

基于循环结构优化的 Elman 神经网络船舶交通流量预测^①

朱庆辉^{②*} 李广儒^{③*} 杨 晓* 勾翔宇* 李海丽 **

(* 大连海事大学航海学院 大连 116026)

(** 南京大学地理与海洋科学学院 南京 210023)

摘要 针对港口的船舶交通流量预测精度不高的问题,首次采用 Elman 神经网络进行船舶交通流量预测,同时引入以预测误差为条件的循环结构优化 Elman 神经网络,并利用前 6 个月数据预测后一个月数据的方式重新构建原始数据。同时,将优化后的 Elman 神经网络应用于芜湖港船舶交通流量的预测,并与原始的 Elman 神经网络、反向传播(BP)神经网络以及径向基函数(RBF)神经网络的预测结果进行误差及评价指标的分析比较。结果显示,在船舶交通流量预测方面,循环结构优化的 Elman 神经网络的预测误差在 2% 以内,小于原始 Elman 神经网络的 3% 的误差,远远小于 BP 神经网络的 8% 和 RBF 神经网络的 6% 的误差,同时优化后的 Elman 神经网络的各项评价指标均占据优势。表明了 Elman 神经网络在船舶交通流量预测方面的良好适用性,同时循环结构的优化效果明显,其预测性能更优,预测值更接近实际值,具有很大的应用价值。

关键词 水上交通, 船舶交通流量, Elman 神经网络, 循环结构, 流量预测, 精度分析

0 引言

“21 世纪海上丝绸之路”的提出,为中国的航运经济提供了新一轮的发展动力,相应地,沿海港口以及内河航道的船舶交通流量必然会随之快速增长,而船舶流量的增长会加剧现有沿海港口及内河航道的航运负担,导致水上事故。这就需要有关部门制定更合理的航道规划方案,采用更有效的通航管理办法以及保持良好的通航环境。而这一切都有赖于船舶交通流量的准确预测,为有关部门采取应对措施提供准确可靠的数据支持。

在研究船舶的交通流量预测方面,以往所提出的回归分析法^[1]、组合预测法^[2]、灰色分析的预测方法^[3]等都存在一定的局限性。其中,回归分析法因其预测变量及数据的选取会很大程度影响预测结

果的准确性,所以对数据的正确性要求很高。组合预测法中,不同预测方法的权值确定一直以来没有确定的方法。灰色分析预测方法的时效性不佳,预测过程中会快速衰减或递增,不适合进行长期预测。近年来,随着神经网络的兴起,李红喜等人^[4]使用反向传播(back propagation, BP)神经网络以及径向基函数(radical basis function, RBF)神经网络对港口船舶的交通流量建模预测,经比较分析,表明 RBF 神经网络拥有更佳的预测效果,但其预测误差仍在 4% 左右。同时,BP 以及 RBF 神经网络都是基于静态的前馈式网络,本质上都是将动态的复杂时间问题转换成静态的空间问题,但船舶流量数据是动态的,将其转换成静态问题处理势必会忽略时间因素以及达到稳定状态前经历的过程,这样对于数据不充分的利用直接影响到了预测结果的准确性。为解决以往预测模型因忽略船舶流量的动态特性而导致

① 国家自然科学基金(51579025)和辽宁省自然科学基金(201602082)资助项目。

② 男,1994 年生,研究生;研究方向:主要从事交通信息工程及控制研究;E-mail: gushizhuqinghui@163.com

③ 通信作者,E-mail: liguangru@sina.com

(收稿日期:2018-07-10)

的精度不足问题,本文首次提出应用 Elman 神经网络进行船舶交通流量预测,并提出利用循环结构再次优化 Elman 神经网络。Elman 神经网络是具有动态学习特征的反馈式网络。相较于前馈式网络,Elman 神经网络能够记忆存储网络的内部状态,可以很好反映数据动态信息特征,使网络能够顺应数据随时间变化的特性^[5-7],进而保证预测模型立足于处理动态时间问题,提高模型预测精度。因此,使用 Elman 神经网络对船舶交通流量进行预测,在先天上就具有一定的优势。同时,Elman 神经网络在风电功率预测^[8]、短期负荷预测^[9]、高速公路交通流预测^[10]、互联网流量预测^[11]、热负荷预测^[12]以及电池的电荷状态预测^[13]等方面都取得了良好的效果。

