

基于 LSTM 的上海港集装箱吞吐量预测

王凤武, 张晓博, 阎际驰, 吉哲

(大连海事大学 航海学院, 辽宁 大连 116026)

摘要:港口作为海上和陆地连接重要的交通物流枢纽,地位显著,而集装箱物流作为港口物流重要的组成部分,已成为评价一个港口地位的重要指标,科学准确的港口集装箱吞吐量预测对港口规划、腹地经济研究及科学决策等方面具有重要的意义。集装箱吞吐量数据非常复杂,并且往往具有多重季节性,很难准确预测,为了更加精准的预测港口集装箱吞吐量,本文采用长短期记忆模型(LSTM)来预测上海港集装箱吞吐量,并使用上海港集装箱吞吐量数据用于实证分析,将 LSTM 模型的预测结果与 ARIMA 模型的预测结果进行比较。比较结果表明,LSTM 模型的预测精度更高。本文所提出的 LSTM 模型预测集装箱吞吐量不仅促进了深度学习技术在港口预测方面的应用,同时能够在港口生产管理业务中有效帮助港口规划决策。

关键词:上海港;集装箱吞吐量;LSTM 模型;预测

中图分类号:U651 **文献标志码:**A

Prediction of Container Throughput of Shanghai Port with LSTM

WANG Fengwu, ZHANG Xiaobo, YAN Jichi, Ji Zhe

(Navigation College, Dalian Maritime University, Dalian 116026, China)

Abstract: Prediction of container throughput of a port is challenging because of its complexity and multiple season-dependent characteristics. The LSTM is used to do the prediction of the container throughput of Shanghai Port and the result is compared to the prediction given by the ARIMA model.

Key words: Shanghai Port; container throughput; LSTM; prediction

进入新世纪以来,随着经济全球化的发展及我国“一带一路”战略的提出,国际贸易量逐年增加。港口作为连接陆地与海上重要的交通枢纽,对于其所在地区的经济发展有着重要的作用,其中集装箱因其装卸效率高、周转快、节省包装费、减少货损差以及适合“门到门”的物流方式等诸多优势受到青睐,目前以集装箱为主的运输体系现已经逐渐成为海上运输的主要方式^[1]。通过对港口集装箱吞吐量的准确预测,一方面可以帮助港口合理决策,安排生产计划,避免造成浪费;另一方面可以有效反映出该地区经济发展情况。因此,科学准确的港口集装箱吞吐量预测对港口规划、经济研究及合理决策等方面具有重要的意义。

自 20 世纪 80 年代起,随着社会经济和学术研究的发展,对于集装箱吞吐量方面的研究方法已经从传统的灰色预测理论^[2]、支持向量机^[3]、自回归

差分移动平均模型(Autoregressive Integrated Moving Average, ARIMA)^[4]和反向传播神经网络(Back Propagation, BP)^[5]等过渡到深度学习算法,这些方法取得了一定的预测效果,但是具有一定的局限性。灰色预测理论在预测过程中易出现快速递增和衰减现象,缺乏自学习、自适应能力,因此只适合做短期预测^[6];支持向量机理论主要取决于核函数的选取,目前比较成熟的核函数及其参数的选择都是人为的,根据经验来选取的,带有一定的主观性^[7];ARIMA 模型在预测过程中只能处理线性时间序列数据,而不能捕捉非线性时间序列的关系;BP 神经网络在预测中需要大量的训练样本,而在实际应用中由于各种因素的限制,不能达到神经网络学习需要的样本数量。因此寻找一种简单、处理效率高且预测精度较高的新方法对于港口货物吞吐量预测具有重要意义。

