

一种考虑时空关联的深度学习短时交通流预测方法

张阳¹, 胡月¹, 辛东嵘²

(1. 福建工程学院交通运输学院, 福建 福州 350118;

2. 福建工程学院土木工程学院, 福建 福州 350118)

摘要: 空间关联特性的关联因素过于复杂且难以量化等问题导致短时交通流预测过于依赖时间关联特性。针对这一问题, 提出一种考虑时空关联的深度学习短时交通流预测方法。首先, 通过构建同时考虑距离、车流流量相似性和车流速度相似性的空间关联性度量函数, 量化目标路段与周边关联道路间的空间关联性。然后, 构建内嵌长短时记忆神经元的卷积神经网络模型, 利用长短时记忆神经元提取数据间的时间关联性, 利用空间关联性度量值及交通数据的卷积传输提取数据间的空间关联性, 以实现同时考虑时空关联性的交通流预测。实验结果表明, 提出的方法能适应工作日和周末等不同交通流特性条件下的短时预测, 且与经典方法相比, 预测精度更优, 在工作日和周末的预测偏差分别为 10.45% 和 12.35%。

关键词: 深度学习; 智能交通; 交通预测; 长短时记忆神经网络; 卷积神经网络

中图分类号: TP274.2

文献标识码: A

doi: 10.11959/j.issn.2096-6652.202117

A deep learning short-term traffic flow prediction method considering spatial-temporal association

ZHANG Yang¹, HU Yue¹, XIN Dongrong²

1. School of Transportation, Fujian University of Technology, Fuzhou 350118, China

2. School of Civil Engineering, Fujian University of Technology, Fuzhou 350118, China

Abstract: The short-term traffic flow prediction is too dependent on the time correlation characteristics, which due to the problems that the correlation factors of the spatial correlation characteristics are too complicated and difficult to quantify. In response to this defect, a deep learning short-term traffic flow prediction method considering spatial-temporal association was proposed. Firstly, by constructing a spatial association measurement function that simultaneously considers distance, flow similarity, and speed similarity, the spatial correlation between the target road segment and the surrounding associated road segments was quantified and predicted. Then, a convolutional neural network model with long short-term memory neurons embedded was constructed. The long short-term memory neurons were used to extract the temporal correlation characteristics between the data, and the spatial correlation metric and the convolution transmission of traffic data were used to extract the spatial correlation characteristics between the data, so as to realize the traffic flow prediction considering the spatial-temporal association. The experimental results show that the proposed method can adapt to short-term forecasting under different traffic flow characteristics such as weekdays and weekends, and the prediction accuracy is better than that of the classical methods. In weekdays and weekends, the forecast bias are 10.45% and 12.35% respectively.

Key words: deep learning, intelligent transportation, traffic prediction, long short-term memory neural network, convolutional neural network

收稿日期: 2021-02-02; 修回日期: 2021-03-02

通信作者: 辛东嵘, 174183983@qq.com

基金项目: 国家自然科学基金资助项目 (No.51678077); 福建省自然科学基金资助项目 (No.2019J01781, No.2020J05194); 福建省财政厅科技计划项目 (No.GY-Z21001)

Foundation Items: The National Natural Science Foundation of China (No.51678077), The Natural Science Foundation of Fujian Province (No.2019J01781, No.2020J05194), Fujian Finance Department Science Foundation (No.GY-Z21001)

1 引言

短时交通流预测是智能交通及大数据处理领域的热点研究问题之一。精确的短时交通流预测是实现高效智能交通诱导和交通管控的关键技术，是提高通行效率、缓解交通拥堵的重要环节。特别在雨雪天气、交通事故发生区域和交通高峰时期等交通极易发生拥堵的情况下，精确的短时交通流预测显得极为重要，不仅能为出行者选择最优路径提供判断依据，同时也能为管理者制定有效的控制措施提供强有力的数据支撑，从而实现缓解交通拥堵、保障交通安全和减少尾气排放等目标。