为了进一步提高预测精度,本文在原始 Elman 神经网络基础上,根据神经网络自身的随机性,建立了循环结构以优化该网络,进而找到最佳网络。同时,将构建的循环结构优化的船舶交通流量预测模型应用于长江芜湖港,并对照分析原始的 Elman 神经网络、BP 神经网络以及 RBF 神经网络针对芜湖

港流量的预测结果及预测误差,分析结果表明 Elman 神经网络在船舶交通流量预测方面同样具有优势,并且优化后的 Elman 神经网络的预测精度更高,稳定性更强,更适合于船舶交通流量的预测。

1 Elman 神经网络

1.1 Elman 神经网络结构

Elman 神经网络一般拥有 4 层^[14],依次是输入层、隐含层、承接层和输出层,该网络的构建模型如图 1 实线所示。

由图 1 实线部分可知,该网络的输入层、隐含层以及输出层三者的结构连接方式类似于前馈式神经网络。其中,输入层只负责数据传递;输出层负责线性的加权;隐含层的传递函数可以是线性也可以是非线性函数;承接层用来存储隐含层前一时间的输出数据并返回给该网络的输入,也可将其看成是“延时算子”。更确切地说,就是网络在 k 时刻的输入,不仅包括当前的输入值,而且还包括隐含层前一时刻的输入值。

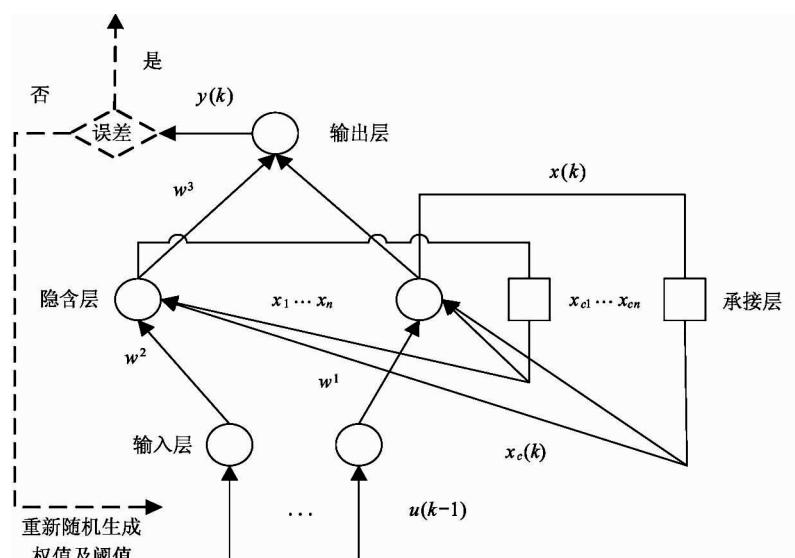


图 1 Elman 神经网络结构模型

1.2 Elman 神经网络学习过程

对照图 1 中实线部分的 Elman 神经网络的结构模型,该网络的输入及输出关系式为

$$\mathbf{x}(k) = f(w^1 \mathbf{x}_e(k) + w^2(\mathbf{u}(k-1))) \quad (1)$$

$$\mathbf{x}_e(k) = \mathbf{x}(k-1) \quad (2)$$

$$\mathbf{y}(k) = g(w^3 \mathbf{x}(k)) \quad (3)$$

式中, \mathbf{y} 、 \mathbf{x} 、 \mathbf{u} 、 \mathbf{x}_e 依次为输出层向量、中间层向量、输入向量、反馈向量; w^1 为承接层至隐含层的连接权值, w^2 为输入层至隐含层连接权值, w^3 为隐含层至输出层连接权值; $f(*)$ 为隐含层的传递函数,

$g(*)$ 为输出层的传递函数, k 为当前神经网络的时刻, $k-1$ 为前一时刻。

在进行 Elman 神经网络的训练时, 隐含层单元使用 S 型函数 tansig 作为传递函数, 输出层使用线性函数 purelin, 训练函数则采用基于 Levenberg-Marquardt 的函数 trainlm, 而权值及阈值的学习函数使用带动量项的函数 learngdm。

