

基于 KNN-LSTM 的短时交通流预测

罗向龙^{1,2}, 李丹阳¹, 杨 或¹, 张生瑞²

(1. 长安大学信息工程学院, 西安 710064; 2. 长安大学公路学院, 西安 710064)

摘要: 针对现有预测模型无法在交通大数据中提取交通流序列的内部规律,且未能充分利用交通流的时空相关性以实现高精度预测的问题,提出了一种基于 K -最近邻(K -nearest neighbor, KNN)与长短时记忆(long short term memory, LSTM)网络模型相结合的短时交通流预测模型. 采用 KNN 算法选择路网中与预测站点时空相关的检测站,以选择的检测站的交通流序列构造数据集,将其输入 LSTM 模型中进行训练及测试,并通过美国交通研究数据实验室的真实交通数据对提出的模型进行验证. 结果表明:与现有的交通预测模型相比,该方法能更好地提取交通流序列的时空特性,预测准确率平均可提高 12.28%,可为交通诱导与控制提供必要的依据.

关键词: 智能交通; 交通流预测; K -最近邻(KNN); 深度学习; 长短时记忆(LSTM)网络

中图分类号: U 491.1

文献标志码: A

文章编号: 0254-0037(2018)12-1521-07

doi: 10.11936/bjtxb2018030029

Short-term Traffic Flow Prediction Based on KNN-LSTM

LUO Xianglong^{1,2}, LI Danyang¹, YANG Yu¹, ZHANG Shengrui²

(1. School of Information Engineering, Chang'an University, Xi'an 710064, China;

2. College of Highway, Chang'an University, Xi'an 710064, China)

Abstract: To solve the problem that existing prediction models cannot extract the internal rules of the traffic flow in traffic big data and fail to make full use of spatiotemporal correlation characteristics to achieve high accurate prediction, a short-term traffic flow prediction model was proposed based on K -nearest neighbor (KNN) and long short term memory (LSTM). The KNN algorithm was used to select the stations that were related to the test station in the road network. The traffic flow data in selected stations were used as the training and testing datasets for the LSTM model. The proposed model was verified by real traffic data from the Transportation Research Data Lab in USA. Results show that the proposed method can better extract the spatiotemporal characteristics of traffic flow sequences, and the prediction accuracy can be improved by 12.28% on average compared with the existing prediction model, which can provide the necessary basis for traffic guidance and control.

Key words: intelligent transportation; traffic flow prediction; K -nearest neighbor (KNN); deep learning; long short term memory (LSTM) network

智能运输系统是全球公认的提高道路安全、缓解交通拥堵、减少交通污染、缩短出行时间、提高

道路通行效率的有效途径. 实时、准确的交通流预测更是交通诱导、出行路线规划等的前提和基础,也

收稿日期: 2018-03-26

基金项目: 国家自然科学基金资助项目(5157081053); 云南省交通运输厅科技计划资助项目(2014(A)29); 长安大学研究生科研创新实践项目(2018098)

