

基于 Seq2Seq 模型的港口进出口货物量预测^①



王涛¹, 张伟², 贾宇欣¹, 林友芳^{1,3}, 万怀宇^{1,3}

¹(北京交通大学 计算机与信息技术学院 交通数据分析与挖掘北京市重点实验室, 北京 100044)

²(天津市商务局 口岸平台处, 天津 300040)

³(北京交通大学 综合交通运输大数据应用技术交通运输行业重点实验室, 北京 100044)

通讯作者: 万怀宇, E-mail: hywan@bjtu.edu.cn

摘要: 港口进出口货物吞吐量是反映港口业务状况的重要指标, 其准确预测将给港口经营管理人员进行决策提供重要的依据. 利用机器翻译领域的 Seq2Seq 模型, 对影响港口进出口货物量的多种因素进行建模. Seq2Seq 模型可以反映进出口货物量在时间维度上的变化规律, 并且可以刻画天气、节假日等外部因素的影响, 从而进行精准预测. Seq2Seq 模型包含两个由循环神经网络 (LSTM) 组成的编码器和解码器, 能够捕捉长短期时间范围内集装箱变化趋势, 可以根据历史进出口货物量预测未来一段时间的货物量信息. 在真实的天津港进出口集装箱数据集上进行了实验, 结果表明 Seq2Seq 模型的深度学习预测方法效果优于传统的时间序列模型以及其他现有的机器学习预测模型.
关键词: 进出口货物量; Seq2Seq; 深度学习; 时间序列

引用格式: 王涛, 张伟, 贾宇欣, 林友芳, 万怀宇. 基于 Seq2Seq 模型的港口进出口货物量预测. 计算机系统应用, 2020, 29(3): 132-139. <http://www.c-s-a.org.cn/1003-3254/7291.html>

Prediction on Import and Export Goods Volume of Ports Based on Seq2Seq Model

WANG Tao¹, ZHANG Wei², JIA Yu-Xin¹, LIN You-Fang^{1,3}, WAN Huai-Yu^{1,3}

¹(Beijing Key Laboratory of Traffic Data Analysis and Mining, School of Computer and Information Technology, Beijing Jiaotong University, Beijing 100044, China)

²(Tianjin Port Platform Office, Commission of Commerce, Tianjin 300040, China)

³(Key Laboratory of Transport Industry of Big Data Application Technologies for Comprehensive Transport, Beijing Jiaotong University, Beijing 100044, China)

Abstract: The port amount of import and export goods can reflect the congestion of port flow, whose accurate prediction would provide suggestions for port management to make reasonable decisions. In this study, the Seq2Seq model in the field of machine translation is used to model various factors that affect the amount of goods inflow and outflow from the port. An Seq2Seq model can reflect the change of the amount of import and export goods in the time dimension and describe the influence of external factors such as weather and holidays, so as to make accurate predictions. An Seq2Seq model consists of two LSTM, respectively acting as an encoder and a decoder. It can capture the changing trend of containers in the short and long term and predict the amount of goods in the future based on historical import and export volume. Experiments were carried out on a real-world dataset of import and export containers in Tianjin Port. The experimental result reveals that the deep learning prediction model based on Seq2Seq is more effective and efficient than traditional time series model as well as other existing machine learning prediction models.

Key words: import and export volume; Seq2Seq; deep learning; time series

① 基金项目: 中央高校基本科研业务费 (2019JBM024)

Foundation item: The Fundamental Research Funds for the Central Universities of China (2019JBM024)

收稿时间: 2019-07-17; 修改时间: 2019-08-22; 采用时间: 2019-08-30; csa 在线出版时间: 2020-02-28

1 引言

港口进出口货物吞吐量是港口发展战略研究的重要内容,是港口物流规划、物流资源合理配置过程中的重要环节,同时它也为政府和港口管理部门制定科学发展规划以及切实可行的市场开拓策略提供依据。政府可以通过港口物流需求预测评估港口物流行业对当地经济发展的总体贡献,从而制定港口物流行业的发展政策,并引导物流市场资源的合理利用与优化配置。因此,正确地预测港口进出口吞吐量对于合理布局港口、科学制定投资规模和营运策略,以及综合运输规划都是十分重要的。与此同时,天津港作为世界上等级最高的人工深水港,也作为我国北方地区重要进出口港口,国内国外辐射广,货物种类多,运输模式复杂,基于多年的港口运行特点形成了自己独有的物流和报关模式,在进口和出口通关数据预测方面十分需要根据目前实际运行状况做深入的梳理和研究,以进一步提高口岸管理信息化和通关作业装备自动化水平,同时提高口岸工作效率^[1-5]。

根据实际需求,本文研究以天为粒度级同时预测八种不同类型的集装箱吞吐量,具体包括:进口集装箱数量(进口),出口集装箱数量(出口),大集装箱数量(大箱),小集装箱数据(小箱),进口大集装箱数量(进口大箱),进口小集装箱数量(进口小箱),出口小集装箱数量(出口小箱),出口大集装箱数量(出口大箱)。不同类别的集装箱吞吐量不仅可以反映港口的承载量变化,也可以反映港口的不同类别的集装箱的变化趋势。