1.3 基于循环结构的优化

此时, 如图 1 实线所示的 Elman 神经网络本文称之为原始网络, 为了进一步提高网络的预测精度, 本文对原始网络进行一定的优化。

神经网络在进行初始化时权值和阈值是随机的, 训练完成后确定的相对最佳的权值和阈值也随之有所不同, 这就导致训练后的神经网络性能也略有不同, 其预测结果存在不稳定性, 相应的最佳预测网络的确定就充满不确定性。因此, 网络的初始权值和阈值的随机性造成了这样的局面: 不同的初始化参数对应着不同的训练后的网络, 这些训练完成的网络的性能有强有弱。为寻找最佳的网络, 以往多是采用复杂算法优化神经网络来缩减初始权值和阈值的范围, 尽量消除或减弱其随机性^[15,16], 以此确定最佳的网络, 进而提高网络的预测精度。但这些方法往往较为复杂, 导致整个神经网络的算法体量过大, 不易理解, 而本文是在原始 Elman 神经网络的基础上, 利用其自身初始权值和阈值的随机性, 以最后训练输出结果的误差为条件, 构建优化该网络的循环结构, 以此在众多随机性导致的不同的训练网络中找到性能更强的网络, 改进方法如图 1 虚线部分所示。

该循环结构以整个原始 Elman 神经网络为主体, 以每次训练结束后预测值的相对误差 RE 为判断条件, 其计算公式如式(4)所示, 其中 d_f 表示船舶交通流量预测值, d_m 表示船舶交通流量的实际值。当预测误差 RE 在当前预设的容许误差内时, 输出当前的预测结果并保存当前的网络; 当预测误差 RE 超出容许误差时, 神经网络重新进行随机的权值和阈值的初始化, 重新进行训练, 以此多次循环, 直至满足误差条件, 特别地, 本文预设的容许误差即判断条件为 0.02。

$$RE = \frac{|d_f - d_m|}{d_m} \quad (4)$$

用于优化的循环结构可以很好地利用神经网络自身的随机性, 采用多次循环的方法找到最佳的 Elman 神经网络, 即找到最佳的权值和阈值, 进而提高整个 Elman 神经网络的预测精度。相对于复杂的优化算法, 该方法在保证精度的同时, 简单明了, 易于理解与实现。

2 船舶交通流量预测

2.1 数据预处理

长江作为中国的“黄金水道”, 每年通航船舶数量的基数很大。同时, 较之于海上航道, 长江等内河的航道更窄、船舶规模更小, 这就导致了同等规模下, 内河中的船舶数量更多、密度更大, 而未来航运经济的快速发展推动着船舶数量的急速增加, 所引发的航运负担加剧首先就会体现在内河航道上。因此, 为进行船舶交通流量预测的验证, 本文选择了内河航道中的芜湖港作为实例。

本文将取自长江海事局 2008 年 1 月至 2016 年 12 月, 共计 108 个月的芜湖港日均船舶交通流量数据, 作为网络训练及预测的基本数据。

首先, 将 2008–2016 年的数据按照时间序列排序, 并以连续 6 个月的船舶交通流量来推测下一个月的数据的方式构建 Elman 神经网络的样本, 即 6 个输入数据, 1 个输出数据。以 2015 年为例, 样本数据的构建方法如表 1 所示, 其中 2015 年芜湖港全年的船舶交通流量数据如表 2 所示。因此, 2008–2016 年的船舶交通流量数据可构建 102 组样本数据。

2.2 预测网络建立

在 Matlab 环境下仿真 Elman 神经网络前, 首先要考虑到该网络的具体结构, 特别是隐含层中的神经元的数目, 需要不断地尝试。本文根据训练数据的时间特性以及多次尝试, 最终确定采用输入层为 6 个神经元, 输出层为 1 个神经元, 隐含层为 7 个神经元的网络结构。

