

基于改进多层感知机模型的港口吞吐量预测研究

刘苗苗, 蒋 艳

(上海理工大学管理学院, 上海 200093)
✉192560916@st.usst.edu.cn; ppjyan@163.com



摘 要: 精确的港口货物吞吐量预测对于港口的发展至关重要。本文提出了改进粒子群优化去尾均值多层感知机模型对上海港货物吞吐量进行预测。选取了影响上海港货物吞吐量的十个因素进行训练, 实验结果表明该预测模型的预测性能明显优于传统MLP预测模型和基本的粒子群优化多层感知机模型。对该预测模型的误差分析和收敛性分析表明该预测模型可靠。

关键词: 粒子群算法; 去尾均值; 多层感知机; 港口吞吐量预测

中图分类号: TP183 **文献标识码:** A

Research on Port Throughput Forecast based on Improved Multilayer Perceptron Model

LIU Miaomiao, JIANG Yan

(Business School, University of Shanghai for Science and Technology, Shanghai 200093, China)
✉192560916@st.usst.edu.cn; ppjyan@163.com

Abstract: Accurate port cargo throughput forecast is vital to port development. This paper proposes an improved particle swarm optimization model of multilayer perceptron (MLP) with trimmed mean to predict the cargo throughput of Shanghai Port. Ten factors that affect cargo throughput of Shanghai Port are selected for training. The experimental results show that prediction performance of the proposed prediction model is significantly better than traditional MLP prediction model and basic particle swarm optimization multi-layer perceptron model. Error and convergence analyses of the prediction model show that the prediction model is reliable.

Keywords: particle swarm algorithm; trimmed mean; multilayer perceptron; port throughput forecast

1 引言(Introduction)

随着“21世纪海上丝绸之路”战略的实施, 对港口的管理提出了更高的要求: 准确地预测港口货物吞吐量, 为港口调度提供依据, 避免港口出现货物船舶的滞留, 缩短交货周期, 提高客户满意度, 使港口运营更高效。因此, 准确地预测港口货物吞吐量对港口发展至关重要。

目前, 在港口货物吞吐量预测方面, 陈昌源等^[1]通过优化灰色分析法对上海港集装箱吞吐量进行了预测; 黄荣富等^[2]通过建立三次指数平滑法对港口吞吐量进行了预测; 高嵩等^[3,4]分别结合不同预测模型, 建立组合预测模型并分别应用于天

津港和宁波港的吞吐量预测; 李广儒等^[5]将Elman神经网络应用于宁波舟山港的货物吞吐量预测; 胡克满等^[6]运用灰色模型理论选取部分已知信息计算未知信息, 结合人工神经网络系统对模型进行优化, 给出了基于灰色神经网络的港口货物吞吐量预测算法。

2 吞吐量影响因素分析(Analysis of influencing factors of port throughput)

由于港口吞吐量受到政治、经济、文化、社会等因素的影响, 各种因素相互作用导致上海港货物吞吐量在时间维度上呈现非线性变化的特点, 而人工神经网络能够拟合非线性

映射,具有较强的自适应和自学习能力。但是人工神经网络存在一些不足之处,它的初始权值和阈值都是随机生成的,并且在训练过程中容易陷入局部极小值,而用粒子群算法进行训练能够很好地解决人工神经网络存在的这些问题。此外,人工神经网络模型的功能往往依赖于网络权重的组合相加,容易受到离群值的负面影响^[7],因此,本文采用一种改进粒子群(IPSO)优化的去尾均值多层感知机模型(Tr-MLP)对上海港的货物吞吐量进行预测研究。

本文的创新点在于在多层感知机模型中增加了去尾均值,减少离群值的负面影响,并且使用IPSO模型训练,使收敛速度更快,预测精度更高。

3 IPSO(Improved particle swarm optimization)

3.1 粒子群优化算法(PSO)模型

粒子群优化算法是通过模拟鸟群觅食行为而发展起来的一种基于群体协作的随机搜索算法。该算法中每个粒子都可以看作搜索空间中的最优解,在移动与飞行的过程中,利用适应度函数求得适应度值,用适应度值评价当前解的优劣。每个粒子由位置、速度和适应度值三项特征值进行表示。PSO初始化为一群随机粒子(随机解),然后通过迭代找到最优解,在每一次迭代中,粒子通过跟踪两个“极值”来更新自己。第一个就是粒子本身所找到的最优解,这个解叫作个体极值 $pbest$; 另一个极值是整个种群找到的最优解,这个极值是全局极值 $gbest$ 。不断调整飞行的速度和位置,以搜索到全局最优值。速度和位置更新公式如下^[8]:

