

文章编号: 1674-599X(2022)02-0102-07

基于 ARIMA-LSTM 的货运量组合预测方法研究

杨艳, 黄晴, 龙思, 潘自翔, 欧阳瑞祥

(长沙理工大学 交通运输工程学院, 湖南 长沙 410114)

摘要: 针对仅考虑单一线性或非线性的货运量预测方法的不足, 基于 ARIMA 和 LSTM 循环神经网络预测模型, 提出 ARIMA-LSTM 4 种组合预测模型, 实现综合考虑线性与非线性特征的货运量预测。研究表明: 任意一种 ARIMA-LSTM 的组合模型的货运量预测精度均优于单一模型的, 由误差倒数确定权重系数的并联组合模型预测精度最优, 该模型相比于 ARIMA, 均方根误差降低 40.66%, 平均绝对误差降低 29.76%, 平均绝对百分比误差降低 51.45%; 相比于 LSTM, 均方根误差降低 13.67%, 平均绝对误差降低 10.75%, 平均绝对百分比误差降低 36.32%, 该研究可为货运量预测提供有效依据。

关键词: 货运量预测; ARIMA; LSTM 循环神经网络; 组合预测模型

中图分类号: U492.3*3

文献标志码: A

Research on combined forecasting method of freight volume based on ARIMA-LSTM

YANG Yan, HUANG Qing, LONG Si, PAN Zixiang, OUYANG Ruixiang

(School of Traffic and Transportation Engineering, Changsha University of Science and Technology, Changsha 410114, China)

Abstract: In view of the shortage of the existing freight volume forecasting method that can only consider the single linear or nonlinear characteristic. Four combined forecasting models were proposed based on ARIMA-LSTM. the freight volume was forecasted considering the linear and nonlinear characteristic. The results show that prediction accuracy of freight volume resulting from any kind of ARIMA-LSTM combined forecasting model is better that from single model. And error reciprocal to determine the weight coefficient of parallel combination model is optimal. Compared with the ARIMA, the root mean square error, mean absolute error, the mean absolute percentage error reduces 40.66%, 29.76% and 51.45%, respectively. Compared with the LSTM, the value is the 13.67%, 10.75% and 36.32%, respectively. This study can provide an effective basis for freight volume forecast.

Key words: the freight volume prediction; ARIMA; LSTM recurrent neural network; combined prediction model

近年来, 中国货运总量虽稳步上涨, 但货运量增速总体呈缓慢下降趋势, 这是由于货运量预测不准确、不合理而导致资源浪费。因此, 需挖掘交通路网的运输潜能, 加强智能化、精细化管理^[1]。货运量预测是交通规划、物流规划等工作的

基础, 为相关运输工作的开展提供了数据支持^[2]。货运量的预测方法有传统统计预测、神经网络预测和组合预测模型 3 种方法。

GODFREY 等人^[3]提出了指数平滑模型, 解决了货运量日常需求预测的复杂性问题, 但精度比

收稿日期: 2021-03-04

基金项目: 湖南省自然科学基金资助项目(2019JJ40306); 长沙理工大学道路灾变防治及交通安全教育部工程研究中心开放基金资助项目(kfj180401)

作者简介: 杨艳(1995—), 女, 长沙理工大学硕士生。

ARIMA模型的差。NARENDRA等人^[4]运用ARIMA模型,提出了基于趋势的ARIMA模型,并进行了验证,研究表明:该模型优于一般的ARIMA模型和基于小波变换的ARIMA模型。张丽莉等人^[5]考虑为较复杂的非线性公路货运量预测问题,提出了采用BP神经网络根据其产生的误差曲线对模型进行迭代优化的方法,该模型具有较好的预测精度。周程等人^[6]针对传统预测方法无法捕捉货运量的非线性关系问题,提出了先利用线性方法预测线性部分,再用BP神经网络预测非线性部分的方法,其预测精度得到大幅度提高。