表 1 预测模型样本数据构建方法

输入数据(年月)						输出数据(年月)
2015—01	2015—02	2015—03	2015—04	2015—05	2015—06	2015—07
2015—02	2015—03	2015—04	2015—05	2015—06	2015—07	2015—08
2015—03	2015—04	2015—05	2015—06	2015—07	2015—08	2015—09
2015—04	2015—05	2015—06	2015—07	2015—08	2015—09	2015—10
2015—05	2015—06	2015—07	2015—08	2015—09	2015—10	2015—11
2015—06	2015—07	2015—08	2015—09	2015—10	2015—11	2015—12

表 2 2015 年芜湖港船舶交通流量

年月	船舶交通流量(艘)
2015—01	1519
2015—02	1217
2015—03	1467
2015—04	1537
2015—05	1534
2015—06	1489
2015—07	1412
2015—08	1454
2015—09	1446
2015—10	1461
2015—11	1332
2015—12	1331

将预处理后的 102 组样本数据中的后 6 组数据,即预测 2016 年 7—12 月的数据作为测试数据,前 96 组样本数据作为训练数据。同时,归一化处理训练数据,以实现网络的快速收敛。

2.3 评价指标

预测值与真实值的接近度,也即二者的误差大小是评价一个预测模型优劣的标准。本文采用绝对百分比误差最大值、平均绝对误差、平均绝对百分比误差以及相对均方根误差 4 项指标来进行预测模型的优劣评价^[17,18]。

在这 4 项评价指标中,绝对百分比误差 (absolute percentage error, APE) 的最大值 MAX 表示的是预测值与实际值的最大误差占实际值的百分比。平均绝对误差 (mean absolute error, MAE) 表示预测误差绝对值的均值,反映精度大小。平均绝对百分比误差 (mean absolute percentage error, MAPE) 是一项反映预测方法的总体有效性的指标。而均方根误差

(root mean squared error, RMSE) 体现的是预测值与实际值的误差的分散程度。4 项评价指标的计算公式如下:

$$MAX = 100 \max_{i=1}^n \left| \frac{d_{fi} - d_{mi}}{d_{mi}} \right| \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |d_{fi} - d_{mi}| \quad (6)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{d_{fi} - d_{mi}}{d_{mi}} \right| \quad (7)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (d_{fi} - d_{mi})^2} \quad (8)$$

其中, d_f 表示船舶交通流量预测值, d_m 表示船舶交通流量的实际值。

2.4 预测结果及分析

在确定好网络结构之后,建立原始 Elman 神经网络和循环结构优化的 Elman 神经网络预测模型,采用重构的芜湖港船舶交通流量数据训练网络,同时预测检验芜湖港 2016 年 7—12 月的数据。将原始的与优化后的 Elman 神经网络预测结果进行分析比较,同时与 BP 神经网络及 RBF 神经网络的预测值进行分析比较,进而检验原始 Elman 网络与优化的 Elman 网络的性能。预测结果及误差如图 2 和图 3 所示。

由图 2 和图 3 可知,Elman 神经网络预测出来的误差普遍小于 BP 和 RBF 网络,其预测值明显更接近于真实值。其中优化后的 Elman 神经网络的折线图最为平缓,说明其预测性能要更优于原始 Elman 神经网络,优化效果得以凸显。