收稿日期:2021-04-12

作者简介:王凤武(1965—),男,辽宁盘锦人,教授,博士,研究方向为船舶安全与保障。E-mail:wangfw650105@163.com

通信作者:张晓博(1994—),男,河北石家庄人,硕士研究生,研究方向为港口与船舶安全。E-mail:zxb941025@163.com

目前,深度学习技术在时间序列预测方面显示出巨大潜力,其被广泛用于提取数据的时间特征,在不同领域有着广泛应用,其中长短期记忆模型(Long Short-Term Memory, LSTM)作为目前应用最新的预测模型之一,在处理时序数据方面较传统的模型预测精度提高很多。如蒲悦逸等^[8]利用长短期记忆模型来获取分析交通流量数据的特征并对北京市城市区域交通流量进行预测,验证结果表明 LSTM 模型比传统模型准确性更高;张古尧等^[9]采用了随机失活技术的 LSTM 模型对避雷器阻性电流进行了预测,进而判断避雷器的老化程度,结果表明 LSTM 模型与 BP 神经网络相比误差更小;连静等^[10]针对行人轨迹预测问题,以社会信息和行人历史轨迹为输入,采用了一种基于人车交互的 LSTM 模型,试验结果表明该模型有效提高了预测精度,为智能驾驶决策提供了参考;唐鸣等^[11]利用 LSTM 模型对南水北调闸前水位进行了预测,并与 BP 神经网络的预测结果进行了比较,结果表明 LSTM 模型预测结果具有很高的精度;YAN 等^[12]将树结构集成到 LSTM 模型中对其进行改进,使用改进后的 LSTM 模型对齿轮的剩余使用寿命进行预测,试验结果表明改进后的模型鲁棒性和收敛速度更好;MEI^[13]为了调整宽带数据传输策略,利用 LSTM 模型对带宽进行预测,结果表明预测精准度较高。在港口货物预测方面,薛艳茹^[14]使用了 LSTM 模型与 ARIMA 模型组合预测的方法对广州港的散杂货进行了短期预测,结果表明引入深度学习相关技术对预测的准确性具有明显提升。

尽管 LSTM 模型在时间序列预测方面具有广泛的应用,但它尚未应用到集装箱吞吐量预测中,通过大量的研究以及预测实例表明, LSTM 模型对数据分布呈规律性变化的序列非常适用,处理非线性时序数据方面较传统的模型预测精度提高^[9]。在对上海港集装箱吞吐量历史数据进行背景分析和预处理之后发现,港口集装箱吞吐量数据具有明显的非线性时间序列特征,发展上呈现较平稳的趋势特征,且随机波动较少^[15]。因此本研究旨在使用 LSTM 模型对上海港集装箱吞吐量进行预测。

1 LSTM 模型构建

LSTM 模型全称叫做长短期记忆模型(Long Short-Term Memory, LSTM)^[14],它是在循环神经网络(Recurrent Neural Network, RNN)的基础上进行的改进,因此也属于 RNN 网络的一种。LSTM 模型主要规避了标准 RNN 网络结构中梯度爆炸和梯度消

失问题,在其基础上引入了门控机制概念,通过输入门、遗忘门和输出门对数据信息流动进行控制,因此训练速度也会更快。一个最基本的 LSTM 模型连接结构如图 1 所示。

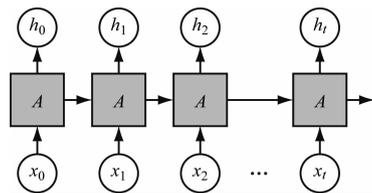


图 1 LSTM 模型连接图示

1.1 LSTM 核心理念

LSTM 模型的主要结构为输入门、遗忘门、输出门和记忆单元四个部分^[16],它们之间以特殊的方式进行交互,具体如图 2 所示。

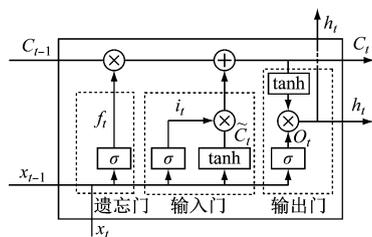


图 2 LSTM 模型主要结构

图 2 中每一个箭头都是一个向量,表示从上一个节点输出到其他节点的输入,圆圈表示向量计算,包括向量相加和向量相乘,箭头合并表示两个节点相加,箭头分叉表示两个节点复制。