单一的预测模型由于自身的特点和局限性,处理复杂问题效果差,因此,许多学者对组合模型进行了研究。GUO等人^[7]提出先运用ARIMA模型提取拟合风速数据的线性成分,再运用最小二乘法和支持向量机提取拟合非线性成分的组合预测方法,该组合模型提高了风速预测精度。马涛^[8]指出单一模型在预测过程中存在缺陷,构建了4种不同的组合预测模型,对预测结果分别进行检验。石庆研等人^[9]将LSTM和ARIMA预测的高度值运用于Critic客观赋权方法,处理非线性、非平稳时间序列,提高了航迹预测的精度。王越敬^[10]通过试验,分别验证了ARIMA、LSTM模型及组合模型对标普500指数的预测效果,研究表明:LSTM模型优于ARIMA模型预测性能,而ARIMA-LSTM组合模型的预测性能优于单一模型的。卢生巧等人^[11]提出了卷积神经网络和门控循环单元神经网络相结合的深度神经网络预测模型,研究表明:该模型具有更好的预测性能,可为交通管理与控制提供有效依据。这些组合模型能实现对单一模型的优势整合,对于线性与非线性问题,组合模型既能较好地拟合线性关系,又能恰当地处理非线性关系。本研究以某货运公司18个月货运量的数据为例,基于货运数据时空特征及线性与非线性复合特点,构建ARIMA线性预测模型、LSTM非线性预测模型和多种组合模型,对比各模型的预测精度,选择最佳预测模型。

1 相关模型理论

1.1 ARIMA预测模型

ARIMA模型线性预测功能强,其认为当前时

间的序列值与过去的时间序列值和外界干扰量呈线性相关^[12]。ARIMA(p,d,q)模型公式为:

$$S_t = \varphi_1 S_{t-1} + \varphi_2 S_{t-2} + \dots + \varphi_p S_{t-p} + \mu_t + \theta_1 \mu_{t-1} + \theta_2 \mu_{t-2} + \dots + \theta_q \mu_{t-q} \quad (1)$$

式中: S_t 为时间序列 S 的当期值; p 、 d 和 q 是模型阶数,均为1; $\varphi_i(i=1,2,\dots,p)$ 和 $\theta_j(j=1,2,\dots,q)$ 为模型参数;随机干扰 μ_t 是均值为0、方差为 σ^2 的白噪声序列; S_t 是前 p 阶 $S_{t-1}, S_{t-2}, \dots, S_{t-p}$ 和前 q 阶 $\mu_{t-1}, \mu_{t-2}, \dots, \mu_{t-q}$ 的多元线性函数。

该模型预测分为平稳性检测、模型定阶、白噪声检测及预测评估4个部分。平稳性是ARIMA模型构建的前提,数据平稳后才可用于预测未来的发展趋势^[13]。运用Python语言中Statsmodels库,构建货运量时间序列ARIMA模型。ARIMA模型的建模具体流程如图1所示。

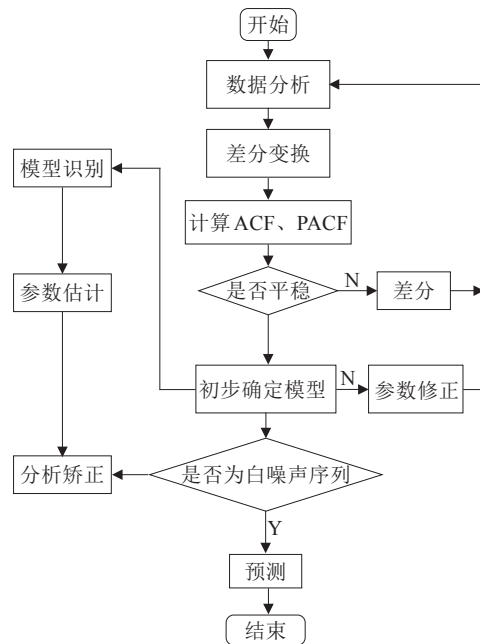


图1 ARIMA建模流程

Fig. 1 ARIMA modeling process

1.2 LSTM预测模型

1997年,HOCHREITER和SCHMIDHUBER提出长短记忆网络(long short term memory network,简称为LSTM)预测模型^[14]。2005年,ALEX对其进行改进并投入应用^[15],LSTM在RNN循环神经网络的基础上发展而来,可解决RNN无法处理长距离序列的问题。