预测不同类型进出口货物的吞吐量是一个非常具有挑战性的问题,因为进出口货物的吞吐量受到许多复杂因素的影响。在时间维度上,未来一段时间的货物吞吐量与距离当前时间较近的一段时间以及历史上具有相似特征时间节点上的吞吐量都有很大的关系。另外,由日常工作的规律可知,货物吞吐量具有明显的以日和周为单位的周期性规律,利用这些规律都可以帮助我们有效提高货物吞吐量预测的准确性。进出口货物的吞吐量还会受到天气、节假日、国家政策、外部事件等外部因素的影响。

近年来,深度学习在很多应用领域都取得了很大的成功。循环神经网络^[6](RNN),在普通多层前馈神经网络基础上,增加了隐藏层各单元间的横向联系,通过一个权重矩阵,可以将上一个时间序列的神经单元的值传递至当前的神经单元,从而使神经网络具备了记

忆功能,对于处理有上下文联系的NLP、或者时间序列的机器学习问题,有很好的应用性。长短期记忆模型(Long Short-Term Memory, LSTM)^[7]作为一种改进的循环神经网络,有效地缓解了传统循环神经网络在处理长序列数据时存在的梯度消失问题,被广泛应用于时间序列学习任务上。在LSTM中输入序列和输出序列必须等长,为了解决输入输出不定长的问题,改进了经典的LSTM,并且加入了编码器、解码器模块。Seq2Seq是一个Encoder-Decoder结构的模型,输入是一个序列,输出也是一个序列。Encoder将一个可变长度的输入序列变为固定长度的向量,Decoder将这个固定长度的向量解码成可变长度的输出序列。受此启发,为了同时刻画货物吞吐量在时间维度上的依赖特性,本文提出了基于Seq2Seq模型的神经网络结构,用于解决进出口货物吞吐量预测问题^[8-11]。

基于Seq2Seq的预测模型首先利用长短期记忆模型刻画货物吞吐量随着时间的推移变化规律。同时,编码器-解码器模块可更好的学习历史货物吞吐量之间在高维隐藏空间的变换模式。该模型还可以对外部影响因素建模,进一步提高进出口货物数量预测准确性。

2 相关工作

近年来,进出口货物量预测已经成为海关进出口贸易的一个重要问题。进出口货物量预测分为定性预测和定量预测两类,在定性预测中研究人员主要关心的是货物量的发展趋势。定性研究方法主要有德尔菲法和专家会议法。而定量问题则更关心进出库货物量的具体大小以及一些细节的变化比如特殊节日,传统的定量预测集中在以年为单位进行预测,更关注整年的情况。本文研究的问题属于定量预测问题,而且预测的单位为天级别,可以做到更细粒度的预测,这个问题的难度更大,更具有研究与实际应用价值。

进出口货物预测的核心研究对象是时间序列数据。早期的研究主要采用经典的时间序列预测模型,如自回归滑动平均模型(Autoregressive Moving Average, ARMA)^[12],自回归积分滑动平均模型(Autoregressive Integrated Moving Average, ARIMA)^[13-15]。基于ARIMA模型,一些扩展模型如SARIMA^[16]、KARIMA^[17]、VAR^[18]以及STARIMA^[19]等被提出来以适应不同的预测问题。然而,此类时间序列预测模型具有很大的局限

性,其预测结果通常很难满足人们的要求。

随着大数据技术越来越成熟,学者们在解决时间序列的预测问题时,开始关注并重点研究数据驱动模型。其中应用得最多的模型包括支持向量回归模型(Support Vector Regression, SVR)^[20]和多元线性回归模型(Multivariable Linear Regression, MLR)^[21]模型以及回归决策树模型(Regression Decision Tree, RDT)^[22]。其中,SVR模型通过核函数将数据映射到高维空间以描述交通数据的非平稳变化特征,但其预测结果的好坏很大程度上取决于核函数的选择。MLR和RDT模型则比较关注于特征的选择方式,很多学者针对不同的需求设计了不同的机器学习模型^[23-25]用于特定场景下的进出口货物数量问题。

近年来,因为神经网络强大的表示能力,基于深度学习的模型在时间序列预测问题当中应用越来越广泛,此类模型中的两个重要分支分别是基于BP神经网络的模型和基于循环神经网络(Recurrent Neural Networks, RNNs)的模型^[26-28]。BP神经网络,即反向传播网络,它是利用非线性可微分函数进行权值训练的多层网络,具有极强的容错性、自组织和自学习性,有

着较好的函数逼近和泛化能力。作为第二类重要分支的循环神经网络常被用于序列数据学习任务^[9,29,30]。其中,长短期记忆模型^[31]在文本分析^[32]、语音识别^[33]以及机器翻译^[34]等序列数据学习任务中都取得了巨大的成功。基于长短期记忆模型的Seq2Seq模型则克服了其输入输出定长的缺陷,可以更灵活的进行预测。在进出口货物数量预测问题中,我们希望预测模型能够自动学习过去一段时间数据之间的依赖关系,而不需要人为发现其中的联系。因此,本文提出一种基于Seq2Seq的深度学习网络结构来解决这一问题。