$$v_{jm}^{k+1} = v_{jm}^k + c_1 \times rand \times (pbest_{jm}^k - x_{jm}^k) + c_2 \times rand \times (gbest^k - x_{jm}^k)$$

$$x_{jm}^{k+1} = x_{jm}^k + v_{jm}^{k+1}$$

其中, $m=1,2,\dots,M$; $j=1,2,\dots,N$; v_{jm} 为第 j 个粒子在第 m 维的飞行速度; x_{jm} 为粒子的位置; c_1 和 c_2 为非负的常数,称为加速度因子; $rand$ 为介于 $[0,1]$ 的随机变量; $pbest$ 为个体粒子经历的自身最优位置; $gbest$ 为种群粒子集合中各个粒子进行比较后所经历的全局最优位置。

3.2 改进PSO

基础的PSO模型中,固定的惯性权重会减弱全局寻优能力和减慢收敛速度,因此提出利用非线性变化惯性权重来提高PSO的性能。将 w 进行如下优化:

$$w = w_{\max} - (w_{\max} - w_{\min}) \times \arcsin(t/t_{\max}) \times 2/\pi$$

其中, $w_{\max}$ 和 $w_{\min}$ 为 w 的最大值和最小值, t 为当前迭代值, $t_{\max}$ 为最大迭代次数。当 t 较小时, w 趋向 $w_{\max}$, w 减小的速度较慢,以保证算法的全局搜索能力。随着迭代次数的增加, w 迅速非线性递减,以保证算法的局部搜索能力,因此改进的算

法可以灵活调整全局搜索能力和局部搜索能力^[9]。

4 去尾均值多层感知机模型(Tr-MLP model)

多层感知机模型(MLP)是一种人工神经网络,它的一个重要特点就是有多层神经元层,我们将第一层称为输入层,最后一层称为输出层,中间层称为隐藏层。MLP模型如图1所示,本文只涉及了一个隐藏层,输入层有三个变量 $[x_1, x_2, x_3]$ 和一个偏置变量 b ,输出层有三个神经。




图1 MLP网络模型

Fig.1 Network model of MLP

假设第一层为输入层,输入的信息为 $[x_1, x_2, x_3]$ 。对于层 L , 用 L_i 表示该层的所有神经元, 其输出为 y_i , 其中第 j 个节点的输出为 $y_i^{(j)}$, 该节点的输入为 $u_i^{(j)}$, 连接第 L 层与第 $(L-1)$ 层的权重矩阵为 w_L , 上一层(第 $L-1$ 层)的第 i 个节点到第 L 层第 j 个节点的权重为 w_L^{ji} 。




图2 MLP神经元计算模型

Fig.2 Neuronal computational model of MLP

单个神经元计算如下:

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k$$

$$y_k = f(v_k)$$

其中, x_j 表示输入数据, w_{kj} 表示连接权值, b_k 为阈值, $f(x)$ 为激活函数, 通常取sigmoid函数。

由以上两个公式可知, 神经元的输出结果受输入数据线性权重相加的影响, 因此, 当数据存在异常值的时候, 对结果影响较大, 根据文献[7], 将去尾均值的概念引入MLP, v^k 公

式改写如下：

$$v_k = \frac{\sum_{j=1}^m w_{kj}x_j + b_k - n - l}{m - 2}$$

其中， $n = \min(w_{k1}x_1, \cdots, w_{kj}x_j, \cdots, w_{km}x_m, b_k)$ ， $l = \max(w_{k1}x_1, \cdots, w_{kj}x_j, \cdots, w_{km}x_m, b_k)$ ， m 代表输入数据 x_j 的个数。

5 实证研究(Empirical research)

5.1 关键因素选取

本人分析已有文献对沿海港口货物吞吐量影响因素的研究，以及利用SPSS相关分析工具对众多影响因素与上海港货物吞吐量进行相关性分析，选出了影响最大的前十个影响因素：国内生产总值、第一产业增加值、第二产业增加值、第三产业增加值、年末总人口、货物运输量、上海港口码头长度、上海港口泊位数、上海港口生产用万吨级泊位数、社会商品零售总额。数据来源于国家统计局《中国统计年鉴》年度数据^[10]，如表1所示。

表1 2000—2018年上海港货物吞吐量及影响因素统计表
Tab.1 Statistical table of cargo throughput and influencing factors of Shanghai Port from 2000 to 2018