作者简介: 罗向龙(1978—), 男, 副教授, 主要从事交通信息处理、机器学习方面的研究, E-mail: xlluo@chd.edu.cn

是智能运输系统的关键技术之一,因此,短时交通流预测长期以来成为智能交通领域关注和研究的热点。

现有的短时交通流预测方法主要分为参数模型、非参数模型、混合模型3类。其中参数模型以自回归滑动平均 (autoregressive integrated moving average, ARIMA)^[1]模型及其改进模型——季节性自回归滑动平均 (seasonal autoregressive integrated moving average, SARIMA)模型^[2]为代表。参数模型是一种基于统计分析的预测方法,其结构简单,计算方便,但最大的缺点是受交通流的波动性影响较大,且对具有较强随机性的非线性、非平稳数据预测效果不佳。为弥补这些不足,在分析交通流序列非线性特性的基础上,提出了诸如非参数回归^[3]、小波理论^[4]等非参数模型,此类模型对复杂变化的交通时间序列具有较好的适用性,但同样存在模型结构复杂、计算量较大、模型参数难以确定等不足。为了提高预测精度,提出了许多将多种模型相组合的混合预测模型。Li等^[5]提出了一种基于支持向量回归 (support vector regression, SVR)和ARIMA的混合模型,通过提取交通流特征进行预测;谭满春等^[6]提出了ARIMA与人工神经网络的组合模型;Hu等^[7]提出了一种粒子群优化 (particle swarm optimization, PSO)和SVR相融合的预测模型,采用PSO优化SVR参数降低噪声对预测性能的影响;Cong等^[8]提出一种基于果蝇优化和SVR的预测模型;刘钊等^[9]提出了K-最近邻 (K-nearest neighbor, KNN)与SVR组合的预测模型,同时考虑预测路段与其近邻路段的历史交通流量;Chan等^[10]提出了指数平滑法和LM (Levenberg-Marquardt)相融合的神经网络模型进行交通流预测;陈小波等^[11]提出了基于遗传算法 (genetic algorithm, GA)和最小均方SVR (least squares SVR, LSSVR)模型的路网短时流量预测。混合模型结合了不同模型的优点,但预测性能受组合方式影响较大。近年来,随着人工智能理论的逐渐成熟,深度学习已作为机器学习的第二次浪潮,广泛应用于图像分类^[12]、语音识别^[13]、轨迹追踪^[14]等领域。目前,国内外学者也逐渐开始将深度学习应用于交通流预测,并取得了一定的成果。Huang等^[15]以深度信念网络 (deep belief network, DBN)为底层,多任务回归层为顶层进行短时交通流预测;Li等^[16]首次采用堆叠式自编码器 (stacked autoencoder, SAE)来逐层学习交通流特征,这些方

法均验证了深度学习在交通流预测方面的可行性,但未能充分利用交通流的时空相关性;罗向龙等^[17]提出了一种基于深度学习的短时交通流预测方法,用DBN进行交通流特征学习,在网络顶层连接SVR模型进行流量预测;Ma等^[18]提出了一种限制玻尔兹曼机 (restricted Boltzmann machine, RBM)与循环神经网络 (recurrent neural network, RNN)相融合的预测模型,并将其应用于大规模的路网交通拥堵预测,虽考虑了时空相关性,但由于梯度消失和梯度爆炸问题的存在,无法处理展开过长的时间序列;Shao等^[19]采用长短时记忆 (long short term memory, LSTM)模型进行交通流预测,克服了循环神经网络存在的问题,但模型仅包含一个隐层,未能充分发挥深度学习模型的优势。

本文在结合交通流时空特性的基础上,提出了一种基于KNN-LSTM的短时交通流预测方法。采用KNN算法对预测目标站点所在区域的路网进行空间相关性筛选,通过设置不同的阈值,筛选出与目标站点相关的K个检测站。将筛选出的K个检测站数据输入LSTM模型进行交通流预测,以误差最小时对应的K值的预测结果作为最终的预测流量。真实的交通流数据测试结果表明,与现有的预测模型相比,本文提出的方法预测误差更低、准确性更高,是一种合理、有效的短时交通流预测模型。

1 深度学习

深度学习是一种训练深层神经网络的机器学习算法,它的本质是通过构建包含多个隐层的机器学习模型以及通过大量的训练数据来进行特征学习,从而最终提高分类或预测的准确性,即通过各种深度模型来进行特征学习。RNN及LSTM由于其独特的模型结构优势,被广泛应用于处理时间序列。

1.1 循环神经网络

RNN即在前馈神经网络中增加了反馈连接,如图1所示。传统模型在分析数据时无法有效利用过去时刻的依赖关系,而RNN由于在隐藏层增加了反馈连接,当前时刻隐藏层的输入是由当前时刻的输入和前一时刻隐藏层输出共同决定的,故可产生对过去数据的记忆状态,并建立不同时段数据之间的依赖关系,从而可以很好地处理时间序列。但它的不足之处在于:若序列的展开时间过长,则由于梯度消失或梯度爆炸问题的存在,无

法实现准确预测. 为了克服这一难题, 实现对长时间序列的有效处理, 提出了它的改进模型——长短时记忆网络.