3 问题描述

本节对货物进出口数量预测问题进行形式化描述,首先对历史进出口货物数量的整体数据特征进行描述,然后在此基础上对问题进行形式化定义。

图1是其几种不同类型的集装箱吞吐量的历史变化趋势图。类别分别为大箱进口,小箱进口,大箱出口,小箱出口。如图1所示,不同类别的集装箱以天为单位在时间轴上连续分布,形成连续的时间序列,因此港口进出口货物问题是一个典型的时间序列预测问题。

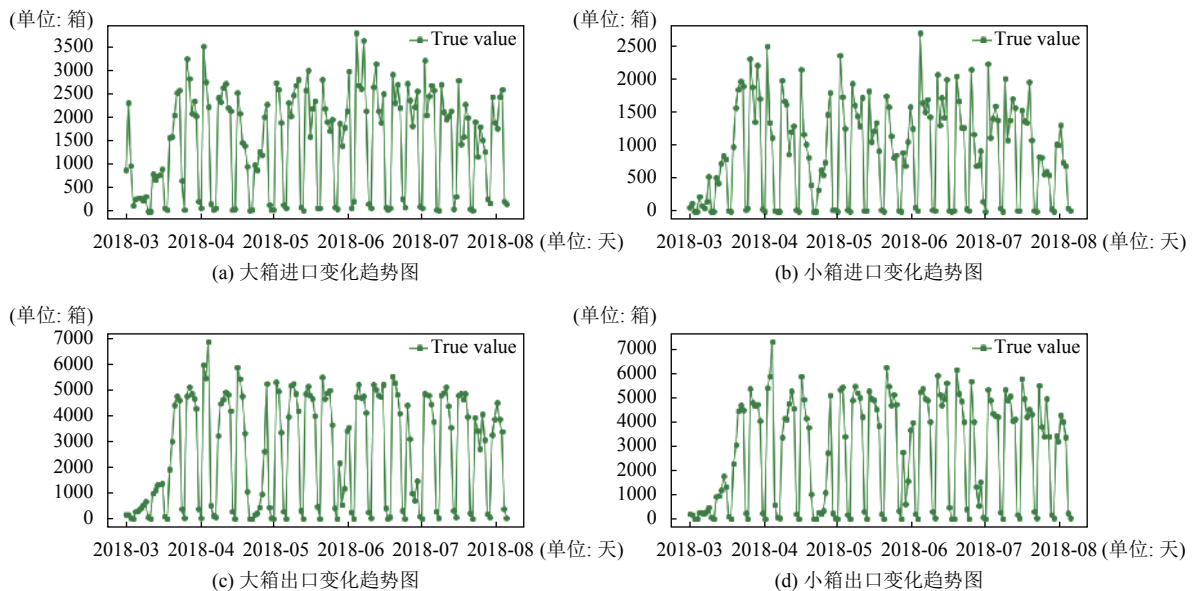


图1 不同种类别集装箱数据趋势变化

本文的研究问题是依据不同类别的集装箱吞吐量历史数据来以周(7天)为级别预测未来的集装箱数量。

问题定义.给定不同类别进出口货物历史统计值 $\{X_t|t=1, 2, \dots, n\}$,预测 $X_{t+\Delta t}$,其中 $\Delta t \in \{1, 2, \dots, 7\}$ 表示待预测的时间区间与当前时间区间 t 之间的跨度,即预

测未来一周的数量。

4 基于Seq2Seq模型进出口货物量预测方法

本节将详细介绍基于Seq2Seq神经网络模型的进出口货物量预测方法。Seq2Seq是RNN(循环神经网络

络)的一个变种,它是一个 Encoder-Decoder 结构的网络,它的输入是一个序列,输出也是一个序列,Encoder 中将一个可变长度的信号序列变为固定长度的向量表达,Decoder 将这个固定长度的向量变成可变长度的目标信号序列.这个结构最重要的地方在于输入序列和输出序列的长度是可变的.将 Seq2Seq 网络应用于时间序列预测问题,可以根据历史一段时间的信息,去预测未来一段时间的数据情况,通过神经网络的记忆性、容错性、自学习性来拟合预测函数,从而进行时间序列问题的预测.

4.1 问题分析

在进出口货物预测问题中存在 4 种时间依赖特性,分别为:短时依赖 (closeness) 特性和周周期依赖 (week influence),节假日影响 (holiday influence) 特性,特殊情况影响 (special influence).例如,图 2 是港口进口集装箱量在某段时间的以天为单位的变化情况,很明显地展示了港口集装箱吞吐量的 3 类时间依赖特性.




图 2 进口集装箱变化曲线

1) 短时依赖特性: 体现在某一天的集装箱数量与其前面刚刚过去的几天内的集装箱量对预测该天的影响,即相邻天集装箱数量之间存在很强的相关性.

2) 周周期依赖特性: 体现了集装箱数量以星期为单位的周期性规律.历史上相同的周次之间之间存在一定的联系,以此类推即集装箱吞吐量会受到当前日期的星期数的影响.