RNN神经网络的基础构架分为输入层、输出层和隐藏层,通过对隐藏层间存在的神经元进行联系,保留数据之间的序列信息^[16-17],如图2所示。




图2 RNN神经网络基础构架

Fig. 2 RNN neural network infrastructure diagram

LSTM提高了较长序列的学习能力，改良了RNN神经网络的内部结构，其优势是具有不同的隐藏层。在原始RNN神经网络中，隐藏层含有唯一的计算模块，而LSTM神经网络在原隐藏层中新增一个可反映隐藏层变化程度细胞状态模块，将计算模块与细胞状态模块合成在一起，构成LSTM记忆模块。“门”是神经网络用于选择通过、去除或新增信息的控制单元。在LSTM神经网络中，门控制单元主要包含遗忘门、输入门和输出门，用来避免产生梯度消失或梯度爆炸的问题。“门”结构依赖于Sigmoid激活函数，输出区间为[0,1]，0表示丢弃信息，1表示全部保留信息，其他情况表示保留部分信息。LSTM隐藏层的工作流程如图3所示^[17]。

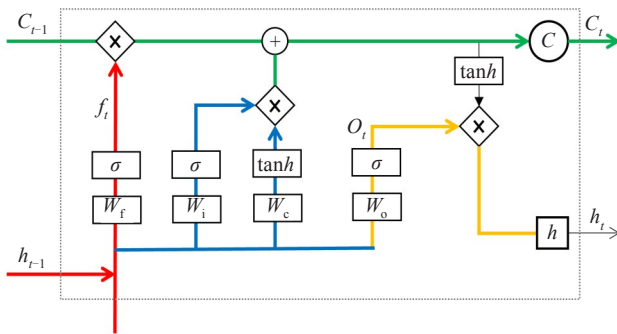


图3 LSTM运算流程

Fig. 3 LSTM operation flow chart

输入门 i_t 、忘记门 f_t 、输出门 o_t 、记忆细胞更新状态 C_t 和隐藏层 h_t 计算公式为：

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \tag{2}$$

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \tag{3}$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \tag{4}$$

$$\tilde{C}_t = \tan h(W_c[h_{t-1}, x_t] + b_c) \tag{5}$$

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \tag{6}$$

$$h_t = o_t \tan h(C_t) \tag{7}$$

式中： σ 为Sigmoid激活函数； b_i 、 b_f 、 b_o 、 b_c 分别表示不同门对应的偏置； W_i 、 W_f 、 W_o 、 W_c 分别表示不同门对应的权值； x_t 表示当前节点的输入； h_t 表示当前节点的输出； \tilde{C}_t 表示计算过程中的候选值向量； C_{t-1} 为上一节点记忆更新状态。

1.3 组合模型

不同组合模型有不同优点，可提升单一预测性能，现有的组合模型可分为两类：①基于误差修正的串联式组合；②基于权重分配的并联式组合^[18]。串联、并联的组合模型流程如图4~5所示。

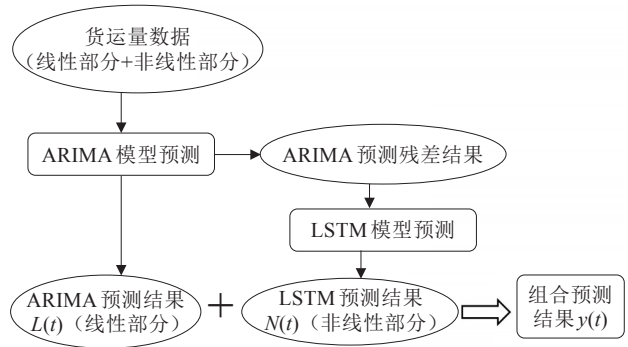


图4 串联组合模型流程

Fig. 4 Flow chart of series combination model




图5 并联组合模型流程

Fig. 5 Flow chart of parallel combination model

2 实例分析

2.1 实验数据

以某货运公司货运物流运营平台（简称公司）2018年1月1日—2019年3月11日训练集数据为例，如图6所示。利用Python语言处理原始数据中的异常信息，处理后的数据为原始数据的93%，为后续准确预测提供优质数据支撑。




图6 货运量数据波动走势

Fig. 6 Fluctuation trend of freight volume data

2.2 组合模型应用

2.2.1 模型粒度

为评估模型预测的准确性, 本研究采用均方根误差 (root mean square error, 简称为RMSE)、平均绝对误差 (mean square error, 简称为MSE) 和平均绝对百分比误差 (mean absolute percent error, 简称为MAPE) 作为误差评价指标。

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - Y_i')^2} \quad (8)$$

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n |Y_i - Y_i'| \quad (9)$$

$$\text{MAPE} = \frac{100}{n} \sum_{i=1}^n \left| \frac{Y_i - Y_i'}{Y_i} \right| \quad (10)$$

