

6-25-2020

Holiday Highway Traffic Flow Prediction Method Based on Deep Learning

Xiaofeng Ji

1. School of Traffic Engineering, Kunming University of Science and Technology, Kunming 650504, China;;2. Yunnan Integrated Transportation Development and Regional Logistics Management Think Tank, Kunming 650504, China;

Yicheng Ge

1. School of Traffic Engineering, Kunming University of Science and Technology, Kunming 650504, China;;2. Yunnan Integrated Transportation Development and Regional Logistics Management Think Tank, Kunming 650504, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Holiday Highway Traffic Flow Prediction Method Based on Deep Learning

Abstract

Abstract: Accurately predicting highway traffic holiday flow can provide important data for the emergency management of highway. The LSTM-SVR prediction model is established by using the theoretical framework of deep learning. The BP neural network is used to process the sample data, and the data features captured by LSTM are input into the SVR regression layer to realize the traffic flow prediction. Before and after the "Eleventh" Golden Week, the LSTM-SVR model was verified by using the traffic monitoring data of the intermodulation station in Lijiang City and the prediction results were compared with the others. It is found that the LSTM-SVR model has good applicability in the highway traffic flow prediction of different periods, weathers and traffic conditions.

Keywords

traffic engineering, holiday traffic flow prediction, deep learning, LSTM-SVR, expressway traffic flow

Recommended Citation

Ji Xiaofeng, Ge Yicheng. Holiday Highway Traffic Flow Prediction Method Based on Deep Learning[J]. Journal of System Simulation, 2020, 32(6): 1164-1171.

基于深度学习的节假日高速公路交通流预测方法

戢晓峰^{1,2}, 戈艺澄^{1,2}

(1. 昆明理工大学交通工程学院, 云南 昆明 650504; 2. 云南综合交通发展与区域物流管理智库, 云南 昆明 650504)

摘要: 准确的预测节假日期间高速公路交通流量, 能够为节假日高速公路应急管理提供重要的数据基础。利用深度学习的理论框架建立了 LSTM-SVR 预测模型, 利用 BP 神经网络对样本数据进行处理, 再将 LSTM 捕获的数据特征输入 SVR 回归层中实现交通流预测。选取“十一”黄金周前后时段, 利用位于丽江市的交调站流量监测数据对 LSTM-SVR 模型进行验证, 并将 LSTM-SVR 模型与其它模型预测效果进行对比。发现 LSTM-SVR 模型在节假日不同时段、天气、流量状态下的高速公路交通流预测中有较好的适用性。

关键词: 交通工程; 节假日交通流预测; 深度学习; LSTM-SVR; 高速公路交通流

中图分类号: TP391.9 文献标识码: A 文章编号: 1004-731X(2020)06-1164-08

DOI: 10.16182/j.issn1004731x.joss.19-0565

Holiday Highway Traffic Flow Prediction Method Based on Deep Learning

Ji Xiaofeng^{1,2}, Ge Yicheng^{1,2}

(1. School of Traffic Engineering, Kunming University of Science and Technology, Kunming 650504, China;

2. Yunnan Integrated Transportation Development and Regional Logistics Management Think Tank, Kunming 650504, China)

Abstract: Accurately predicting highway traffic holiday flow can provide important data for the emergency management of highway. The LSTM-SVR prediction model is established by using the theoretical framework of deep learning. The BP neural network is used to process the sample data, and the data features captured by LSTM are input into the SVR regression layer to realize the traffic flow prediction. Before and after the “Eleventh” Golden Week, the LSTM-SVR model was verified by using the traffic monitoring data of the intermodulation station in Lijiang City and the prediction results were compared with the others. It is found that the LSTM-SVR model has good applicability in the highway traffic flow prediction of different periods, weathers and traffic conditions.