LSTM 模型中最重要的结构就是记忆单元,即图 2 中水平线 C_i ,它主要是用来确定上一次记忆单元 C_{i-1} 有多少成分保留在记忆单元 C_i 中,以及确定输入 x_i 中有多少成分保留在 C_i 中,通过 C_i 可以控制信息的变化,选择性保留历史记忆和现在记忆的信息,这便是长短时记忆神经网络。同时该模型引入门(Gate)来控制信息流的状态,通过门来控制信息的筛选。门是由激活函数 Sigmoid 和元素相乘运算组成,它的输出是 0 和 1 之间的数值,1 代表“完全保留信息”,0 表示“完全丢掉信息”。门可以表示为:

$$g(x) = \sigma(W_x + b) \quad (1)$$

式中 g 表示“Gate”, b 是偏置项, W 是门的权重向量。

1.2 LSTM 的网络结构

1.2.1 输入门

输入门主要决定输入 x_i 有多少成分保留在记忆单元 C_i 中,输入门的结构如图 3 所示,其中共含有两个神经网络层,即 Sigmoid(即图中 σ) 和 tanh

激活函数。

输入门的公式可分别表示为:

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

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

式中 i 表示“Input”,其中 W_i 表示 t 时刻输入层的权重, W_c 表示 t 时刻隐藏层的权重, x_t 表示在 t 时刻的输入, h_{t-1} 表示 $t-1$ 时刻的隐藏状态, b_i 和 b_c 分别表示输入层与候选值的偏置。

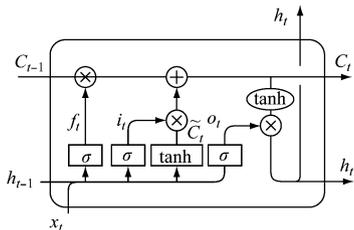


图3 LSTM 输入门结构

1.2.2 遗忘门

遗忘门决定 t 时刻输入中的 C_{t-1} 有多少成分保留在 C_t 中,控制 t 时刻保留信息的上限,遗忘门结构图如图4所示。

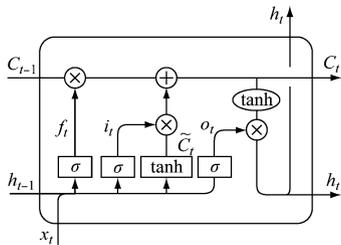


图4 LSTM 遗忘门结构

遗忘门的公式可以表示为:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (4)$$

式中 f 表示“Forget”, b_f 表示遗忘门的偏置项, W_f 表示此时前一层隐藏神经元在遗忘门输出时的权重,都需经过训练与学习。

1.2.3 输出门

输出门决定控制单元 C_t 输出到 O_t 有多少成分输出到隐藏层 h_t 中。输出层由两部分构成,一部分为短期记忆结合当前输入信息得到的信息输出 O_t ,另一部分为结合长期记忆后的最终输出。输出门结构图如图5所示。

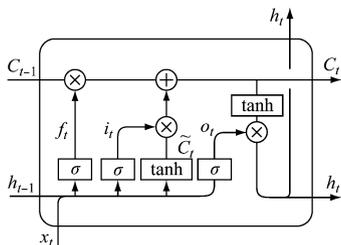


图5 LSTM 输出门结构

输出门的公式为:

$$h_t = O_t \cdot \tanh(C_t) \quad (5)$$

首先,经过输入门和遗忘门之后的状态 C_t ,用公式可以表示为:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (6)$$

式中,第一项 $f_t \cdot C_{t-1}$ 为输入层保留在 C_t 中的成分,第二项 $i_t \cdot \tilde{C}_t$ 为遗忘层保留在 C_t 中的成分。

其次,为了确定 C_t 中有多少成分保留在 h_t 中,输出层用公式可以表示为:

$$O_t = \sigma(U_o x_t + W_o h_{t-1} + b_o) \quad (7)$$

式中 O_t 为 t 时刻输出层上的状态。

最后,经过输出门,保留在隐藏层上的成分为 h_t 。

通过以上对 LSTM 模型的介绍,可以较清楚地了解到该模型的内部结构和网络结构,本文构建了一个全连接层的网络结构,如图6所示。具体操作步骤为首先进行原始数据处理,将处理后数据标准化,作为模型的输入 x_t ,经过 LSTM 模型之后输出为,并最终进行数据反标准化。其中原始数据处理、数据标准化等步骤将在下一节详细阐述。