式中: Y_i 为 i 时刻的真实值; Y_i' 为 i 时刻的预测值; n 为样本数。

2.2.2 串联组合模型应用

采用串联组合构建预测方法, 假设预测对象的时间序列 y_t 由线性自相关主体 L_t 与非线性残差 N_t 两部分组成。因此, 考虑线性与非线性拟合能力, 将 ARIMA 模型预测结果的非线性残差数据作为 LSTM 预测模型的输入变量。

$$y_t = L_t + N_t \quad (11)$$

试验步骤为:

1) 建立 ARIMA 模型。根据时间序列的理论, 建立 ARIMA 模型。采用 2018 年 1 月 1 日—2019 年 3 月 12 日的货运量数据和 Python 语言建立 ARIMA (1,1,1) 模型, 残差数据见表 1。建立的 ARIMA (1,1,1) 模型的残差序列短期存在一定自相关性, 不是白噪声序列。表明: ARIMA 模型对时间序列数据的提取不够充分, 需进行第二步对数据的非线性相关部分进行提取。

2) 构建 LSTM 神经网络模型, 识别 ARIMA 模型的残差序列。提取残差序列数据, 生成训练

集, 输入矩阵。训练模型完成后, 将模型的输出作为货运量时间序列的非线性部分预测。

3) 将其两部分预测值相加, 得到串联组合模型的货运量预测值, 结果见表 2。

4) 串联组合的结果用 3 种误差评价指标进行预测精度评价分析, 得到 RMSE 值为 114.340 0、MSE 值为 88.560 0、MAPE 值为 0.178 3, 均优于单一模型的误差指标, 从理论上验证了组合模型预测精度更优。

2.2.3 并联组合模型应用

1) 等权平均法:

$$W_i = \frac{1}{n}, i = 1, 2, \dots, n \quad (12)$$

其中, $\sum_{i=1}^n W_i = 1, w \geq 0, i = 1, 2, \dots, n$ 。

2) 误差倒数法:

$$W_i = \frac{E_i^{-1}}{\sum_{i=1}^n E_i^{-1}}, i = 1, 2, \dots, n \quad (13)$$

其中, $\sum_{i=1}^n W_i = 1, w \geq 0, i = 1, 2, \dots, n$ 。 E_i 为第 i 种单项预测模型相对误差。

3) Critic 客观权重赋值法:

$$\sum_{p=1}^n (1 - r_{pj}) \quad (14)$$

其中, r_{pj} 为指标 P 与指标 j 之间的相关系数, 每个指标的信息含量由对比强度和冲突程度共同决定, 则指标 j 的信息量 C_j 为:

$$C_j = \sigma_j (1 - r_{pj}), j = 1, 2, \dots, J \quad (15)$$

其中, σ_j 为第 j 个指标的标准差, 即指标的对比度, r_{pj} 是评价指标 p 和 j 之间的相关系数。 C_j 越大, 所包含的信息量越大, 第 j 个指标的客观权重 W_j 的计算式为:

$$W_j = \frac{C_j}{\sum_{j=1}^J C_j}, j = 1, 2, \dots, J \quad (16)$$

并联组合模型构建的核心在于确定模型权重, 本试验选择结合这 3 种常用模型的权重确定方法, 其公式为:

$$y_t = w_i L_t + w_j M_t \quad (17)$$

式中: y_t 为并联组合模型的预测结果; w_i 为 ARIMA 模型权重; L_t 为 ARIMA 预测的结果; w_j 为 LSTM 模型的权重; M_t 为 LSTM 模型的预测结果。

并联组合模型与串联相比, 更简单快捷, 只

需将 ARIMA 和 LSTM 预测结果乘以并联组合中对应的权重系数, 即可得到试验结果, 不同方式并联组合模型的权重见表 3。各模型预测精度对比见表 4。

由表 4 可知, 无论是串联, 还是并联, 组合模型的预测精度均高于单一模型的。在 3 种并联组合中, 采用误差倒数法确定权重系数的组合模型误差最小。表明: 该模型的精确度在 4 种组合方式中最佳, 可考虑将此组合方式确定为最佳预测模型。

表 1 ARIMA 模型残差序列 (节选)

Table 1 Residual sequence of the ARIMA model (excerpt)