Keywords: traffic engineering; holiday traffic flow prediction; deep learning; LSTM-SVR; expressway traffic flow

引言

黄金周高速公路免费通行政策的实施, 促使节假日期间, 高速公路路段的交通流量显著增大且较

为密集, 尤其以自驾旅游为主的交通流为主要旅游城市之间的高速公路路段带来巨大的运行压力, 致使其交通运行效率降低、旅游交通体验度下降、交通安全事故增加。因此, 准确可靠的节假日高速公路交通流预测不仅能够为管理部门运输组织方案的制定提供科学依据, 而且有利于出行者合理规划行程。

短时交通流预测作为国内外智能交通系统的



收稿日期: 2019-10-08 修回日期: 2020-01-07;
基金项目: 国家自然科学基金(71563023), 云南省院省校合作研究项目(SYSX201611);
作者简介: 戢晓峰(1982-), 男, 湖北随州, 博士, 教授, 博导, 研究方向为交通运输规划与管理等。

<http://www.china-simulation.com>

• 1164 •

研究热点,在不同发展时期均取得了较为丰硕的研究成果。研究趋势主要由单一的参数统计模型过渡到非参数模型以及组合预测模型。随着交通流数据不断丰富, Vlahogianni 等^[1]指出交通流预测方法正逐渐从传统的模型驱动方法向数据驱动技术转变。时间序列的自回归统计(ARIMA)、k-最近邻、贝叶斯网络等基于模型驱动的浅层模型将无法很好地适应复杂的交通流状态。为此,基于数据驱动方法的神经网络和深度学习^[2]由于可实现自动提取交通流数据的相关深层次特征,被国内外研究者提出并将其用于交通流预测。如刘明宇等^[3]基于深度学习的神经网络结构,将门控循环单元神经网络算法应用于城市交通短时交通流预测,并通过比较 GRU 模型与 BPNN、ARIMA 和 SVR 模型的预测性能,最终证实 GRU 模型在城市交通流量方面具有较高的精度。罗文慧等^[4]通过对比单一的支持向量回归和卷积神经网络模型,验证了结合卷积神经网络与支持向量回归的预测模型的有效性。但卷积神经网络(CNN)需要足够的输入数据点来进行卷积,无法适用于小样本数据,因而基于 RNN (Recurrent Neural Network)和 LSTM(Long Short-Term Memory)的交通流预测模型应用较为广泛。王祥雪等^[5]通过不同路段、样本和步长的预测,证明了基于长短时记忆神经网络的递归神经网络模型可极大提升训练效率,缩短训练时长,具备较高的预测精度。高速公路系统是一个具有高度非稳定性和非线性的复杂系统,天气变化、道路故障、节假日等因素对原本封闭的高速公路系统的交通状态影响极大。许岩岩等^[6]以美国某高速路网的真实交通流量数据验证了分类回归树预测模型的有效性。张平等^[7]基于信息熵的概念,对高速公路路网 OD 流量进行分析,进而对高速公路出口流量进行了预测。张兰芳等^[8]考虑货车因素,用遗传算法优化支持向量机提高了高速公路交通流的预测性能。

目前, LSTM 模型较多应用于城市道路流量预测,基于节假日特殊情景下,将该模型用于高速公路交通流预测的研究稍显薄弱。节假日高速公路短

时交通流预测已经成为保障节假日期间高速公路安全畅通的重要前提,但将深度学习理论应用于这方面的研究较为鲜见。其次,受各种随机干扰因素及数据获取途径的影响,获取的原始交通流样本数据的质量较难符合预测模型需求,当质量较低的数据量较大时,模型也会更加复杂,必然导致整个算法效率低下,尤其引发的过拟合等问题将会严重影响预测性能。因此,对样本数据进行准确高效的处理和调整是保障和提高预测性能的重要基础。

基于上述分析,以神经网络和深度学习的思想框架为基础,将样本数据输入到预训练好的 BP 神经网络中实现残差直连对数据进行微调,然后利用 LSTM 模型对时间序列的强大记忆和特征提取功能,以及 SVR 模型对较小样本的适应性,构建 LSTM-SVR 模型对节假日交通流进行预测。最后,以丽江市的交通流量监测站数据为例进行模型验证,并对比了 LSTM-SVR 模型与 LSTM 和 SVR 单一模型的预测效果。

1 基本模型

1.1 LSTM 模型

LSTM 模型是由 Hochreiter 等提出的一种特殊的 RNN 模型,相比于 RNN 模型, LSTM 模型能够解决因权重矩阵难以确定而引发的梯度消失和梯度爆炸的问题。LSTM 网络引入了一种称为存储单元的新结构,如图 1 所示。