3) 节假日影响特性: 体现了节假日 (周六,周日,法定放假节日等) 与非节假日的区别,节假日之间的联系,还包括节前补班与节后上班之间的差异.图 2 中节假日显示出明显的差异.

4) 特殊情况影响特性: 体现在每个月的月末出现的集装箱变化异常,以及特殊政策因素造成的影响.

根据以上分析结果,我们进行了相应的特征构造.根据反复的特征构造实验以及实验结果,我们确定以星期 (1-7),是否节假日,是否补班,月底 (月末一周),放假前 (前 3 天) 作为最优特征组合,以上特征反映货物进出口数量在时间维度上的所有特性.

4.2 模型结构

图 3 是本文提出的基于 Seq2Seq 的神经网络模型的完整网络结构.该模型可以将短时依赖特性、周周期依赖特性、节假日影响、特殊情况影响全部都考虑进去,并进行规律的学习.

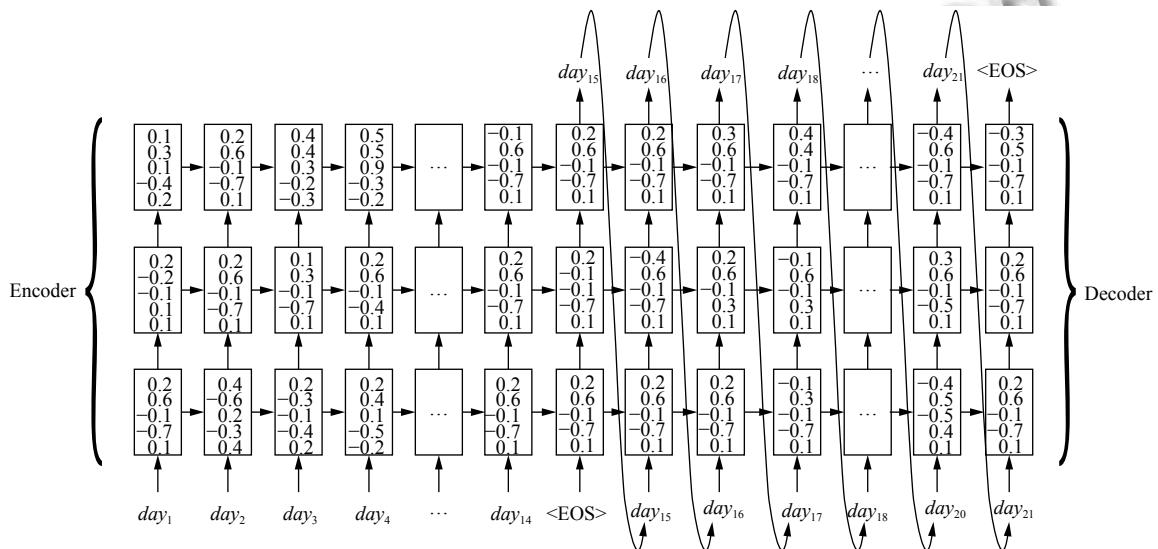


图 3 基于 Seq2Seq 的神经网络结构

图 3 的底端表示模型的输入.输入以 3 周作为一个窗口,前两周的特征矩阵作为 Encoder 层的输入,后一周的集装箱量的值作为 Decoder 层的输出,Decoder

层的输出与真实值作为损失函数计算的输入.每一个窗口的输入由 21 天组成,用 $input = [day_1, day_2, day_3, \dots, day_{14}]$ 表示每一个窗口里 Encoder 层的输入, $day_i =$

["Holidays", "Work", "Month_end", "Before_holidays", "Days₁", "Days₂", "Days₃", "Days₄", "Days₅", "Days₆", "Days₇"] 其中 $day_i \in input$. day_i 表示特征向量, 采用 one-hot 方法表示.

$output = [day_{15}, day_{16}, day_{17}, \dots, day_{21}]$, $output$ 向量表示当天真实的货物进出口数量. 这样每一个训练窗口 $window = [input, output]$, 表示由 Encoder 层的输入和 Decoder 层的输出维度大小组成的向量, 每一个 $window$ 为 21×12 . 具体含义见表 1. 基于深度学习的 Seq2Seq 模型中有很多需要学习的参数, 所以需要大量训练样本. 本文提出一种滑动窗口样本构造方法, 在给定历史时间 (单位: 天) 的集装箱数据上, 可构造出更多训练样本. 本方法尤其适用于历史数据量不充分的情况. 每一个训练的窗口 $window$ 大小为连续 21 天的数据, 然后以天为单位向后滑动窗口, 类似于 TCP 的滑动窗口选择^[35]. 假设总数据有 N 个点 ($N > 21$), 那么就可以构造 $(N-21+1)$ 个窗口, 极大提高了独立样本的数量. 滑动窗口可很好刻画集装箱量的短时依赖特性, 保证数据在时间上的连续性, 充分利用每一天的数据, 且可以实现数据在时间维度上的交叉验证即数据在不同的窗口内既可以充当测试集也可以充当验证集, 可以更好的优化学习参数.