图 1 循环神经网络结构

Fig. 1 Structure of RNN

1.2 长短时记忆模型

LSTM 模型是 RNN 的一种改进模型, 如图 2 所示, 它的改进之处在于用记忆块取代传统的隐含节点, 使梯度在训练展开比较长时不消失或爆炸, 从而解决了 RNN 无法处理过长时间序列的难题. 核心部分为记忆块, 由输入门、遗忘门、输出门组成, 结构如图 3 所示. 一个记忆块在 t 时刻的计算过程如下:

$$\tilde{c}_t = \tanh(\mathbf{w}_{xc} \mathbf{x}_t + \mathbf{w}_{ch} \mathbf{h}_{t-1} + \mathbf{b}_c) \quad (1)$$

$$\mathbf{i}_t = \sigma(\mathbf{w}_{xi} \mathbf{x}_t + \mathbf{w}_{hi} \mathbf{h}_{t-1} + \mathbf{w}_{ci} \mathbf{c}_{t-1} + \mathbf{b}_i) \quad (2)$$

$$\mathbf{f}_t = \sigma(\mathbf{w}_{xf} \mathbf{x}_t + \mathbf{w}_{hf} \mathbf{h}_{t-1} + \mathbf{w}_{cf} \mathbf{c}_{t-1} + \mathbf{b}_f) \quad (3)$$

$$\mathbf{o}_t = \sigma(\mathbf{w}_{xo} \mathbf{x}_t + \mathbf{w}_{ho} \mathbf{h}_{t-1} + \mathbf{w}_{co} \mathbf{c}_t + \mathbf{b}_o) \quad (4)$$

$$\mathbf{c}_t = \mathbf{c}_{t-1} \circ \mathbf{f}_t + \mathbf{i}_t \circ \tilde{\mathbf{c}}_t \quad (5)$$

$$\mathbf{h}_t = \mathbf{o}_t \circ \tanh \mathbf{c}_t \quad (6)$$

式中: \tilde{c}_t 表示 t 时刻记忆细胞的更新状态; $\mathbf{i}_t, \mathbf{f}_t, \mathbf{o}_t, \mathbf{c}_t, \mathbf{h}_t$ 分别表示输入门、遗忘门、输出门、记忆细胞以及隐层在 t 时刻的输出; \mathbf{x}_t 表示 t 时刻的输入; $\mathbf{h}_{t-1}, \mathbf{c}_{t-1}$ 分别表示隐层及记忆细胞在 $t-1$ 时刻的输出; $\mathbf{w}_{xc}, \mathbf{w}_{ch}$ 分别表示记忆细胞与输入 \mathbf{x}_t 以及隐层的权值矩阵; $\mathbf{w}_{xi}, \mathbf{w}_{hi}, \mathbf{w}_{ci}$ 分别为输入门与 \mathbf{x}_t 、隐层、记忆细胞的权值; $\mathbf{w}_{xf}, \mathbf{w}_{hf}, \mathbf{w}_{cf}$ 分别为遗忘门与 \mathbf{x}_t 、隐层、




图 2 LSTM 模型结构

Fig. 2 Structure of LSTM model

记忆细胞的权值; $\mathbf{w}_{xo}, \mathbf{w}_{ho}, \mathbf{w}_{co}$ 分别为输出门与 \mathbf{x}_t 、隐层、记忆细胞的权值; $\mathbf{b}_c, \mathbf{b}_i, \mathbf{b}_f, \mathbf{b}_o$ 均表示偏置项; $\sigma(\cdot)$ 及 $\tanh(\cdot)$ 为激活函数; “ \circ ” 表示阿达马积, 即逐点乘.