图 1 LSTM 结构图

Fig. 1 LSTM structure diagram

每个存储器单元包含 4 个主要元件:输入门、遗忘门、输出门和具有自重复的神经元。输入门 f_t 决定需要更新的单元,如式(1)所示;通过遗忘门

的 sigmoid 神经层对上一时刻单元状态中的信息进行抛弃或保留的选择, 并进行更新, 如式(2)和式(3)所示; 其次, 将输入门和遗忘门结合, 如式(4)所示; 最后, 由输出门限层决定将传递多少信息暴露给下一个时间单元并进行输出, 如式(5)所示, 其中, 获得隐藏状态信息如式(6)所示。

$$f_t = \sigma_g(W_f x_t + U_f h_{t-1} + b_f) \quad (1)$$

$$i_t = \sigma_g(W_i x_t + U_i h_{t-1} + b_i) \quad (2)$$

$$s_t = \tanh(W_c \cdot [W_c x_t + U_c h_{t-1}] + b_c) \quad (3)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot s_t \quad (4)$$

$$o_t = \sigma_g(W_o x_t + U_o h_{t-1} + b_o) \quad (5)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (6)$$

其中, $W_f, b_f, w_i, b_i, W_o, b_o$ 分别是各门限层的权值和偏移量, σ 和 \tanh 为激活函数。

1.2 SVR 模型

采用 RBF-SVR 函数替代 LSTM 的 Dense 层作为模型的输出。给定训练数据集 $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$, 对于样本 (x_i, y_i) 根据模型的输出 $f(x_i)$ 与真实值 y_i 之间的差别来计算损失, 当 $|f(x_i) - y_i| > \varepsilon$ 时, ε -SVR 的目标函数如公式(7)所示:

$$\begin{aligned} \min & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \\ \text{s.t.} & \begin{cases} f(x_i) - y_i \leq \varepsilon + \xi_i, \\ y_i - f(x_i) \leq \varepsilon + \xi_i^* \\ \xi_i > 0, \xi_i^* > 0, i = 1, 2, \dots, N \end{cases} \end{aligned} \quad (7)$$

式中: C 为惩罚系数; ξ_i 和 ξ_i^* 为松弛变量。

引入拉格朗日乘子, $\mu_i \geq 0, \hat{\mu}_i \geq 0, \alpha_i \geq 0, \hat{\alpha}_i \geq 0$, 定义拉格朗日函数为

$$\begin{aligned} L(w, b, \alpha, \hat{\alpha}, \mu, \hat{\mu}, \xi, \hat{\xi}) = & \frac{1}{2} \|w\|_2^2 + C \sum_{i=1}^N (\xi_i + \hat{\xi}_i) - \\ & \sum_{i=1}^N \mu_i \xi_i - \sum_{i=1}^N \hat{\mu}_i \hat{\xi}_i + \sum_{i=1}^N \alpha_i (f(x_i) - y_i - \varepsilon - \xi_i) + \\ & \sum_{i=1}^N \hat{\alpha}_i (y_i - f(x_i) - \varepsilon - \hat{\xi}_i) \end{aligned} \quad (8)$$

根据拉格朗日对偶性可得

$$w = \sum_{i=1}^N (\hat{\alpha}_i - \alpha_i) x_i \quad (9)$$

假设最终解为 $\alpha^* = (\alpha_1^*, \alpha_2^*, \dots, \alpha_N^*)$, 在 $\hat{\alpha}^* = (\hat{\alpha}_1^*, \hat{\alpha}_2^*, \dots, \hat{\alpha}_N^*)^T$ 中找出 α^* 的某个分量 $C > \alpha_j^* > 0$, 则有

$$b^* = y_i + \varepsilon - \sum_{i=1}^N (\hat{\alpha}_i^* - \alpha_j^*) x_i^T x_j \quad (10)$$

则模型输出的预测值为

$$f(x) = \sum_{i=1}^N (\hat{\alpha}_i^* - \alpha_i^*) K(x, x_i) + b^* \quad (11)$$

径向基核函数为

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad (12)$$

2 LSTM-SVR 预测模型

一方面, 节假日旅游流占据高速公路交通流的主导地位, 已有研究表明, 区域高速公路路段的旅游流集聚变化特征较为明显和复杂^[9]。由此导致高速公路交通流具有很大的随机性, 同时具备一定的规律性, 所有特性一般由短时变化引起, 而后引发小时、日的变化特征, 不同时间维度的集聚变化特征层层嵌套、相互关联。另一方面, 高速公路上的运行车辆涵盖以客车、货车、轻型机动车为主的十余种车型, 使得交通流数据内部特征复杂且节假日时间跨度较长。而 LSTM 模型能够通过自身的多层次体系架构, 由小及大、从不同层面提取原始数据中的固有特征, 具备识别节假日交通流特征的强大功能, 对于精确预测节假日高速公路路段交通流具有重要作用。LSTM 模型不仅能够识别节假日高速公路路段交通流在时间维度的变化特征, 同时, 能够将预测时间序列下的潜在交通拥堵、暴风雨天气等随机时空状态纳入考虑, 在特征提取时具有强大的鲁棒性和灵活性。