为进一步比较不同神经网络的性能,本文计算了预测误差百分比、绝对百分比误差的最大值、平均绝对误差、平均绝对百分比误差以及均方根误差等

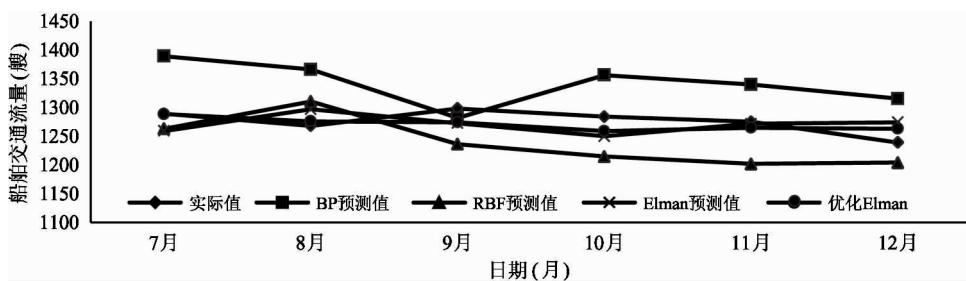


图 2 不同神经网络的预测值和实际值

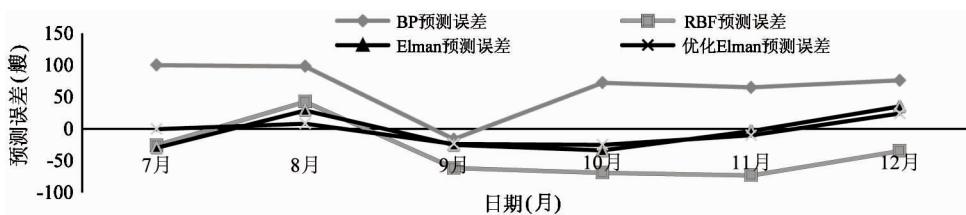


图 3 不同神经网络预测误差

指标。船舶交通流量实际值、预测误差百分比及 4 项指标计算结果如表 3、表 4 所示。

由表 3、表 4 分析可知, BP 神经网络的预测误差在 8% 以内, RBF 神经网络的预测误差在 6% 以内, 而相同预测数据下的原始 Elman 神经网络的误差不超过 3%, 与之对应的循环结构优化的 Elman 神经网络的误差不超过 2%; 4 项评价指标的比较中

同样是优化后的 Elman 神经网络占据优势, 其指标数据在原始 Elman 神经网络的基础上提升了 50% 左右。这进一步说明, Elman 神经网络在船舶的交通流量预测方面具有良好的适用性; 原始的 Elman 神经网络的预测性能要优于 BP 和 RBF 神经网络; 优化后的 Elman 神经网络的预测性能确实得到了提升, 更适合于预测。

表 3 船舶交通流量实际值与预测误差百分比

年月	实际船舶交通 流量(艘)	BP 预测误差 (%)	RBF 预测误差 (%)	原始 Elman 预测 误差(%)	优化 Elman 预测 误差(%)
2016—07	1289	7.76	-2.02	-2.32	-0.06
2016—08	1268	7.73	3.34	2.26	0.62
2016—09	1298	-1.27	-4.77	-1.98	-1.83
2016—10	1284	5.62	-5.41	-2.66	-1.97
2016—11	1275	5.08	-5.74	-0.27	-0.81
2016—12	1239	6.13	-2.81	2.83	1.93

表 4 预测结果的评价指标

评价指标	BP	RBF	原始 Elman	优化 Elman
MAX(%)	7.76	5.74	2.83	1.97
MAE	71.30	51.30	26.20	15.30
MAPE(%)	5.60	4.02	2.05	1.20
RMSE	76.50	54.30	28.20	18.00

3 结 论

本文首次引入 Elman 神经网络进行船舶的交通流量预测, 同时采用循环结构优化 Elman 神经网络, 并利用 2008—2016 年芜湖港的每月日均船舶交通流量数据作为实例, 进行数据重构、网络训练及预

测。经过仿真实验及精度评价分析可知,相比于 BP 神经网络和 RBF 神经网络,Elman 神经网络在船舶交通流量预测方面同样具有良好的适用性,并且循环结构的优化大幅提升了 Elman 神经网络的预测性能,优化后的网络预测精度更高。因此,采用 Elman 神经网络特别是基于循环结构优化的 Elman 神经网络进行船舶交通流量预测具有可行性。该方法能够为改善沿海港口及内河航道的通航环境、优化资源配置等提供更精确更有力的数据支持,进而助力“21 世纪海上丝绸之路”。

虽然本文利用循环结构进行优化有效地提高了 Elman 神经网络的预测精度,但实验中时间上的消耗也在相应增加。因此,在此基础上,如何降低运行时间、提高预测的快速性有待进一步研究。