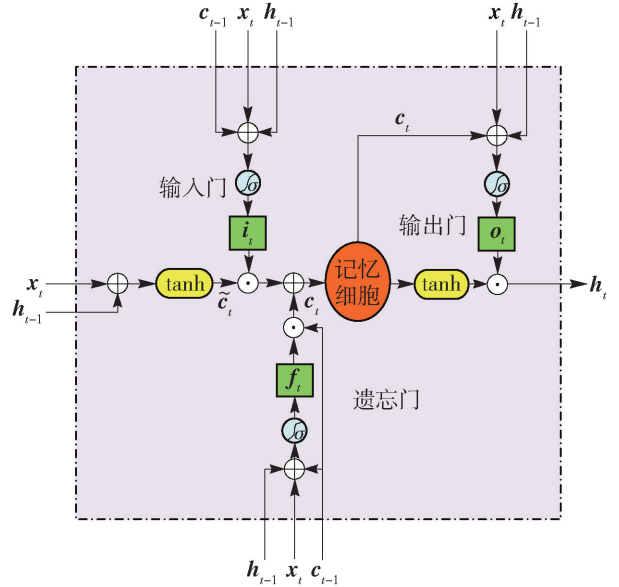


图 3 LSTM 记忆块结构

Fig. 3 Structure of LSTM memory block

2 KNN 算法

KNN 算法是一种基于回归和分类问题的算法. 该算法由于实现简单且训练速度快, 引起了人们的关注, 其核心思想是测量不同特征值之间的距离, 常用的测量距离的方法包括欧式距离、马氏距离、曼哈顿距离等测量方法. 其中欧式距离通过计算不同维度的坐标值差值的平方来评价 2 个点之间的距离, 它考虑到了微小时间段内不同时间序列的相似性程度, 适合随机序列的相似性判断. 结合交通流序列的特点, 本文采用欧式距离来衡量目标站与附近站之间的相关程度, 从而揭示路网中交通流的空间相关性, 具体计算方法为

$$d_i = \| \mathbf{X}_0 - \mathbf{X}_i \|_2 = \sqrt{\sum_j (x_0(j) - x_i(j))^2} \quad (7)$$

式中: \mathbf{X}_0 为目标检测站的交通流量; \mathbf{X}_i 为路网中第 i 个检测站的交通流量.

3 KNN-LSTM 短时交通流预测模型

假设一个给定的路网区域, 该区域中共包含 M 个断面检测站, 则定义路网第 d 天的交通流量数据矩阵 \mathbf{S}^d 为

$$\mathbf{S}^d = \begin{bmatrix} \mathbf{X}_1^d \\ \mathbf{X}_2^d \\ \vdots \\ \mathbf{X}_o^d \\ \mathbf{X}_i^d \\ \vdots \\ \mathbf{X}_M^d \end{bmatrix} = \begin{bmatrix} \mathbf{X}_{c1}^d \\ \mathbf{X}_{c2}^d \\ \vdots \\ \mathbf{X}_o^d \\ \mathbf{X}_{ci}^d \\ \vdots \\ \mathbf{X}_{cK}^d \end{bmatrix} =$$

$$\begin{bmatrix} x_1^d(1) & x_1^d(2) & \cdots & x_1^d(j) & \cdots & x_1^d(n) \\ x_2^d(1) & x_2^d(2) & \cdots & x_2^d(j) & \cdots & x_2^d(n) \\ \vdots & \vdots & & \vdots & & \vdots \\ x_o^d(1) & x_o^d(2) & \cdots & x_o^d(j) & \cdots & x_o^d(n) \\ x_i^d(1) & x_i^d(2) & \cdots & x_i^d(j) & \cdots & x_i^d(n) \\ \vdots & \vdots & & \vdots & & \vdots \\ x_M^d(1) & x_M^d(2) & \cdots & x_M^d(j) & \cdots & x_M^d(n) \end{bmatrix} \quad (8)$$

$$\begin{bmatrix} x_{c1}^d(1) & x_{c1}^d(2) & \cdots & x_{c1}^d(j) & \cdots & x_{c1}^d(n) \\ x_{c2}^d(1) & x_{c2}^d(2) & \cdots & x_{c2}^d(j) & \cdots & x_{c2}^d(n) \\ \vdots & \vdots & & \vdots & & \vdots \\ x_o^d(1) & x_o^d(2) & \cdots & x_o^d(j) & \cdots & x_o^d(n) \\ x_{ci}^d(1) & x_{ci}^d(2) & \cdots & x_{ci}^d(j) & \cdots & x_{ci}^d(n) \\ \vdots & \vdots & & \vdots & & \vdots \\ x_{cK}^d(1) & x_{cK}^d(2) & \cdots & x_{cK}^d(j) & \cdots & x_{cK}^d(n) \end{bmatrix} \quad (11)$$