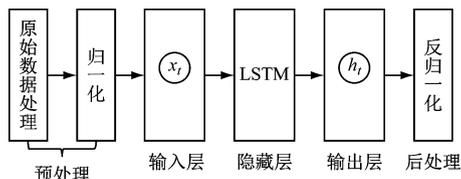


图6 LSTM 网络结构

2 实例验证

上海港位于中国大陆海岸线中部,长江与东海交汇处,自古以来,上海港是我国对外交通和贸易往来的重要港口。上海港作为全球集装箱吞吐量和货物吞吐量最大的港口,是中国的第一大港,也是我国港口的代表,在整个物流的体系中占有重要的地位。2010年上海港完成集装箱吞吐量2 905万 TEU,成为世界第一大集装箱港口,超过新加坡港约50万 TEU;2011年上海港集装箱吞吐量达到3 175万 TEU,第一次突破了3 000万 TEU;2016年上海港继续保持国际集装箱枢纽港地位,集装箱吞吐量为3 713.3万 TEU,成为世界第一吞吐量港^[10];2017年上海港集装箱吞吐量为4 023万 TEU,首次突破4 000万 TEU;2018年吞吐量达到了4 201万 TEU,并继续保持稳定增长;2019年达到了4 332万 TEU^[17]。从这些数据可以发现上海港集装箱吞吐量每年保持增长,港口的发展离不开科学合理的决

策,而科学合理的决策需要准确的预测,因此对其集装箱吞吐量进行预测具有重要的意义,不仅提高了预测的科学性与准确性,为港口方面科学合理决策与规划提供参考,同时为政府及从事航运事业的相关人员提供相关建议。

本文选用上海港作为实例验证港,为了更加有效的验证本文所使用的 LSTM 模型的预测精度,同时选用 LSTM 模型和 ARIMA 模型作为预测上海港集装箱吞吐量的模型,在保证初始条件一致的情况下,通过建立评价指标的方式分别评价 LSTM 模型预测结果和 ARIMA 模型预测结果与实际值的差距,并对两种模型的评价结果进行了对比分析。

2.1 ARIMA 模型的优势及适用性分析

ARIMA 模型是由自回归过程(Auto Regressive, AR)和移动平均过程(Moving Average, MA)共同构成的,在时间序列预测方面受到广泛应用,其对线性时间序列的拟合能力较好,能够消除数据周期性变化对预测结果的影响,短期预测准确率较高,但是随着时间的延长,预测误差开始变大,同时要求时序数据稳定,不能捕捉数据的非线性关系,且对数据量有要求,数据量过少,预测效果越差。

2.2 LSTM 模型建模流程

本文使用 Python 语言进行编程,以 TensorFlow 为后台,基于 Keras 框架构建了 LSTM 模型,建模流程如图 7 所示。

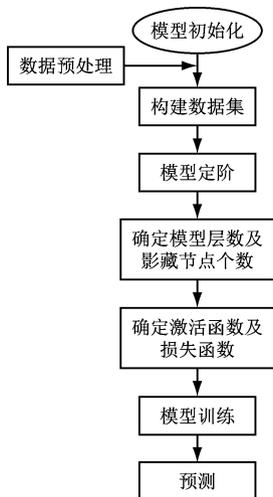


图7 建模流程图

2.3 原始数据

本文基于中国港口集装箱网收集整理了上海港 2016~2019 年共计 48 个月集装箱吞吐量数据,并按照时间序列排序,原始数据如表 1 所示。

2.4 数据预处理方法

2.4.1 数据平稳性检测及差分处理

数据保持平稳是基于时间序列预测的前提,因

此在建立模型前首先需要对数据的平稳性进行检测,本文使用 ADF 单位根检测法来对上海港 2016~2019 年集装箱吞吐量数据序列进行检验,当检测结果小于 1%、5%、10% 的置信水平时,此序列才会保持平稳。如表 2 所示,上海港集装箱吞吐量时间序列的检验统计量(t-Statistic)为 -3.146 197 比 1% 置信水平的检测结果 -3.581 152 要大,因此该序列不平稳。