图 4 表示单层 Seq2Seq 网络结构, Source 表示网络输入, $h(x)$ 和 $H(x)$ 分别表示 LSTM 的 cell, 在每一层

网络里 Encoder 将输入 Source 序列转为上下文向量 (context vector) C , Decoder 将 C 转化为输出序列.

表 1 特征向量表示

特征名称	含义	取值
Holidays	是否节假日	1/0
Work	是否补班	1/0
Month_end	是否是月底 (月末一周)	1/0
Before_holidays	是否是放假前 (前 3 天)	1/0
Days ₁	是否是周一	1/0
Days ₂	是否是周二	1/0
Days ₃	是否是周三	1/0
Days ₄	是否是周四	1/0
Days ₅	是否是周五	1/0
Days ₆	是否是周六	1/0
Days ₇	是否是周日	1/0

$$C = F(day_1, day_2, day_3, \dots, day_{14}) \quad (1)$$

$$day_i = G(C, day_{15}, day_{16}, \dots, day_{i-1}) \quad (2)$$

其中, $i \in [15, 21]$ 且 F 和 G 分别表示编码器和解码器模块.

模型的训练以最小化损失函数为目标. 我们将损失函数定义为每个窗口里的集装箱数量的真实值和预测值之间的平均绝对误差, 我们以 $d\hat{a}y_i$ 表示模型输出值, day_i 表示真实大小, 其中 $i \in [15, 21]$.

$$\mathcal{L}(\theta) = \frac{1}{7} \sum_{i=15}^{21} \|day_i - d\hat{a}y_i\| \quad (3)$$

其中, θ 包括 Seq2Seq 模型中所有需要训练的参数.

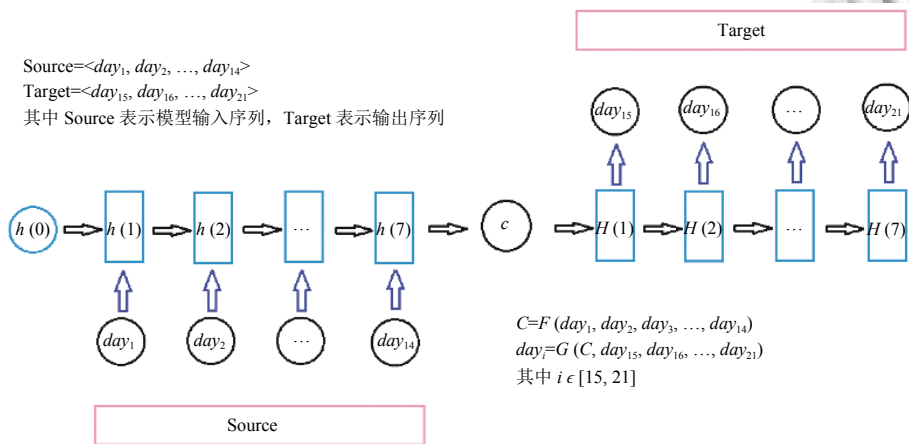


图 4 单层 Seq2Seq 网络结构

基于 Seq2Seq 的预测模型相比于其他方法强调模型结构的深度, 突出特征学习的重要性, 通过逐层特征变换, 将样本在原空间的特征表示变换到新特征空间, 并将时间及外部特征进行编码、解码的高维度映射, 使预测结果更准确.

5 实验与结果分析

5.1 数据集

实验数据集为天津港历史集装箱吞吐量数量数据集 (TJ_DataSet), 数据集的统计信息如表 2 所示.

表2 数据集统计信息

数据集	TJ_DataSet
数据类型	天级别的各种类型的集装箱吞吐量
港口	天津港
时间跨度	2017.7.26~2018.9.13
时间区间长度	414天
非空数据点	358
集装箱类别	8种(进口,出口,大箱,小箱,进口大箱,进口小箱,出口大箱,出口小箱)
时间单位	天
节假日	119天
补班	15天

5.2 数据预处理

(1) 无效数据过滤

首先对分析数据,剔除异常数据,异常原因主要有关检融合,系统未普及等,数据清洗后选定数据质量良好的时间段,即2018-3-1~2018-8-25为实验数据集。

(2) 滑动窗口

实验采取滑动窗口的形式来组织训练集和测试集,将原始数据按类别(大箱/小箱/进口大箱/进口小箱/出口大箱/出口小箱/进口/出口)、时间顺序排列,数据总量为2018-3-1到2018-8-5,共185个点,每个时间窗口的大小为21天(2周输入,1周输出),并按天滑动。训练集与测试集的比例为7:3,总窗口数为164个,其中训练集窗口个数为126个,测试集窗口个数为28个。