其次, 考虑到原始数据样本量较小, 且基于 BP 神经网络预训练和 LSTM 时间序列特征提取后的矢量特征维度较低、非线性强度较大, SVR 模型由于仅依赖于训练数据的一个子集, 非线性预测效率普遍较高^[10], 因此设计了 SVR 模型作为顶层预测模型。基于此, 提出 LSTM-SVR 相结合的预

测框架,对节假日高速公路交通流进行预测,框架如图 2 所示。其中, Epoch 表示样本轮寻次数, Batchsize 为训练样本的最小批量。

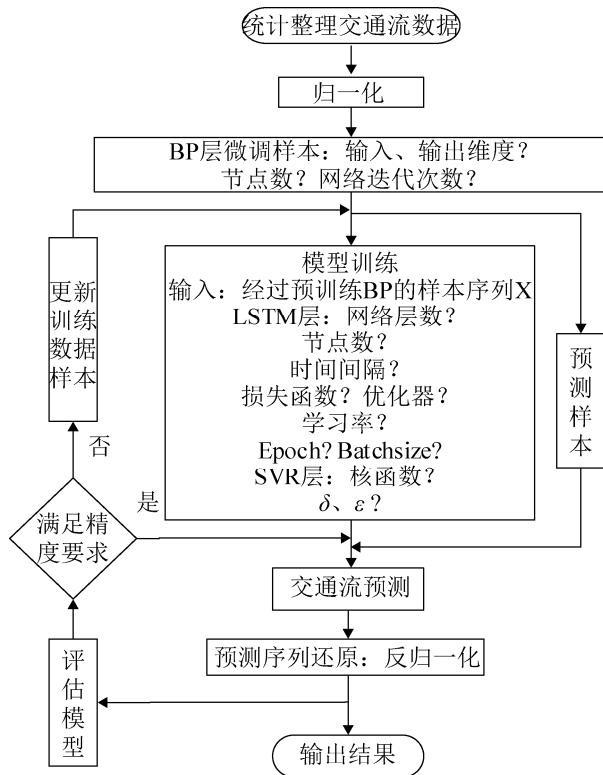


图 2 节假日高速公路交通流短时预测框架

Fig. 2 Holiday highway traffic flow short-term prediction framework

2.1 时间序列预处理

考虑到样本数据间因时间跨度大、波动频繁,使得初始的样本数据之间的量纲数量级差异较大,会对网络鲁棒性和收敛速度产生影响,因而样本数据的预处理是提高模型精度和训练速度的必要基础。考虑模型需求及数据特征,先后采用标准化和归一化方法对样本数据进行预处理,如式(13)所示。将预处理后的数据输入至已经训练好的 BP 神经网络中,数据序列分布趋势平稳,波动较小。若未归一化处理,在模型构建和运行过程中极易出现问题,主要体现在学习率的大小与收敛速率不易掌控,学习率过大时,下降速率较慢;反之则会呈直角形下降,速度过快。归一化处理在消除数据量纲数量级差异同时,能够较为完整的保存原始数据的信息。

$$X' = \frac{X - \min(X)}{\max(X) - \min(X)} \quad (13)$$

2.2 时间序列微调

将归一化后的数据输入至经过 2000 次迭代预训练的 BP 神经网络模型中进行时间序列微调。输入数据的维度为 4, 第一层隐含层节点个数 256, 设置第二层隐含层节点数为 4 以保证 BP 网络的输入和输出数据的维度不变。将隐含层的输出与 BP 网络输入层进行加和实现残差直连,避免过拟合问题同时提高了样本数据与 LSTM 模型的匹配度。此外,通过残差直连后,处理时间步长缩短、权值求导路径减小,避免了梯度问题的发生,在提升学习速率同时又减小了数据训练误差。