年份	国内生产总值 (亿元)	第一产业增加值 (亿元)	第二产业增加值 (亿元)	第三产业增加值 (亿元)	年末总人口 (万人)	货物运输量 (万吨)	上海港口码头长度 (米)	上海港口泊位数 (个)	上海港口生产用万吨级泊位数 (个)	社会商品零售总额 (亿元)	上海港口货物吞吐量 (万吨)
2000	4,771.17	76.68	2,207.63	2,486.86	1,321.63	46,789	23,557	225	70	1,722.3	20,440
2001	5,210.12	78.00	2,403.18	2,728.94	1,327.14	50,880	23,555	228	71	1,861.3	22,099
2002	5,741.03	79.68	2,622.45	3,038.9	1,334.23	54,064	24,370	222	74	2,035.2	26,384
2003	6,694.23	81.02	3,209.02	3,404.19	1,341.77	58,507	25,604	215	82	2,220.6	31,621
2004	8,072.83	83.45	3,892.12	4,097.26	1,352.39	62,986	24,046	197	74	2,454.6	37,896
2005	9,247.66	90.26	4,381.2	4,776.2	1,360.26	68,636	23,580	183	78	2,979.5	44,317
2006	10,572.24	93.81	4,969.95	5,508.48	1,368.08	72,381	24,561	175	80	3,375.2	47,040
2007	12,494.01	101.84	5,571.06	6,821.11	1,378.86	78,340	24,468	174	80	3,873.3	49,227
2008	14,069.86	111.8	6,085.84	7,872.23	1,391.04	84,400	114,931	1,141	137	4,577.2	50,808
2009	15,046.45	113.82	6,001.78	8,930.85	1,400.70	76,669	116,834	1,145	148	5,173.2	49,467
2010	17,165.98	114.15	7,218.32	9,833.51	1,412.00	87,256	119,248	1,160	150	6,186.6	56,320
2011	19,195.69	124.94	7,927.89	11,142.86	1,419.36	92,962	119,704	1,164	150	7,185.8	62,432
2012	20,181.72	127.8	7,854.77	12,199.15	1,426.93	94,038	122,859	1,183	152	7,840.4	63,740
2013	21,818.15	124.89	7,907.81	13,785.45	1,432.34	84,305	123,988	1,191	156	8,557	68,273
2014	23,567.7	124.26	8,167.71	15,275.72	1,438.69	89,980	126,044	1,220	156	9,303.5	66,954
2015	25,123.45	109.82	7,991.00	17,022.63	1,442.97	90,893	126,921	1,238	174	10,131.5	64,906
2016	28,178.65	109.47	8,406.28	19,662.90	1,450.00	88,324	109,222	1,152	172	10,946.6	64,482
2017	30,632.99	110.78	9,330.67	21,191.54	1,455.13	96,850	106,079	1,078	172	11,830.3	70,542
2018	36,011.82	104.78	10,360.78	25,546.26	1,462.38	106,983	107,234	1,054	181	12,668.7	68,392

5.2 基于IPSO-Tr-MLP模型的上海港吞吐量预测

本文选取2000—2018年的前十个影响因素统计值作为多层感知机的输入，将2000—2018年上海港货物吞吐量作为输出，分别利用传统的多层感知机(MLP)、PSO-Tr-MLP模型和IPSO-Tr-MLP模型对其进行训练拟合。多层感知机的网络结构设置为：输入层10个神经元、隐藏层40个神经元、输出层1个神经元，输入权重学习率 lr_{in} 取0.1，输出权重学习率 lr_{ol} 取0.001，动力因子 a 取0.3，最大迭代次数取1,000次。粒子群算法(PSO)参数设置为：群体粒子个数 N 为100，最大迭代次数Max_iteration取1,000次，学习因子 c_1 与学习因子 c_2 均取1.5，惯性权重最大值 w_{max} 取0.8，惯性权重最小值 w_{min} 取0.4，位置最大值 X_{max} 取5，位置最小值 X_{min} 取-5，速度最大值 v_{max} 取1，速度最小值 v_{min} 取-1。使用matlab仿真实现传统的多层感知机(MLP)训练、基于PSO训练的去尾均值多层感知机(Tr-MLP)模型和基于IPSO训练的Tr-MLP模型的上海港吞吐量预测结果如表2所示，预测效果如图3所示。