(3) 数据标准化

对集装箱量大小进行min-max标准化,进行标准化可以加快模型的收敛速度以及提高模型的精度。

5.3 基准方法与评价指标

本文将Seq2Seq模型和以下4个基准方法进行比较。

(1) RDT: 回归决策树模型,是一种基于决策树的回归模型。

(2) SVR: 支持向量回归模型,SVR是使用SVM(支持向量积)来拟合曲线,从而进行回归分析,是一种应用广泛的时间序列预测方法。

(3) MLR: 多元线性回归模型,是在线性回归的基础上进行时间序列拟合。

(4) LSTM: 长短期记忆模型,是一种循环神经网络模型,擅长处理序列类型的数据。

本文使用均方根误差(Mean Absolute Deviation, MAE)作为模型预测效果的评价指标:

$$MAE = \frac{1}{n} \sum_{i=0}^n \|day_i - \hat{day}_i\| \quad (4)$$

其中, day_i 表示集装箱数据的真实值, \hat{day}_i 表示集装箱

数据的预测值, n 表示连续天数大小。

5.4 TJ_DataSet 数据集实验

在TJ_DataSet数据集上验证了基于Seq2Seq神经网络的预测效果。模型的超参设置见表3所示,预测结果如表4。

表3 Seq2Seq中的超参设置

参数	值	备注
hidden_dim	30	隐藏层神经元个数
depth	3	网络层数
Dropout 大小	0.5	Dropout
SequenceLength	14	输入序列长度
ResultLength	7	返回序列长度
normalise	true	对数据进行正则化
学习速率	0.0002	学习速率
优化器	Adam	训练时用的优化器
批大小	30	训练模型时的批大小

表4 各种方法预测结果

类别	RDT	SVR	MLR	LSTM	Seq2Seq
大箱进口	298.52	285.14	568.34	476.91	275.02
小箱进口	299.50	277.67	384.86	511.23	280.27
大箱出口	524.52	530.55	1082.75	1055.75	431.54
小箱出口	692.81	629.28	1150.67	1028.34	409.50
进口	514.37	519.64	895.70	973.14	494.85
出口	1186.49	1162.65	2195.11	1922.32	830.45
大箱	730.53	719.61	1544.89	1097.38	711.69
小箱	877.34	783.06	1413.01	1089.51	592.19

如表4所示,基于Seq2Seq的神经网络明显比其他基准方法要好,在大箱进口,大箱出口,小箱出口,进口,出口,大箱,小箱这7种类别上,Seq2Seq方法的MAE明显比其他所有的方法要好,在小箱进口上基于RBF核的SVR表现要略好一点,通过对小箱进口的数据进行分析发现,测试集种小箱进口的数据短期依赖性比较差,而SVR可以在长期记忆性上做的更好一些。Seq2Seq模型相对于单独的LSTM模型具有较大优势,首先Seq2Seq可以通过更长时间的数据来学习短期内的一段数据,而LSTM只能通过定长的时间来学习并预测与之等长的时间序列,而且Seq2Seq的编码器-解码器模块具有更高维度上的拟合性。

各种类型的集装箱数量预测图如图5所示,这里截取测试集中2018-7-3~2018-7-31这一时间段的进行展示。由图5可以看出,模型在未来一段时间内的预测效果相对较好。其中7-23到7-27这一周出现明显的误差,后经过业务分析,这一周的确存在因为关检融合造成的原数据不准的情况,进一步说明了模型的稳定性和正确性,并且具有一定的异常纠错功能。