3 实例分析

3.1 预测场景

大(理)丽(江)高速公路是连接中国西南和西北地区的重要通道,全程 197.328 km,起于大理云浪收费站,止于丽江西收费站,沿线分布鸡足山、双廊、拉市海等多处旅游景点,而白汉场-丽江交调站是通往迪庆州及丽江市部分景点的必经站点。因此,选取大(理)丽(江)高速上的白汉场-丽江交调站,利用云南省交通流量数据统计平台获取 2014-2018 年十一黄金周前后 3 日的交通流监测数据,数据采样间隔为 1 h。以 2014-2017 年的 768 个样本数据为训练集,2018 年的 192 个样本数据为测试集进行流量预测,预测日的交通流及环境状态如表 1 所示。

表 1 预测目标日交通流及环境总体情况

Tab. 1 Predicting target day traffic flow and overall situation of environment

预测目标日期	2018-09-30	2018-10-01	2018-10-03
节假日状态	非正式节假日	国庆节第一日	国庆节中期
站点天气状况	天气晴朗	阴雨天气	天气晴朗
站点流量	流量较为平缓	流量波动较大	假日单日流量高峰
总体情况	平缓	较大	流量高峰

3.2 模型训练

基于上述节假日高速公路交通流预测框架,在 python 开发环境中的 IDE PyCharm 中完成模型的搭建和训练。考虑到普通的梯度下降法会使得训练过程产生震荡,且收敛速率较慢。为此,使用动量梯度下降法(Gradient descent with Momentum)对每个参数的学习率进行调整,对每一系列梯度进行指数加权平均,当梯度维持初始方向下降时,增加下降的幅度,从而使得更快地达到最优值;当梯度下降方向发生改变时,使用动量梯度下降法使变量更加平滑,不仅弥补了网络初始值设置的缺陷,也使网络能较快地达到最优值而没有太多震荡。

依据调整过后的样本数据特征,采用双层的 LSTM-SVR 模型,设置隐含层节点数 30,时间间隔为 4,各层输入输出维度如图 3 所示。

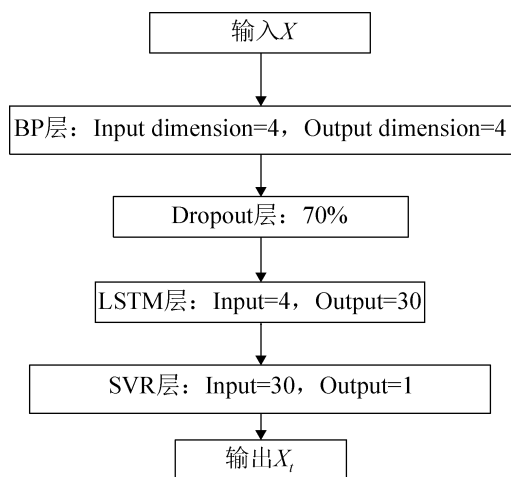


图 3 交通流时间序列预测模型

Fig. 3 Holiday highway traffic flow short-term prediction model


为防止过拟合,Dropout 层设定随机断开 70% 的神经元,使用“Adagrad”进行随机优化,“tanh”为激活函数,损失函数为 RMSE。同时,设置 Batchsize 为 32、Epoch 为 238,迭代达 5 000 次时学习趋近稳定,且当迭代次数继续增加时,模型的训练误差波动较小,趋于稳定。训练周期过长时存在模型过度拟合以及模型计算效率降低的风险。所以在模型训练过程中,应在兼顾精度与时效性的要

求,确定 Batchsize 与 Epoch 的值。最终将 LSTM 学习的特征向量输入到 SVR 的回归层中进行预测,调整参数 $C=0.1$, $\epsilon=0.01$ 。


3.3 预测结果及误差分析

(1) LSTMs 模型在不同条件下的预测结果分析


基于上述预测流程,选择实时预测的 2018-09-30, 2018-10-01, 2018-10-03 三日进行分析,如图 4 所示。实验发现, LSTM-SVR 模型在不同时间、天气、流量的状态下均可以实现较好地拟合交通流的变化趋势。尤其当流量变化较为平稳时段,平均误差在 21 辆/h。在部分时间点,交通流出现突变时,误差略微增大,预测精度有待提高。