参考文献

- [1] 张杏谷. 回归分析方法在 VTS 预测研究中的应用 [J]. 中国航海, 1996, 39(2): 32-35
- [2] 刘敬贤, 张涛, 刘文. 船舶交通流组合预测方法研究 [J]. 中国航海, 2009, 32(3): 80-84
- [3] 顾荣忠, 何惠. 江苏省航运量的预测 [J]. 河海大学学报(自然科学版), 1995, 23(6): 53-58
- [4] 李红喜, 付玉慧, 张仁初. 港口船舶交通流量预测 [J]. 大连海事大学学报(自然科学版), 2009, 35(3): 40-42
- [5] 张秋余, 朱学明. 基于 GA-Elman 神经网络的交通流短时预测方法 [J]. 兰州理工大学学报, 2013, 39(3): 94-98
- [6] 蒋绍坚, 付国富, 黄靓云, 等. 基于 Elman 神经网络的烟煤与生物质混烧灰熔点预测 [J]. 中南大学学报(自然科学版), 2016, 47(12): 4240-4247
- [7] 尤马彦, 凌捷, 郝彦军. 基于 Elman 神经网络的网络安全态势预测方法 [J]. 计算机科学, 2012, 39(6): 61-63 + 76
- [8] Chen Y. Forecast of short-term wind power based on GA optimized Elman neural network [J]. *Applied Mechanics & Materials*, 2014, 536-537: 470-475
- [9] Zhang Z S, Gong W J. Short-term load forecasting model based on quantum Elman neural networks [J]. *Mathematical Problems in Engineering*, 2016, 2016(3): 1-8
- [10] 梁新荣, 刘智勇, 毛宗源. 高速公路动态交通流 Elman 神经网络模型 [J]. 交通运输工程学报, 2006, 6(3): 92-96
- [11] Wang X Q, Zhao Z T, Zhang S W. Prediction for network traffic based on modified Elman neural network [J]. *Applied Mechanics and Materials*, 2013, 241-244(10): 3005-3009
- [12] Fu X Q, Huang S Y, Li R, et al. Thermal load prediction considering solar radiation and weather [J]. *Energy Procedia*, 2016, 103(2016): 3-8
- [13] Han H X, Wang J Q, Chen K, et al. SOC prediction research of VRB based on Elman neural network [J]. *Applied Mechanics and Materials*, 2016, 826: 118-122
- [14] Elman J L. Finding structure in time [J]. *Cognitive Science*, 1990, 14: 179-211
- [15] 刘雄峰, 李博, 李俊. 基于遗传算法的 Elman 神经网络模型在大坝位移预测中的应用 [J]. 水资源与水工程学报, 2014, 25(3): 152-156
- [16] 张广斌, 张润梅. 基于改进 Elman 神经网络的徽派古建筑寿命预测 [J]. 中国科学技术大学学报, 2017, 47(10): 817-822
- [17] Madsen H, Pinson P, Kariniotakis G, et al. Standardizing the performance evaluation of short term wind power prediction models [J]. *Wind Engineering*, 2005, 29(6): 475-489
- [18] 戴浪, 黄守道, 黄科元, 等. 风电场风速的神经网络组合预测模型 [J]. 电力系统及其自动化学报, 2011, 23(4): 27-31

Ship traffic flow prediction based on Elman neural network optimized by cyclic structure

Zhu Qinghui^{*} , Li Guangru^{*} , Yang Xiao^{*} , Gou Xiangyu^{*} , Li Haili^{**}

(^{*}Navigation College, Dalian Maritime University, Dalian 116026)

(^{**}School of Geographic and Oceanographic Sciences, Nanjing University, Nanjing 210023)

Abstract

In view of the problem that the prediction accuracy of ship traffic flow in port is not high, Elman neural network is used for the first time to predict the traffic flow of ships. At the same time, the Elman neural network is optimized by the cyclic structure with the prediction error as the condition, and the original data are rebuilt in the way that the next month data are forecasted by the last six-month data. At the same time, the optimized Elman neural network is applied to the prediction of ship traffic flow in Wuhu port, and the error and evaluation indexes are compared with the original Elman neural network, back propagation (BP) neural network and radical basis function (RBF) neural network. The results show that the prediction error of the Elman neural network optimized by cyclic structure is less than 2%, less than 3% of the original Elman neural network, far less than the error of 8% of BP neural network and 6% of the RBF neural network, and all the evaluation indexes of the optimized Elman neural network are dominant. It shows the good applicability of Elman neural network in predicting the traffic flow of ships. At the same time, the optimization effect of the cycle structure is obvious. The prediction performance is better, and the prediction value is closer to the actual value. The way has great application value.

Key words: waterway transportation, ship traffic flow, Elman neural network, cyclic structure, flow forecasting, precision analysis