式中: \mathbf{X}_o^d 为目标检测站第 d 天的流量; \mathbf{X}_i^d 为第 i 个检测站第 d 天的流量; $x_o^d(j)$ 为目标检测站第 d 天 j 时刻的流量; $x_i^d(j)$ 为第 i 个检测站第 d 天 j 时刻的流量; n 为日交通流量序列的样本个数。

预测模型以每个检测站连续 D 天的交通流量作为测试数据,则路网 D 天的交通流量数据矩阵 \mathbf{S} 定义为

$$\mathbf{S} = [\mathbf{S}^1 \quad \mathbf{S}^2 \quad \cdots \quad \mathbf{S}^d \quad \cdots \quad \mathbf{S}^D]^T \quad (9)$$

对路网数据矩阵 \mathbf{S} ,采用KNN算法对预测目标站点所在区域的路网进行空间相关性筛选,通过设置不同的阈值,筛选出与目标站点相关的 K 个检测站。将筛选出的 K 个检测站数据输入LSTM网络模型进行交通流预测,并将误差最小时的结果作为最终的交通流量预测值。具体算法可描述如下。

1) 对路网矩阵 \mathbf{S} 中每个检测站前 $D-1$ 天的流量数据按

$$\bar{X}_i = \frac{1}{D-1} \sum_{d=1}^{D-1} \mathbf{X}_i^d \quad (10)$$

求均值,得到每个检测站的流量均值。

2) 按式(7)分别计算第 i 个检测站的流量均值与目标检测站流量均值的欧式距离 d_i 。

3) 按距离递增顺序对 d_i 进行排序。

4) 令 $K=1$ 。

5) 选取 d_i 中与前 K 个距离对应的检测站数据,构造空间筛选后路网第 d 天的交通流矩阵 \mathbf{S}_c^d 以及路网第 D 天的交通流矩阵 \mathbf{S}_c ,其定义为

$$\mathbf{S}_c = [\mathbf{S}_c^1 \quad \mathbf{S}_c^2 \quad \cdots \quad \mathbf{S}_c^d \quad \cdots \quad \mathbf{S}_c^D]^T \quad (12)$$

式中: \mathbf{X}_{ci}^d 为空间筛选后第 i 个检测站第 d 天的流量; $x_{ci}^d(j)$ 为空间筛选后第 i 个检测站第 d 天 j 时刻的流量。

6) 选取筛选后的路网矩阵 \mathbf{S}_c 中前 $D-1$ 天数据为训练集,预测目标检测站第 D 天的交通流量预测值

$$\hat{X}_o^D = \Phi([\mathbf{S}_c^1 \quad \mathbf{S}_c^2 \quad \cdots \quad \mathbf{S}_c^d \quad \cdots \quad \mathbf{S}_c^{D-1}]^T) \quad (13)$$

式中 Φ 表示预测模型,本文中选择的是LSTM模型。

7) 令 $K=K+1$,循环5)和6),直到 $K>M$ 时停止迭代。

8) 选取 K 值预测误差最小时对应的预测结果为最终预测结果。

具体的预测流程图如图4所示。

4 实例分析

4.1 数据来源

为了评估本文方法的有效性,以美国交通研究数据实验室(Transportation Research Data Lab, TRDL)提供的高速公路交通数据进行算法测试。该数据包含4500个检测站以30s为周期对路网中多个路段实时采集的交通流、占有率和速度。文中以I394、I494、US169及TH100四条高速公路组成的区域作为研究对象,其中共包含36个断面检测站。各检测站的分布及ID如图5所示,其中S339为预测的目标站点。以2015年3月3日到2015年4月28日的交通流量作为实验数据,并将30s数据求和处