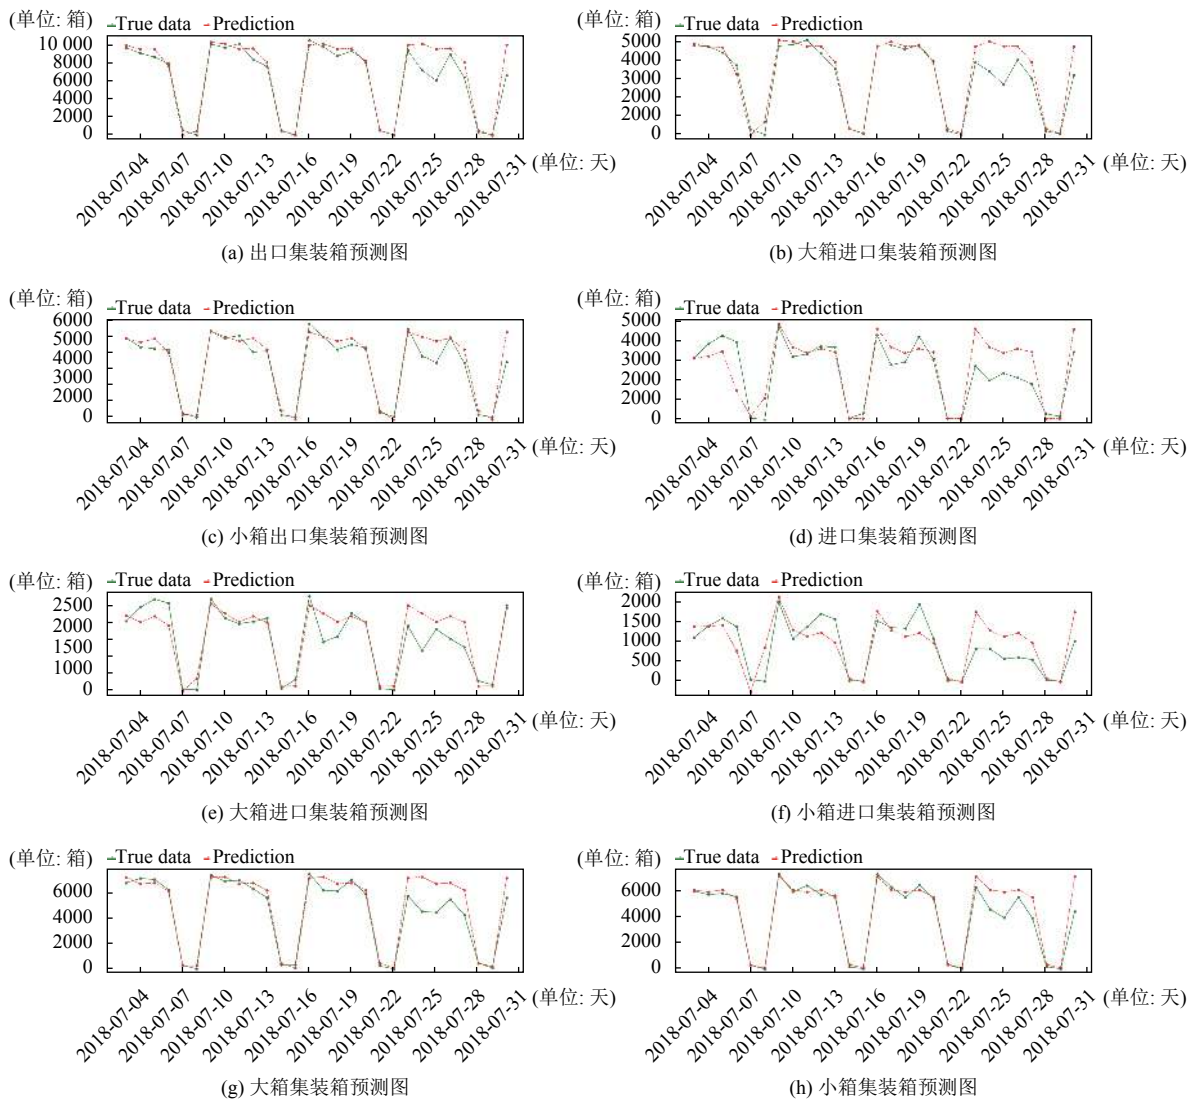


图5 模型预测效果图

6 结束语

本文提出一种基于 Seq2Seq 的神经网络模型用于解决港口货物量预测问题。基于 Seq2Seq 的模型可以同时影响港口货物量变化的两类因素,即时间依赖以及外部影响因素进行建模。基于 Seq2Seq 的神经网络模型结合长短期记忆模型和编码器、解码器模块能够学习港口货物量数据的时间特征,最终通过滑动窗口的学习方式,得到准确的预测结果。我们将基于 Seq2Seq 的模型和经典的时间序列预测模型、机器学习模型,基于深度学习的预测模型同时在相同的数据集上进行了对比实验,实验结果表明基于 Seq2Seq 的网络在不同数据集上取得了 7 种类型下的最优和一个类型下的次优的预测效果。但该方法还有优化的空间,比如其他外部特征比如政治因素,经济形式,天气,股票等,也会

对集装箱的吞吐量大小产生一定的影响,但这部分因素难以进行合理量化,可作为后续模型调优的方向。

参考文献

- 岳雷,余丽波,周健,等. 全国主要港口一季度综述. 中国远洋海运, 2019, (4): 86.
- 王宇,杨磊. 智慧港口建设推动天津港集装箱板块提质增效. 中国港口, 2019, (2): 23-26.
- 刘长俭. 发挥港口优势, 高质量建设北方国际航运核心区. 产业创新研究, 2018, (7): 23-27.
- 吕晓涵. “一带一路”战略下天津港转型与发展. 经贸实践, 2018, (9): 100, 102.
- 佚名. 中国主要港口集装箱码头吞吐量快报. 集装箱化, 2019, 30(2): 32-33.
- Zhang J, Man KF. Time series prediction using RNN in