(a) 2018-09-30 预测结果



(b) 2018-10-01 预测结果



(c) 2018-10-03 预测结果

图 4 预测结果

Fig. 4 Forecast results

(2) 3 种模型预测结果对比分析

分别采用 LSTM-SVR 模型、LSTM 与 SVR 单一模型对 198 个测试数据进行预测, 结果如图 5~7 所示。




图 5 LSTM-SVR 模型预测结果

Fig. 5 Prediction results with LSTM-SVR model




图 6 LSTM 模型预测结果

Fig. 6 Prediction results with LSTM model




图 7 SVR 模型预测结果

Fig. 7 Prediction results with SVR model

可以发现, SVR 模型在时间序列波动较大或较频繁时, 预测性能较差, 不能较好地跟踪节假日交通流的变化趋势, 说明单一的 SVR 模型不能很好的适应节假日高度波动的交通流时间序列。LSTM 模型在平稳时间序列及峰值预测中性能较好, 能较好的拟合交通流的变化趋势, 体现了 LSTM 强大的时间记忆及提取时间序列趋势和特征的能力, 但在发生突变的序列中性能明显降低, 说明 LSTM 简单的顶层回归预测对该时间序列的预测性能有待改善。而 LSTM-SVR 模型无论是在平稳时段、高峰期或突变节点, 均能更好的贴近真实的交通流时间序列。说明对于节假日高速公路等特殊情境下, 本文选取的 SVR 在基于最小化间隔损失的顶层预测能力要强于交叉熵损失函数。

(3) 误差分析

平均绝对误差(MAE)和均方根误差(RMSE)是体现模型效果的重要指标, 如式(14)~(15)所示:

$$MAE = \frac{1}{n} \sum_{t=1}^n |X_t - \hat{X}_t| \quad (14)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (X_t - \hat{X}_t)^2} \quad (15)$$

式中: n 为样本数量; X_t 为第 t 个样本的真实值; \hat{X}_t 为第 t 个样本的预测值。

其中, 可以用来评价 LSTM-SVR 模型与 LSTM、SVR 的单一模型的节假日高速公路交通流预测性能, 3 种模型的预测误差结果如表 2~3 所示。同时, 结合图 4 的预测结果可以对 3 种模型在节假日高速公路交通流预测工作中的适用性进行评价。

表 2 3 种模型在不同情况下的预测结果评价
Tab. 2 Evaluation of prediction results of three models under different conditions

节假日	MAE			RMSE		
	SVR	LSTM	LSTM-SVR	SVR	LSTM	LSTM-SVR
9月30日	0.243	0.084	0.076	0.104	0.105	0.047
10月1日	0.281	0.185	0.083	0.122	0.109	0.076
10月3日	0.248	0.118	0.072	0.114	0.128	0.047

表 3 预测结果对比
Tab. 3 Comparison of prediction results

方法	MAE	RMSE
SVR	0.313	0.112
LSTM	0.108	0.061
LSTM-SVR	0.091	0.053

可以发现, 单一的 SVR 模型预测性能最差, 相比之下, LSTM 的预测性能有了很大的改善。同时, LSTM-SVR 模型在 LSTM 模型的基础上, 进一步缩小了误差, 能更好的接近真实值。从 MAE 指标来看, LSTM-SVR 模型相比于 SVR 模型降低了 70.93%, 相比于 LSTM, 模型降低了 15.74%。从 RMSE 指标来看, LSTM-SVR 模型相比于 SVR 模型减小了 52.68%, 相比于 LSTM 模型降低了 13.11%, 印证了 LSTM-SVR 模型对于高速公路免费通行黄金周不同状态下的交通流是一种有效的预测方法。

4 结论

为了准确预测节假日高速公路交通流, 提出了 LSTM-SVR 节假日高速公路交通流预测模型。在利用 BP 神经网络进行样本数据处理的基础上, 通过 LSTM 模型进行特征提取, 并应用 SVR 模型实现预测。同时, 对 LSTM-SVR 模型和 LSTM、SVR 单一模型的预测效果进行了对比。为了符合应用场景, 选取大(理)丽(江)高速公路中的白汉场-丽江交调站为节假日高速公路交通流预测点, 对十一黄金周前后时段的交通流进行预测。主要结论如下:

(1) 建立的 LSTM-SVR 预测模型对于小样本数据和节假日高强度变化的交通流具有较高的预测精度, 主要在于 LSTM 模型能够高强度提取多

维特征向量, 提高数据挖掘效率, 在阴雨天气等随机、特殊情形下依然具有很强的抗干扰能力, 在训练中缓解了梯度问题。在此基础上, SVR 支持向量机预测模型也在顶层预测中展现了较强的非参数线性预测能力, 预测效率较高, 并且能够与 LSTM 模型较好的衔接和融合。