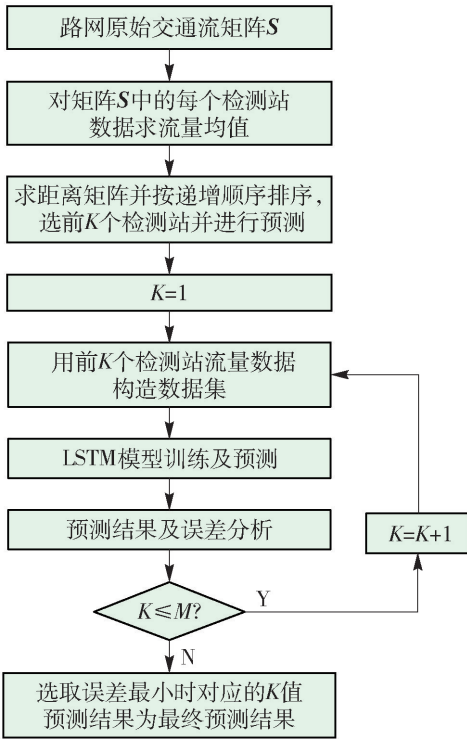


图 4 预测模型流程

Fig. 4 Flowchart of the prediction model

理成 5 min 间隔, 即日交通流量序列的样本个数 $n = 288$ 。以前 56 天的数据作为训练数据, 以 4 月 28 日的数据作为测试数据。

4.2 误差评价指标

为了评价预测结果的性能, 本文分别以均方误差 (mean square error, MSE) 及准确率 (accuracy, ACC) 作为评价指标, 具体定义如下:

$$MSE = \frac{1}{N} \sqrt{\sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (14)$$

$$ACC = \left(1 - \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{y}_i - y_i}{y_i} \right| \right) \times 100\% \quad (15)$$

式中: y_i 为交通流量的真实值; \hat{y}_i 为预测结果; N 为预测样本个数。

4.3 实验结果及分析

经多次实验后, 本文将所使用的 LSTM 模型层数设置为 4 层, 包括输入层、两层隐藏层以及输出层。按照图 4 所示的流程进行预测, 站点 S339 在 4 月 28 日的交通流量预测值及真实值如图 6 所示。图中绿色实线为真实流量, 红色虚线为本文方法的预测值, 此时 KNN 选择的与时空相关的检测站个数为 9, 即 $K=9$ 。从图 6 中可以看出, 预测值与真实值吻合度很好, 能很好地反映交通流随时间的变化特征, 表明本文所提出的预测模型在实际交通流量预测中具有可行性。

为了评价 KNN-LSTM 模型的预测性能, 本文分别计算了预测结果的 MSE 及 ACC, 并与 ARIMA、SVR、DBN-SVR 及 LSTM 模型的预测结果进行对比, 结果如表 1 所示。可以看出, 提出的 KNN-LSTM 模型具有最佳的预测性能, 其预测准确率达到 94.59%, 比 ARIMA、SVR 及 DBN-SVR 模型的预测准确率分别提高了 33.50%、6.42% 和 4.99%。同样与未考虑空间相关性的 LSTM 模型相比, 其预测精度也提高了 4.20%。表明本文所提出的基于时空相关的 KNN-LSTM 模型具有良好的预测性能, 是