日期	残差	日期	残差	日期	残差
2018/1/1	0.45	2018/1/4	-3.2	2018/1/7	15.6
2018/1/2	5.10	2018/1/5	1.7	2018/1/8	10.1
2018/1/3	-3.20	2018/1/6	-12.5	2018/1/9	11.2

表 2 串联组合模型结果 (节选)

Table 2 Results of series combination model (excerpt)

日期	残差	日期	残差	日期	残差
2018/1/1	0.45	2018/1/4	-3.2	2018/1/7	-21.68
2018/1/2	11.2	2018/1/5	1.7	2018/1/8	50.98
2018/1/3	5.10	2018/1/6	-3.2	2018/1/9	111.00

表 3 不同方式并联组合模型权重确定

Table 3 Weight determination of different parallel combination models

模型	并联组合 1 (等权平均)		并联组合 2 (误差倒数)		并联组合 3 (客观赋值)	
	ARIMA	LSTM	ARIMA	LSTM	ARIMA	LSTM
权重	0.5	0.5	0.42	0.58	0.57	0.43

表 4 三种并联组合及串联组合误差对比

Table 4 Error comparison of three parallel combinations and series combinations

误差评价指标	并联组合 1	并联组合 2	并联组合 3	串联组合
RMSE	143.960 0	101.250 0	135.070 0	114.340 0
MSE	101.490 0	79.840 0	91.740 0	88.560 0
MAPE	0.163 9	0.125 7	0.146 2	0.178 3

3 模型结果对比分析

在 ARIMA 线性模型、LSTM 非线性模型和组合模型试验中, 选择预测效果最好的 ARIMA-LSTM 组合模型将货运量预测值与真实值进行拟合, 如图 7 所示。从图 7 中可以看出, 组合模型的预测值与真实值的拟合程度最好, 预测效果最佳,

LSTM 非线性模型的拟合效果优于 ARIMA 线性模型的。




图 7 多种预测结果与真实值对比

Fig. 7 Comparison of various predicted results and real values

为直观对比单一模型与组合模型的预测精度, 比较各模型的真实值与预测值的相对误差大小, 用货运量的实际值减去各方法得到的预测值, 如图 8 所示。从图 8 可以看出, 单一模型误差相对组合模型误差曲线的变化幅度大且不稳定。表明: 与单一模型的预测结果相比, 组合模型的预测结果更精准、更稳定, 即组合模型的预测效果更佳。为准确地评价这 3 种模型实现的货运量预测效果, 各模型的误差效果对比情况见表 5。

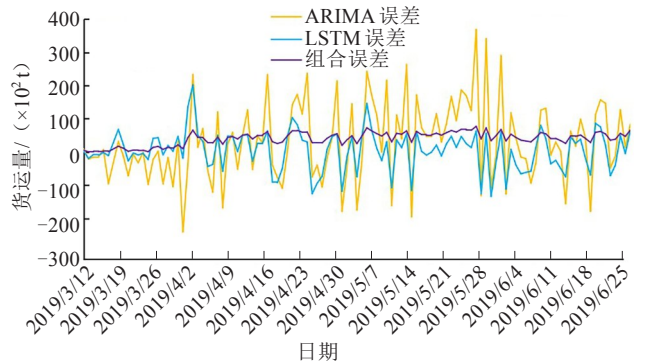


图 8 多种预测方法的误差曲线

Fig. 8 Error curves of various prediction methods

表 5 单一模型与最优组合模型 (误差倒数法) 效果对比

Table 5 Comparison of the effects of the single model and the combined model

模型	RMSE	MSE	MAPE
ARIMA	170.626	113.524	0.258 9
LSTM	117.289	89.457	0.197 4
ARIMA-LSTM 组合	101.250	79.840	0.125 7

由表 5 可知, 在这 3 种误差指标中, LSTM 的各种误差均比 ARIMA 模型的值降低 25% 以上。表

明: ①LSTM神经网络模型优于ARIMA模型; ②由表4可知, 无论何种方式的组合均比任意单一模型的预测效果佳。其中, 表5中以误差倒数确定权重系数的组合模型相较于ARIMA的RMSE、MSE和MAPE, 分别降低了40.66%、29.67%、51.45%; 相较于LSTM误差分别降低了13.67%、10.75%、36.32%。表明: 任何一种组合方式在理论和实践中, 都较单一模型提高了精度。