(2) 选取适合样本数据特征的预处理方法为模型提供了高质量的基础数据, 将样本数据输入到经过训练好的 BP 神经网络, 实现残差直连进行微调后, 提升了数据与模型的匹配度。

目前所建立的 LSTM-SVR 模型仅基于单个高速公路站点进行了实证研究, 考虑公路网络的复杂性, 下一步可通过改进此模型应用于节假日高速公路网及城市道路流量预测研究中来。

参考文献:

- [1] Vlahogianni E I, Karlaftis M G, Golias J C. Short-term traffic forecasting: Where we are and where we're going[J]. *Transportation Research Part C Emerging Technologies* (S0968-090X), 2014, 43(1): 3-19.
- [2] Lv Y, Duan Y, Kang W, et al. Traffic flow prediction with big data: A deep learning approach[J]. *IEEE Transactions on Intelligent Transportation Systems* (S1524-9050), 2014, 16(2): 1-9.
- [3] 刘明宇, 吴建平, 王钰博, 等. 基于深度学习的交通流量预测[J]. *系统仿真学报*, 2018, 30(11): 4100-4105, 4114.
Liu Mingyu, Wu Jianping, Wang Yubo, et al. Traffic flow prediction based on deep learning[J]. *Journal of System Simulation*, 2018, 30(11): 4100-4105, 4114.
- [4] 罗文慧, 董宝田, 王泽胜. 基于 CNN-SVR 混合深度学习模型的短时交通流预测[J]. *交通运输系统工程与信息*, 2017, 17(5): 68-74.
Luo Wenhui, Dong Baotian, Wang Zesheng. Short-term traffic flow prediction based on CNN-SVR hybrid deep learning model[J]. *Journal of Transportation Systems Engineering and Information*, 2017, 17(5): 68-74.
- [5] 王祥雪, 许伦辉. 基于深度学习的短时交通流预测研究[J]. *交通运输系统工程与信息*, 2018, 18(1): 81-88.
Wang Xiangxue, Xu Lunhui. Research on short-term traffic flow prediction based on deep learning[J]. *Journal of Transportation Systems Engineering and Information*, 2018, 18(1): 81-88.
- [6] 许岩岩, 翟希, 孔庆杰, 等. 高速路交通流短时预测方

- 法[J]. 交通运输工程学报, 2013, 13(2): 114-119.
- Xu Yanyan, Zhai Xi, Kong Qingjie, et al. Short-term prediction method of traffic flow in expressway[J]. Journal of Traffic and Transportation Engineering, 2013, 13(2): 114-119.
- [7] 张平, 张明欣, 宋国杰, 等. 基于 OD 稳定模式的高速公路出口流量预测方法研究[J]. 交通运输系统工程与信息, 2012, 12(3): 122-128.
- Zhang Ping, Zhang Mingxin, Song Guojie, et al. Research on highway export flow forecasting method based on OD stabilization mode[J]. Journal of Transportation Systems Engineering and Information, 2012, 12(3): 122-128.
- [8] 张兰芳, 赵焜. 考虑货车因素的高速公路短期交通流风险预测[J]. 同济大学学报(自然科学版), 2018, 46(2): 208-214.
- Zhang Lanfang, Zhao Kun. Short-term traffic flow risk prediction of expressway considering truck factors[J]. Journal of Tongji University(Natural Science Edition), 2018, 46(2): 208-214.
- [9] 戢晓峰, 戈艺澄, 陈方. 基于公路交通流大数据的节假日旅游流时空分异特征——以云南省 2017 年 7 个节假日为例[J]. 旅游学刊, 2019, 34(6): 37-47.
- Ji Xiaofeng, Ge Yicheng, Chen Fang. Spatial and temporal differentiation characteristics of holiday tourism flow based on highway traffic flow big data: A case study of seven holidays in 2017 in Yunnan Province[J]. Tourism Tribune, 2019, 34 (6): 37-47.
- [10] Li W, Hu J, Chen B H. A deep quasi-linear kernel composition method for support vector machines[C]//Proceedings of the International Joint Conference on Neural Networks. Vancouver, Canada: Institute of Electrical and Electronics Engineers Inc, 2016: 1639-1645.