表1 2016~2019 年上海港集装箱吞吐量统计 万 TEU

| 月份 | 2016 年 | 2017 年 | 2018 年 | 2019 年 |
|----|--------|--------|--------|--------|
| 1 | 298 | 328 | 339 | 375 |
| 2 | 257 | 262 | 293 | 286 |
| 3 | 300 | 340 | 338 | 381 |
| 4 | 312 | 323 | 352 | 361 |
| 5 | 312 | 350 | 362 | 376 |
| 6 | 310 | 340 | 360 | 376 |
| 7 | 325 | 350 | 355 | 385 |
| 8 | 330 | 345 | 347 | 376 |
| 9 | 313 | 338 | 381 | 371 |
| 10 | 322 | 340 | 353 | 363 |
| 11 | 320 | 355 | 350 | 355 |
| 12 | 314 | 352 | 371 | 327 |

表2 上海港 2016~2019 集装箱吞吐量数据 ADF 根检测结果

| | t-Statistic | Prob. * |
|--|-------------|---------|
| Augmented Dickey-Fuller test statistic | -3.146 197 | 0.030 0 |
| Test critical values: 1% Level | -3.581 152 | |
| 5% Level | -2.926 622 | |
| 10% Level | -2.601 424 | |

LSTM 模型可以对数据差分处理使序列保持平稳,首先对序列进行了一阶差分处理,一阶差分后 t-Statistic 结果为 -4.023 127 小于三个置信水平结果。图 8 为一阶差分后的时间序列。

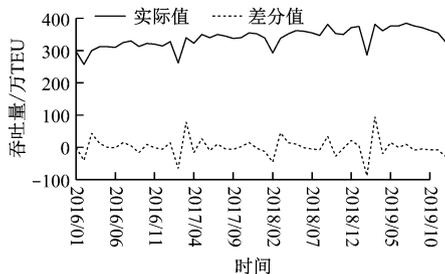


图8 上海港集装箱吞吐量时间序列一阶差分结果

为了保证 LSTM 模型快速收敛、保持数据一致性以及提高模型的预测精度,在输入时对数据进行了标准化处理,在输出时进行反标准化。

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (8)$$

公式中: x 代表输入数据, x_{\min} 代表输入数据的最小值, x_{\max} 代表输入数据的最大值, x^* 代表标准化后的输入数据。

2.4.2 数据构建方法

为了充分发挥数据的作用,同时提高模型的预测精度,本文采用连续 3 个月吞吐量数据递归预测下一个月数据进行构建 LSTM 模型样本数据,即采用 1~3 月的吞吐量数据预测第 4 个月的吞吐量,2~4 月的吞吐量数据预测第 5 月的吞吐量,总共可构建 45 组样本数据,其中将前 27 组作为训练数据集,将后 18 组作为数据检验集,样本数据构建方法如表 3 所示。

表 3 样本数据构建方法

| 输入数据 | | | 输出数据 |
|---------|---------|---------|---------|
| 2016-01 | 2016-02 | 2016-03 | 2016-04 |
| 2016-02 | 2016-03 | 2016-04 | 2016-05 |
| 2016-03 | 2016-04 | 2016-05 | 2016-06 |
| 2016-04 | 2016-05 | 2016-06 | 2016-07 |
| 2016-05 | 2016-06 | 2016-07 | 2016-08 |
| 2016-06 | 2016-07 | 2016-08 | 2016-09 |
| 2016-07 | 2016-08 | 2016-09 | 2016-10 |
| 2016-08 | 2016-09 | 2016-10 | 2016-11 |
| 2016-09 | 2016-10 | 2016-11 | 2016-12 |
| | | | ... |