- multi-dimension embedding phase space. Proceedings of 1998 IEEE International Conference on Systems, Man, and Cybernetics. San Diego, CA, USA. 1998. 1868–1873.
- 7 Huang ZH, Xu W, Yu K. Bidirectional LSTM-CRF models for sequence tagging. arXiv: 1508.01991, 2015.
 - 8 Cho K, Van Merriënboer B, Gulcehre C, *et al.* Learning phrase representations using RNN encoder-decoder for statistical machine translation. arXiv: 1406.1078, 2014.
 - 9 Sutskever I, Vinyals O, Le QV. Sequence to sequence learning with neural networks. Proceedings of the 27th International Conference on Neural Information Processing Systems. Montreal, Canada. 2014. 3104–3112.
 - 10 Luong T, Pham H, Manning CD. Effective approaches to attention-based neural machine translation. Proceedings of 2015 Conference on Empirical Methods in Natural Language Processing. Lisbon, Portugal. 2015. 1412–1421.
 - 11 Bahdanau D, Cho K, Bengio Y. Neural machine translation by jointly learning to align and translate. arXiv: 1409.0473, 2014.
 - 12 Hamilton JD. Time Series Analysis. New Jersey: Princeton University Press, 1994. E
 - 13 Box GEP, Jenkins GM, Reinsel GC, *et al.* Time Series Analysis: Forecasting and Control. 5th ed. Hoboken: John Wiley and Sons, 2015.
 - 14 Polson N, Sokolov V. Deep learning predictors for traffic flows. arXiv: 1604.04527, 2016.
 - 15 Wu YK, Tan HC. Short-term traffic flow forecasting with spatial-temporal correlation in a hybrid deep learning framework. arXiv: 1612.01022, 2016.
 - 16 Williams BM, Hoel LA. Modeling and forecasting vehicular traffic flow as a seasonal ARIMA process: Theoretical basis and empirical results. Journal of Transportation Engineering, 2003, 129(6): 664–672. [doi: [10.1061/\(ASCE\)0733-947X\(2003\)129:6\(664\)](https://doi.org/10.1061/(ASCE)0733-947X(2003)129:6(664))]
 - 17 Van der Voort M, Dougherty M, Watson S. Combining Kohonen maps with ARIMA time series models to forecast traffic flow. Transportation Research Part C: Emerging Technologies, 1996, 4(5): 307–318. [doi: [10.1016/S0968-090X\(97\)82903-8](https://doi.org/10.1016/S0968-090X(97)82903-8)]
 - 18 Bolshinsky E, Friedman R. Traffic flow forecast survey. Computer Science Department, Technion, 2012.
 - 19 Kamarianakis Y, Prastacos P. Space-time modeling of traffic flow. Computers & Geosciences, 2005, 31(2): 119–133.
 - 20 Williams G, Baxter R, He HX, *et al.* A comparative study of RNN for outlier detection in data mining. Proceedings of 2002 IEEE International Conference on Data Mining. Maebashi City, Japan. 2002. 709–712.
 - 21 王大荣, 张忠占. 线性回归模型中变量选择方法综述. 数理统计与管理, 2010, 29(4): 615–627.
 - 22 杨学兵, 张俊. 决策树算法及其核心技术. 计算机技术与发展, 2007, 17(1): 43–45. [doi: [10.3969/j.issn.1673-629X.2007.01.015](https://doi.org/10.3969/j.issn.1673-629X.2007.01.015)]
 - 23 王文. 线性回归结合季节性复合序列的深圳港集装箱吞吐量预测. 中国水运, 2012, 12(12): 23–25, 27.
 - 24 林慧君, 徐荣聪. 组合 ARMA 与 SVR 模型的时间序列预测. 计算机与现代化, 2009, (8): 19–22. [doi: [10.3969/j.issn.1006-2475.2009.08.006](https://doi.org/10.3969/j.issn.1006-2475.2009.08.006)]
 - 25 鲁渤, 杨显飞, 汪寿阳. 基于情境变动的港口吞吐量预测模型. 管理评论, 2018, 30(1): 195–201.
 - 26 范莹莹, 余思勤. 基于 NARX 神经网络的港口集装箱吞吐量预测. 上海海事大学学报, 2015, 36(4): 1–5.
 - 27 张树奎, 肖英杰, 鲁子爱. 基于灰色神经网络的港口集装箱吞吐量预测模型研究. 重庆交通大学学报 (自然科学版), 2015, 34(5): 135–138.
 - 28 LeCun Y, Bengio Y, Hinton G. Deep learning. Nature, 2015, 521(7553): 436–444. [doi: [10.1038/nature14539](https://doi.org/10.1038/nature14539)]
 - 29 LeCun Y, Bottou L, Bengio Y, *et al.* Gradient-based learning applied to document recognition. Proceedings of the IEEE, 1998, 86(11): 2278–2324. [doi: [10.1109/5.726791](https://doi.org/10.1109/5.726791)]
 - 30 Williams RJ, Zipser D. A learning algorithm for continually running fully recurrent neural networks. Neural Computation, 1989, 1(2): 270–280. [doi: [10.1162/neco.1989.1.2.270](https://doi.org/10.1162/neco.1989.1.2.270)]
 - 31 Hochreiter S, Schmidhuber J. Long short-term memory. Neural Computation, 1997, 9(8): 1735–1780. [doi: [10.1162/neco.1997.9.8.1735](https://doi.org/10.1162/neco.1997.9.8.1735)]
 - 32 Sutskever I, Martens J, Hinton G. Generating text with recurrent neural networks. Proceedings of the 28th International Conference on Machine Learning. Bellevue, WA, USA. 2011. 1017–1024.
 - 33 Vinyals O, Ravuri S, Povey D. Revisiting recurrent neural networks for robust ASR. Proceedings of 2012 IEEE International Conference on Acoustics, Speech and Signal Processing. Kyoto, Japan. 2012. 4085–4088.
 - 34 Bahdanau D, Cho K, Bengio Y. Neural machine translation by jointly learning to align and translate. arXiv: 1409.0473. [2016-05-19/2018-07-05].
 - 35 Cai YK. Study on performance of TCP in wireless networks. Proceedings of the 2018 4th International Conference on Systems, Computing, and Big Data. UK. 2018: 5.