4 结论

以某货运公司提供的2018年1月—2019年6月货运数据为研究背景, 基于货运数据时空特征和线性与非线性相复合特点, 构建串联式和并联式组合预测模型。串联组合为ARIMA线性模型加上LSTM非线性模型, 对其残值进行预测。并联组合分别以等权平均、误差倒数和Critic客观赋权的3种方式确定权重系数, 对线性模型与非线性模型组合进行预测, 同样使用3种误差评价指标进行分析与验证, 得到结论为:

1) 任意一种ARIMA-LSTM组合的货运量预测模型精度均优于单一模型的。

2) 不同权重组合形式下模型的预测精度不同, 试验表明: 用误差倒数确定权重系数的并联组合效果优于其他3种组合模型的。

3) 从时间与空间2个角度对货运量进行分析。货运量的时间特征主要从时间和空间2个角度进行分析, 证实了货运量具有时空分布规律, 时空特征分析出的货运数据具有季节性与趋势性特征。采用ARIMA和LSTM循环神经网络两种预测模型, 提出了基于ARIMA-LSTM的4种组合预测模型。综合考虑货运量数据线性与非线性特征, 实现对其预测, 克服了单一预测模型的局限性。结果表明: 任意一种ARIMA-LSTM组合的货运量预测精度均优于单一模型的, 且误差倒数确定权重系数的并联组合模型最优。本研究得到的预测组合模型可为未来货运量预测提供理论依据及实践指导意义。

参考文献(References):

[1] 何磊, 丘建栋, 刘恒. 基于突变理论的交通速度预测方法

研究[J]. 公路与汽运, 2018(4): 11-13. (HE Lei, QIU Jiandong, LIU Heng. Research on traffic speed prediction method based on catastrophe theory[J]. Highway and Automobile Transportation, 2018(4): 11-13. (in Chinese))

[2] 常丹丹. 基于深度学习的公路货物运输量预测方法研究[D]. 西安: 长安大学, 2018. (CHANG Dandan. Research on volume of road cargo transportation forecasting method based on deep learning[D]. Xi'an: Chang'an University, 2018. (in Chinese))

[3] GODFREY G A, POWELL W B. Adaptive estimation of daily demands with complex calendar effects for freight transportation[J]. Transportation Research Part B: Methodological, 2000, 34(6): 451-469.

[4] BABU C N, Reddy B E. Predictive data mining on Average Global Temperature using variants of ARIMA models[C]//IEEE-International Conference on Advances In Engineering, Science and Management (ICAESM-2012). Nagapattinam, Tamil Nadu. IEEE, 2012: 256-260.

[5] 张丽莉. 基于神经网络的公路货运量预测方法研究[J]. 华中师范大学学报(自然科学版), 2015, 49(2): 186-189. (ZHANG Lili. A study on highway freight volume forecasting method based on neural network[J]. Journal of Huazhong Normal University(Natural Sciences), 2015, 49(2): 186-189. (in Chinese))

[6] 周程, 施文, 马士华. 基于改进PSO-BP非线性补偿的货运量“分解-集成”预测[J]. 统计与决策, 2018, 34(9): 81-85. (ZHOU Cheng, SHI Wen, MA Shihua. "Decomposition integration" prediction of freight volume based on improved PSO-BP nonlinear compensation[J]. Statistics & decision making, 2018, 34(9): 81-85. (in Chinese))

[7] GUO Z H, ZHAO J, ZHANG W Y, et al. A corrected hybrid approach for wind speed prediction in Hexi Corridor of China[J]. Energy, 2011, 36(3): 1668-1679.

[8] 马涛. 组合预测方法及其应用研究[D]. 兰州: 兰州大学, 2017. (MA Tao. A research on combining forecasting methods and its applications[D]. Lanzhou: Lanzhou University, 2017. (in Chinese))

[9] 石庆研, 岳聚财, 韩萍, 等. 基于LSTM-ARIMA模型的短期航班飞行轨迹预测[J]. 信号处理, 2019, 35(12): 2000-2009. (SHI Qingyan, YUE Jucai, HAN Ping, et al. Short-term flight trajectory prediction based on LSTM-ARIMA model[J]. Journal of Signal Processing, 2019, 35(12): 2000-2009. (in Chinese))