2.4.3 评价指标确定

为了更好地展现 LSTM 模型对港口集装箱吞吐量的预测结果,本文使用了绝对百分比误差最大值(定义为 MAX)、平均绝对误差(Mean Absolute Error, MAE)、平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)以及均方根误差(Root Mean Squared Error, RMSE)四项评价指标来衡量预测结果与实际值之间的差距^[18]。其中 MAX 反映预测值与真实值之间的误差占真实值的百分比,MAE 反映误差绝对值的均值情况,MAPE 反映预测方法是否有效,RMSE 评价预测值与真实值之间的偏差,四项评价指标公式如下:

$$t_{MAX} = 100 \max_{i=1}^n \left(\left| \frac{d_{f_i} - d_{m_i}}{d_{m_i}} \right| \right) \quad (9)$$

$$t_{MAE} = \frac{1}{n} \sum_{i=1}^n |d_{f_i} - d_{m_i}| \quad (10)$$

$$t_{MAPE} = \frac{100}{n} \sum_{i=1}^n \left| \frac{d_{f_i} - d_{m_i}}{d_{m_i}} \right| \quad (11)$$

$$t_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (d_{f_i} - d_{m_i})^2} \quad (12)$$

式中: d_f 为港口集装箱吞吐量预测值, d_m 为港口吞吐量实际值。

2.5 模型预测

2.5.1 模型参数设置

在进行港口货物吞吐量预测前,本文根据港口集装箱吞吐量数据进行多次尝试,最终确定隐藏层为 30 个神经元,采用 Adam 算法进行优化,学习率为 0.001,LSTM 神经网络模型中激活函数选择 Tanh 函数,训练次数 200 次。

2.5.2 结果与分析

通过采用上海港集装箱吞吐量样本数据中 27 组训练数据对 LSTM 模型训练,18 组验证数据对模型进行验证,损失函数的变化趋势如图 9 所示。

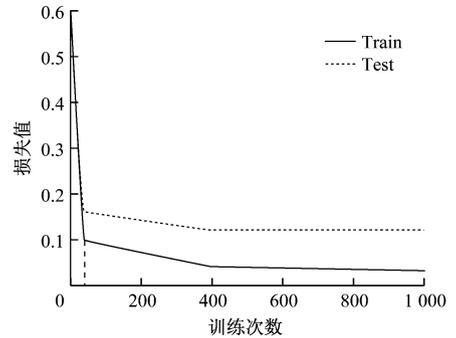


图 9 损失函数变化趋势

从图中可以看出,当模型训练到第 40 次时,训练集和测试集损失函数明显降低,并保持了平稳。

为了验证 LSTM 模型对时间序列预测的准确性,本文基于相同的集装箱吞吐量数据,分别采用 LSTM 模型与 ARIMA 模型对上海港集装箱吞吐量预测,并将两种模型的预测结果进行对比分析,如图 10 所示。

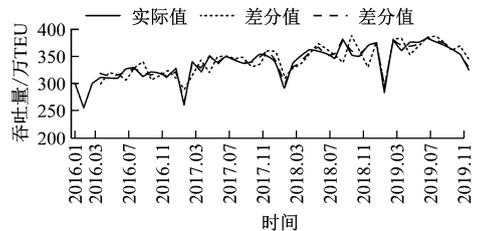


图 10 LSTM 与 ARIMA 模型预测结果

从图 10 中可以看出,LSTM 预测结果更加接近真实值,为了更深入的比较两种模型预测结果的精

准度,本文进行了四种评价指标的计算,结果如表4所示。

表4 LSTM模型与ARIMA模型评价指标

| 模型 | $t_{MAX}(\%)$ | t_{MAE} | $t_{MAPE}(\%)$ | t_{RMSE} |
|-------|---------------|-----------|----------------|------------|
| LSTM | 1.607 | 12.007 | 3.270 | 14.998 |
| ARIMA | 7.801 | 20.732 | 8.102 | 23.976 |

由表4所知,ARIMA模型的预测绝对误差最大值为7.801%,而LSTM模型的预测绝对误差最大值控制在2%以内,同时该模型的其他三项预测指标均优于ARIMA模型,说明LSTM模型预测误差更小,拟合精度更高,证明了深度学习中的LSTM模型更加适用于港口集装箱吞吐量预测。