表2 上海港货物吞吐量预测结果
Tab.2 Forecast result of cargo throughput of Shanghai Port

年份	传统MLP			PSO-Tr-MLP			IPSO-Tr-MLP		
	实际值	预测值	相对误差	实际值	预测值	相对误差	实际值	预测值	相对误差
2000	2.0440	2.5746	-0.2596	2.0440	1.8079	0.1155	2.0440	1.9274	0.0570
2001	2.2099	2.6385	-0.1939	2.2099	2.3267	-0.0529	2.2099	2.3412	-0.0594
2002	2.6384	2.7316	-0.0353	2.6384	2.8147	-0.0668	2.6384	2.7587	-0.0456
2003	3.1621	2.8591	0.0958	3.1621	3.2068	-0.0141	3.1621	3.1403	0.0069
2004	3.7896	3.1619	0.1656	3.7896	3.7912	-0.0004	3.7896	3.6859	0.0274
2005	4.4317	3.9223	0.1150	4.4317	4.2533	0.0403	4.4317	4.2995	0.0298
2006	4.7040	4.6471	0.0121	4.7040	4.6555	0.0103	4.7040	4.6758	0.0060
2007	4.9227	4.9620	-0.0080	4.9227	5.0200	-0.0198	4.9227	5.0922	-0.0344
2008	5.0808	5.3073	-0.0446	5.0808	4.9194	0.0318	5.0808	4.9067	0.0343
2009	4.9467	5.5221	-0.1163	4.9467	5.2488	-0.0611	4.9467	5.0819	-0.0273
2010	5.6320	5.8417	-0.0372	5.6320	5.6839	-0.0092	5.6320	5.7053	-0.0130
2011	6.2432	6.0968	0.0234	6.2432	6.0556	0.0300	6.2432	6.3236	-0.0129
2012	6.3740	6.2472	0.0199	6.3740	6.3348	0.0061	6.3740	6.4666	-0.0145
2013	6.8273	6.4066	0.0616	6.8273	6.5405	0.0420	6.8273	6.5076	0.0468
2014	6.6954	6.5389	0.0234	6.6954	6.7292	-0.0050	6.6954	6.6730	0.0033
2015	6.4906	6.6494	-0.0245	6.4906	6.7245	-0.0360	6.4906	6.4743	0.0025
2016	6.4482	6.7461	-0.0462	6.4482	6.7768	-0.0510	6.4482	6.6584	-0.0326
2017	7.0542	6.8330	0.0314	7.0542	6.8705	0.0260	7.0542	6.9448	0.0155
2018	6.8392	6.9145	-0.0110	6.8392	6.7644	0.0109	6.8392	6.8649	-0.0038




图3 上海港货物吞吐量预测结果

Fig.3 Forecast result of cargo throughput of Shanghai Port

6 结果分析(Result analysis)

6.1 误差分析

误差分析是通过分析预测模型的预测结果与实际值的贴近程度,进而反映出预测值与实际值之间存在的映射关系,是评价一个预测模型预测效果优劣的重要指标之一。其中,

$$error = \frac{T - T'}{T} \quad (T' \text{代表预测值}, T \text{代表实际值})$$

根据表2获得预测结果,分别对三个模型的相对误差进行分析,得到如图4所示的相对误差分布图。




图4 相对误差分布图

Fig.4 Relative error profile

通过图4可以看出,三个模型的相对误差分布围绕 $error=0$ 上下波动,通过计算两个模型的平均绝对误差(MAE)发现,MLP模型的预测MAE为0.273889,PSO-Tr-MLP模型的预测MAE为0.1465,IPSO-Tr-MLP模型的预测MAE为0.109626,如表3所示。

表3 平均绝对误差比较

Tab.3 Mean absolute error comparison

预测模型	MLP	PSO-Tr-MLP	IPSO-Tr-MLP
MAE	0.273889	0.1465	0.109626

可见,IPSO-Tr-MLP模型的预测误差更小,预测精度更高。

6.2 收敛性分析

基于MLP的预测模型除了需要保证模型的预测精度,作为被广泛应用的神经网络模型之一,收敛性是衡量神经网络

性能的重要指标之一。由于MSE可以评价数据的变化程度,MSE的值越小,说明预测模型描述实验数据具有更好的精确度,因此本文选取MSE作为收敛性分析目标,得到了两个预测模型的MSE值随迭代次数变化的收敛曲线图,如图5所示的MLP模型收敛曲线图和如图6所示的PSO-Tr-MLP模型收敛曲线图,以及如图7所示的IPSO-Tr-MLP模型收敛曲线图。

显然,图5中MLP预测值的MSE值随着迭代次数的增加总体趋势是下降的,最终趋向0;而图6和图7的模型随着迭代次数的增加,MSE值迅速收敛到一个极小值。经过比较可以看出,IPSO-Tr-MLP模型得到更小的MSE值且更加快速地收敛到最小值,这证明改进的模型具有更好的全局搜索能力和更快的收敛速度。




图5 MLP收敛曲线

Fig.5 Convergence curve of MLP




图6 PSO-Tr-MLP收敛曲线

Fig.6 Convergence curve of PSO-Tr-MLP




图7 IPSO-Tr-MLP收敛曲线

Fig.7 Convergence curve of IPSO-Tr-MLP

(下转第35页)