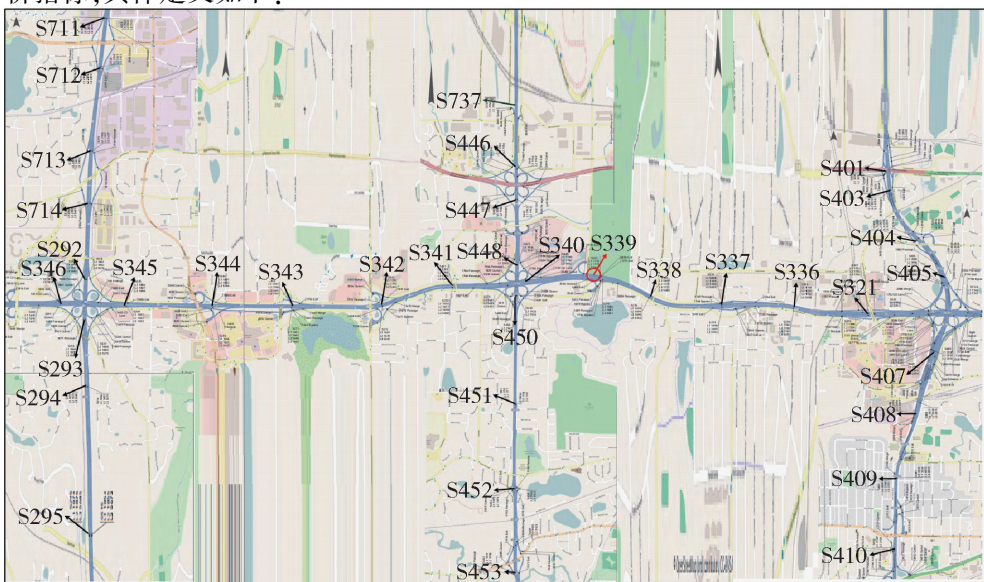


图 5 实验路网的检测站分布和 ID

Fig. 5 Detector locations and ID in experimental road network




图6 预测结果和真实值


Fig. 6 Predicted and real traffic flow

一种有效的短时交通流预测模型。

为了提高预测精度,充分利用交通流的时空相关性,本文采用KNN进行空间相关性的筛选。但对于KNN算法,不同的 K 值,即选取与目标站空间

表2 不同 K 值筛选出的检测站IDTable 2 Selected detector ID for different K values

K 的选取	选择的检测站 ID									
$K=1$	S339									
$K=2$	S339,	S340								
$K=3$	S339,	S340,	S321							
$K=4$	S339,	S340,	S321,	S342						
$K=5$	S339,	S340,	S321,	S342,	S341					
$K=6$	S339,	S340,	S321,	S342,	S341,	S344				
$K=7$	S339,	S340,	S321,	S342,	S341,	S344,	S338			
$K=8$	S339,	S340,	S321,	S342,	S341,	S344,	S338,	S336		
$K=9$	S339,	S340,	S321,	S342,	S341,	S344,	S338,	S336,	S337	
$K=10$	S339,	S340,	S321,	S342,	S341,	S344,	S338,	S336,	S337,	S346

图7 不同 K 值预测的MSEFig. 7 MSE predicted by different K values

从表2和图7可以看出, $K=9$ 时,预测的MSE最小。此时选出的空间相关的检测站编号分别为:S339、S340、S321、S342、S341、S344、S338、S336和S337。从图5中各检测站的位置可知,与S339相关性最大的检测站均位于其上下游位置,即路网中某

表1 不同模型预测性能

Table 1 Prediction performances of different models

预测模型	评价指标	
	MSE	ACC/%
ARIMA	1.513 4	61.09
SVR	0.326 6	88.17
DBN-SVR	0.305 3	89.60
LSTM	0.126 2	90.39
KNN-LSTM	0.098 7	94.59

相关站点数的多少,直接影响预测的性能。表2给出了 K 取不同值时,与目标站最相关的检测站ID。随着 K 值的增加,所选的检测站与目标站的相关度降低,因此,表2中只列出 K 值较小时的部分结果,图7给出了不同 K 值时的预测误差。

个断面的流量受其上下游位置的流量影响较大,这与实际情况比较吻合。

5 结论

1) 考虑交通流的时空特性,提出了一种基于KNN-LSTM的短时交通流预测模型。美国交通研究数据实验室提供的实测数据测试结果表明,与ARIMA、SVR、DBN-SVR及LSTM模型对比,本文提出的模型是一种性能更好的短时交通流预测方法。

2) 本文方法综合考虑了路网中交通流的时空相关性;采用的预测模型为LSTM模型,该模型由于其“记忆块”的独特功能,可产生对过去状态的记忆,充分利用了交通流序列的时间依赖关系;提出的模型预测误差更小,平均预测的精度提高了12.28%。

参考文献:

- [1] VOORT M V D, DOUGHERTY M, WATSON S. Combining Kohonen maps with ARIMA time series models to forecast traffic flow [J]. *Transportation Research Part C: Emerging Technologies*, 1996, 4(5): 307-318.
- [2] WILLIAMS B M, HOEL L A. Modeling and forecasting vehicular traffic flow as a seasonal ARIMA process: theoretical basis and empirical results [J]. *Journal of Transportation Engineering*, 2003, 129(6): 664-672.
- [3] 孙棣华, 李超, 廖孝勇. 高速公路短时交通流量预测的改进非参数回归算法[J]. *公路交通科技*, 2013, 30(11): 112-118.
SUN D H, LI C, LIAO X Y. Study on short-term forecasting of highway traffic flow using nonparametric regression [J]. *Journal of Highway and Transportation Research and Development*, 2013, 30(11): 112-118. (in Chinese)
- [4] YU W X, SU J, ZHANG W C. Research on short-term traffic flow prediction based on wavelet de-noising preprocessing [C]// 2013 Ninth International Conference on Natural Computation. Piscataway: IEEE, 2013: 252-256.
- [5] LI L C, HE S L, ZHANG J, et al. Short-term highway traffic flow prediction based on a hybrid strategy considering temporal-spatial information [J]. *Journal of Advanced Transportation*, 2016, 50(8): 2029-2040.
- [6] 谭满春, 冯萃斌, 徐建闽. 基于 ARIMA 与人工神经网络组合模型的交通流预测[J]. *中国公路学报*, 2007, 20(4): 118-121.
TAN M C, FENG L B, XU J M. Traffic flow prediction based on hybrid ARIMA and ANN model [J]. *China Journal of Highway and Transport*, 2007, 20(4): 118-121. (in Chinese)
- [7] HU W B, YAN L P, LIU K Z, et al. A short-term traffic flow forecasting method based on the hybrid PSO-SVR[J]. *Neural Processing Letters*, 2016, 43(1): 155-172.
- [8] CONG Y L, WANG J W, LI X L. Traffic flow forecasting by a least squares support vector machine with a fruit fly optimization algorithm [J]. *Procedia Engineering*, 2016, 137: 59-68.
- [9] 刘钊, 杜威, 闫冬梅, 等. 基于 K 近邻算法和支持向量回归组合的短时交通流预测[J]. *公路交通科技*, 2017, 34(5): 122-128.
LIU Z, DU W, YAN D M, et al. Short-term traffic flow forecast based on combination of K nearest neighbor algorithm and support vector regression [J]. *Journal of Highway and Transportation Research and Development*, 2017, 34(5): 122-128. (in Chinese)
- [10] CHAN K Y, DILLON T S, SINGH J, et al. Neural-network-based models for short-term traffic flow forecasting using a hybrid exponential smoothing and Levenberg-Marquardt algorithm [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2012, 13(2): 644-654.
- [11] 陈小波, 刘祥, 韦中杰, 等. 基于 GA-LSSVR 模型的路网短时交通流预测研究[J]. *交通运输系统工程与信息*, 2017, 17(1): 60-66.
CHEN X B, LIU X, WEI Z J, et al. Short-term traffic flow forecasting of road network based on GA-LSSVR model [J]. *Journal of Transportation Systems Engineering and Information Technology*, 2017, 17(1): 60-66. (in Chinese)
- [12] GRAVES A, LIWICKI M, FERNÁNDEZ S, et al. A novel connectionist system for unconstrained handwriting recognition [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2009, 31(5): 855-868.
- [13] HINTON G, DENG L, YU D, et al. Deep neural networks for acoustic modeling in speech recognition: the shared views of four research groups [J]. *IEEE Signal Processing Magazine*, 2012, 29(6): 82-97.
- [14] WANG L, LEI Z, ZHANG Y. Trajectory predictor by using recurrent neural networks in visual tracking [J]. *IEEE Trans Cybern*, 2017, 47(10): 3172-3183.
- [15] HUANG W H, SONG G J, HONG H K, et al. Deep architecture for traffic flow prediction: deep belief networks with multitask learning [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2014, 15(5): 2191-2201.
- [16] LÜ Y S, DUAN Y J, KANG W W, et al. Traffic flow prediction with big data: a deep learning approach [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2015, 16(2): 865-873.
- [17] 罗向龙, 焦琴琴, 牛力瑶, 等. 基于深度学习的短时交通流预测[J]. *计算机应用研究*, 2017, 34(1): 91-93.
LUO X L, JIAO Q Q, NIU L Y, et al. Short-term traffic flow prediction based on deep learning [J]. *Application Research of Computers*, 2017, 34(1): 91-93. (in Chinese)
- [18] MA X L, YU H Y, WANG Y P, et al. Large-scale transportation network congestion evolution prediction using deep learning theory [J]. *Plos One*, 2015, 10(3): e0119044.
- [19] SHAO H X, SOONG B H. Traffic flow prediction with long short-term memory networks (LSTMs) [C] // Proceedings of 2016 IEEE Region 10 Conference. Piscataway: IEEE, 2016: 2986-2989.