3 结论

本文将LSTM模型应用到港口集装箱吞吐量预测中,首先详细讨论了实现该方法的步骤,其次将上海港吞吐量数据输入模型中进行预测,为了对其预测性能进行判断,应用了传统预测方法ARIMA模型对上海港集装箱吞吐量同样进行了预测,并使用了四种误差评价指标来对两种方法的预测结果进行评价,比较预测结果表明LSTM模型的预测精度明显优于ARIMA模型。集装箱物流是一个价值巨大的行业,在战略、战术或运营决策层面的微小改进将带来巨大的效益,在理论意义方面本文基于时间序列对港口集装箱吞吐量进行了分析,发现港口集装箱吞吐量逐年递增,通过使用LSTM模型对港口集装箱吞吐量进行预测,并与实际结果进行比较,可以促进深度学习技术在港口集装箱吞吐量预测方面的应用。在实际应用价值方面,本文构建的LSTM模型预测结果很好的拟合了港口集装箱吞吐量数据非线性与线性交织叠加的特点,应用到港口生产管理业务中,能够有效帮助港口规划决策,当吞吐量预测趋势上升时,港口方面需要增加人力、硬件等方面的投资来满足即将到来的运力需求;当吞吐量预测下降时,可以通过降低费用、加大宣传等措施来提高港口的竞争力。

参 考 文 献

[1] 姜汝翰. 基于灰色模型的青岛港集装箱吞吐量预测研究[D]. 大连:大连海事大学,2019.

- [2] 孙瀚冰,程亮. 灰色预测模型在港口集装箱吞吐量预测中的应用[J]. 集装箱化,2003(9):36-38.
- [3] MAK K L, YANG D H. Forecasting Hong Kong's Container Throughput with Approximate Least Squares Support Vector Machines [J]. Lecture Notes in Engineering and Computer Science,2007,2165(1).
- [4] 刘宇璐,陈冬林. 基于ARIMA模型的武汉港货物吞吐量预测研究[J]. 中国水运,2016(10):45-47.
- [5] 杨思凡,魏梦,丁蓉. 基于多因素选择和误差修正的BP神经网络港口货物吞吐量预测[J]. 价值工程,2020,39(18):68-71.
- [6] 杨金花,杨艺. 基于灰色模型的上海港集装箱吞吐量预测[J]. 上海海事大学学报,2014,35(2):28-32.
- [7] 王炳丹. 基于SVM的集装箱吞吐量预测研究[D]. 北京:北京交通大学,2011.
- [8] 蒲悦逸,王文涵,朱强,等. 基于CNN-ResNet-LSTM模型的城市短时交通流量预测算法[J]. 北京邮电大学学报,2020:1-9.
- [9] 张古尧,马爱清. 基于随机失活LSTM网络的避雷器阻性电流预测方法[J]. 水电能源科学,2020,38(10):159-162.
- [10] 连静,王欣然,李琳辉,等. 基于人-车交互的行人轨迹预测[J]. 中国公路学报,2020:1-10.
- [11] 唐鸣,雷晓辉,龙岩,等. 基于长短时记忆网络(LSTM)的南水北调中线水位预测[J]. 中国农村水利水电,2020(10):189-193.
- [12] Haoran Y, Yi Q, Sheng X, et al. Long-term gear life prediction based on ordered neurons LSTM neural networks[J]. Measurement, 2020:165.
- [13] Mei L, Hu R, Cao H, et al. Realtime mobile bandwidth prediction using LSTM neural network and Bayesian fusion[J]. Computer Networks, 2020, 182: 107515.
- [14] 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.
- [15] 赵亚鹏,丁以中. 基于GRNN神经网络的长江干线港口集装箱吞吐量预测[J]. 中国航海,2006(4):90-91,100.
- [16] 岳聚财. 基于LSTM-ARIMA的短期航迹预测方法研究及可视化系统开发[D]. 天津:中国民航大学,2020.
- [17] 李娜. 港口经济与腹地经济互动发展[D]. 上海:上海海洋大学,2018.
- [18] 李广儒,朱庆辉. 基于Elman神经网络的港口货物吞吐量预测[J]. 重庆交通大学学报(自然科学版),2020,39(6):8-12.