBEN G B, ZHANG K, BAO H, et al. Application

- and sensitivity analysis of artificial neural network for prediction of chemical oxygen demand[J]. *Water Resources Management*, 2018, 32(1): 1-11.
- [6] MAGHREB M, SAMMUT C, WALLER T S. Predicting the duration of concrete operations via artificial neural network and by focusing on supply chain parameters[J]. *Building Research Journal*, 2014, 61(1): 1-14.
- [7] RAVA E, CHIRWA E M. Prediction of performance of the moving-bed biofilm pilot reactor using backpropagation artificial neural network (BP-ANN) [J]. *Chemical Engineering Transactions*, 2017, 61: 189-1194.
- [8] ZHANG J, YANG G. Analysis on Shanghai's logistics demand based on BP neural network [C]//*IEEE International Conference on Networking*, 2013, 16(2): 556-561.
- [9] 曾庆山,全书鹏,靳志强.融合BP神经网络与ARIMA的短时交通流预测[J].*郑州大学学报(工学版)* 2011, 32(4): 60-63.
- [10] HU Z, ZHANG Y, YAO L. Radial basis function neural network with particle swarm optimization algorithms for regional logistics demand prediction [J]. *Discrete Dynamics in Nature & Society*, 2014(2): 189-192.
- [11] 毛晓波,张群,梁静,等.基于PSO-RBF神经网络的雾霾车牌识别算法研究[J].*郑州大学学报(工学版)* 2017, 38(4): 46-50.
- [12] 陈志礼,宁正福,杜华明,等.基于改进BP神经网络的页岩吸附量预测模型[J].*断块油气田*, 2018, 25(2): 208-212.
- [13] 贺文阳,王俊年.RBF神经网络的混合微粒群学习算法[J].*计算机与现代化* 2009(4): 35-38.
- [14] 杨杰,李爱群,曾捷.改进RBF网络及其在悬索桥吊索损伤定位中的应用[J].*南京航空航天大学学报*, 2011, 43(1): 110-114.

## A Model Based on the Combination of BP and RBF Neural Network for Port Logistic Demand Forecasting

CAI Wanzhen<sup>1</sup>, HUANG Han<sup>2</sup>

(1. Department of Economic Management, Shantou Polytechnic, Shantou 515078 China; 2. School of Software Engineering, South China University of Technology, Guangzhou 510006 China)

**Abstract:** In order to get the excellent accuracy for port logistic demand forecasting, a combination model based on the BP and RBF neural network was utilized to forecast the logistic demand of Shantou port in this paper. According to the nonlinear change of logistic demand, the BP neural network and RBF neural network were used to establish the single forecasting sub-model separately. And then, the sub-models were combined through the magnitude of the forecasting error to forecast the logistic demand. The simulation was performed by using MATLAB software. Experiment results showed that the combination model could achieve considerably better predictive performances than the single model of BP or RBF neural network. It could reduce the mean absolute percentage error and root mean square error in the logistic demand of Shantou port. These results indicated that forecast combination could improve the precision of the single neural network model for port logistic demand forecasting, and could help the decision maker in relevant port sector make proper decisions.

**Key words:** BP neural network; RBF neural network; combined model; forecast; port logistic demand