- [10] 王越敬. 基于 LSTM-ARIMA 混合模型的股价相关系数预测模型研究[D]. 绵阳:西南科技大学, 2020. (WANG Yuejing. Prediction model of stock price correlation coefficient based on ARIMA-LSTM hybrid model. Mianyang: Southwest University of Science and Technology, 2020. (in Chinese))
- [11] 卢生巧, 黄中祥. 基于深度学习的短时交通流预测模型[J]. 交通科学与工程, 2020, 36(3):74-80. (LU Shengqiao, HUANG Zhongxiang. Prediction model of short-term traffic flow based on CNN-GRU deep learning[J]. Journal of Transport Science and Engineering, 2020, 36(3):74-80. (in Chinese))
- [12] 黄红梅. 应用时间序列分析[M]. 北京:清华大学出版社, 2016. (HUANG Hongmei. Application of time series analysis [M]. Beijing: Tsinghua University Press, 2016. (in Chinese))
- [13] 薛艳茹. 基于时间序列分析的散杂货港口吞吐量短期预测研究[D]. 北京:北京交通大学, 2019. (XUE Yanru. Short-term prediction of bulk cargo port throughput based on time series analysis[D]. Beijing: Beijing Jiaotong University, 2019. (in Chinese))
- [14] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8):1735-1780.
- [15] GRAVES A, SCHMIDHUBER J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures[J]. Neural Networks, 2005, 18(5-6): 602-610.
- [16] NAKHAEI F, IRANNAJAD M. Application and comparison of RNN, RBFNN and MNLN approaches on prediction of flotation column performance[J]. International Journal of Mining Science and Technology, 2015, 25(6):983-990.
- [17] CHUNG J, GULCEHRE C, CHO K, et al, Gated feedback recurrent neural networks[C]//International Conference on Machine Learning, 2015:2067-2075.
- [18] 伊恩·古德费洛, 约书亚·本吉奥, 亚伦·库维尔. 深度学习[M]. 赵申剑, 黎彧君, 符天凡, 等, 译. 北京:人民邮电出版社, 2017. (IAN G, YOSHUA B A C. Deep learning[M]. Translation by ZHAO ShenJian, LI Huojun, FU Tianfan, et al. Beijing: Posts & Telecom Press 2017. (in Chinese))

(上接第 74 页)

- Research Institute, 1992, 9(3):8-16. (in Chinese))
- [10] 刘勇健, 李子生. 岩土工程位移反分析的智能反演综述[J]. 地下空间, 2004(1): 84-88, 141. (LIU Yongjian, LI Zisheng. Review of intelligent back exercise of displacement back analysis in geo-technical engineering [J]. Underground Space, 2004(1):84-88, 141. (in Chinese))
- [11] 张德华, 刘士海, 任少强. 隧道喷射混凝土强度增长规律及硬化速度对初期支护性能影响试验研究[J]. 岩土力学, 2015, 36(6): 1707-1713. (ZHANG Dehua, LIU Shihai, REN Shaoqiang. Experimental study of effects of strength increase and hardening rate of shotcrete on its early supporting performances in tunneling[J]. Rock and Soil Mechanics, 2015, 36(6):1707-1713. (in Chinese))
- [12] 陈萌, 毕苏萍, 刘立新, 等. 商品混凝土轴心抗拉强度与受拉弹性模量的试验研究[J]. 四川建筑科学研究, 2008, 34(2):186-189. (CHEN Meng, BI Suping, LIU Lixin, et al. An experimental study on axial tensile strength and tensile elastic modulus of commercial concrete[J]. Sichuan Building Science, 2008, 34(2): 186-189. (in Chinese))
- [13] 李秀芳, 柯玉军, 徐长峰, 等. 公路隧道监控量测数据的回归分析及其运用[J]. 公路交通科技(应用技术版), 2013, 9(1): 178-182. (LI Xiufang, KE Yujun, XU Changfeng, et al. Regression analysis and application of highway monitoring data[J]. Highway Traffic Science and Technology (Application Technology Edition), 2013, 9(1): 178-182. (in Chinese))
- [14] 王勇, 崔涛. 基于当量正态化法的隧道锚喷支护可靠度分析[J]. 公路与汽运, 2014(3):226-229. (WANG Yong, CUI Tao. Reliability analysis of tunnel bolting and shotcreting support based on equivalent normalization method[J]. Highways & Automotive Applications, 2014(3):226-229. (in Chinese))