经典的短时交通流预测方法多关注交通流参数在时间上的关联性，然后利用此特点实现预测。比较有代表性的方法有时间序列法、卡尔曼滤波法、支持向量回归等^[1]。这类方法充分考虑了交通流历史数据与未来数据的时间关联，利用回归等方法实现短时预测。然而交通流复杂多变，特别是在恶劣天气和发生交通事故的条件下，交通流极易发生突变，使下一时刻的交通特性较上一时刻发生显著变化。时间关联性的突变导致预测发生较大偏差，使短时交通流预测发展达到瓶颈。目前，越来越多的学者试图用深度学习的方法来解决这一问题，通过构建层次更深、自学习能力更强的神经网络来适应交通流的复杂变化。比较具有代表性的有长短时记忆（long short-term memory, LSTM）^[2]、卷积神经网络（convolutional neural network, CNN）^[3]和深度信念网（deep belief net, DBN）^[4]等，其中 LSTM 拥有较好的时间特征学习能力，而 CNN 拥有较好的空间特征学习能力，这些方法大大推动了交通流预测技术的发展。然而，由于交通流受到诸多因素的影响，在时间上的变化规律复杂多变，仅靠单一的交通流时间特性很难实现更精准的短时交通流预测。而交通流除了在时间上有紧密的关联，在路网空间上的关联性也十分密切，同时考虑交通流的时空关联性能更好地捕捉交通流的变化规律，从而提升其预测精度^[5]。已有部分学者开展了同时考虑时空关联性的交通流预测研究，如 Sun B 等人^[6]提出了一种自调节的 K 近邻的时空交通流预测方法，Wu Y K 等人^[7]提出了一种混合式深度神经网络，同时提取交通流时空特性实现交通流预测，均取得了良好的预测效果。由于深度学习在捕捉深层次关系能力上的优势，近年来，利用深度

学习并考虑交通网络时空相关性进行交通预测也取得了一定的成果，如 Cui Z Y 等人^[8]提出了一种基于图卷积神经网络的深度学习框架，同时考虑路网时空特性实现交通流预测，Hao P 等人^[9]提出了一种考虑时空影响的深度学习算法实现枢纽站点的客流预测。然而，与时间关联性相比，交通流数据的空间关联性更复杂，精确度量其空间关联性以及在捕捉空间关联性的同时准确提取交通流数据的时间关联特性是该类方法成功的关键，也是需要进一步解决的难点问题^[10]。

为了解决上述问题，本文提出一种考虑时空关联的深度学习短时交通流预测方法。首先，通过提取路网范围中临近路段的距离、车流流量相似度及车流速度相似度，建立预测点与周围路段的空间关联性度量函数；其次，构建 CNN 预测框架模型，通过输入空间关联性度量值及相关路段历史流量数据，实现数据空间关联性的自学习；同时，为了增强该方法的交通流量时间关联性学习能力，对传统的 CNN 模型进行改进，考虑到 LSTM 具有优越的时间关联学习能力，将 LSTM 内嵌至 CNN 的神经元，提升算法的时间关联学习能力。该方法同时增强算法的时空关联处理能力，以期能够提升短时交通流预测性能^[9]。

2 空间关联性度量函数

城市道路短时交通流预测应根据交通流数据在时空上的演变规律进行科学预测。其中，预测节点与周围路段上交通特性的空间关联性较难获取和量化。为了解决这一问题，本文构建了一种可量化的空间关联性度量函数模型。根据预测节点与周围路段空间关联的实际影响因素，该函数模型同时考虑距离、车流流量相似度及车流速度相似度 3 个重要的关联条件，实现预测节点与周围路段上交通特性的空间关联量化。

预测的目标路段及周边的路网结构示意图如图 1 所示，道路 AB 为短时交通流预测的目标路段（以下简称目标路段），其他周边关联道路则是目标路段的空间关联道路。

目标路段的未来交通流量除了与自身流量的历史数据相关，还与其他周边关联道路的交通特性相关。设 S_n 为目标路段与第 n 条关联道路的空间距离，其计算方式为目标路段的中点与第 n 条关联道路中点间的最小可达距离。设 $X_0(t)$ 和 $X_n(t)$ 分别为目




图1 预测的目标路段及周边的路网结构示意图

标路段和周边关联道路在 $[t-T, t]$ 时段内的道路交通流量历史数据集, 则它们分别表示为:

$$X_0(t) = [x_0(t-T), x_0(t-T+1), \dots, x_0(t)] \quad (1)$$

$$X_n(t) = [x_n(t-T), x_n(t-T+1), \dots, x_n(t)], n=1, 2, \dots, N \quad (2)$$

其中, t 为道路交通流的起始时刻, T 为抽样历史数据的最长时间跨度, N 为周边关联道路的总条数。

利用欧氏距离来量化目标路段与周边关联道路的流量相似度 dq_n :

$$dq_n = \|X_0(t) - X_n(t)\|_2 = \sqrt{\sum_t (x_0(t) - x_n(t))^2} \quad (3)$$

根据式 (3) 可以计算目标路段与周边每条关联道路之间的流量相似度。

设 $V_0(t)$ 和 $V_n(t)$ 分别为目标路段和周边关联道路在 $[t-T, t]$ 时段内的道路交通流速度集, 则它们分别表示为:

$$V_0(t) = [v_0(t-T), v_0(t-T+1), \dots, v_0(t)] \quad (4)$$

$$V_n(t) = [v_n(t-T), v_n(t-T+1), \dots, v_n(t)], n=1, 2, \dots, N \quad (5)$$

考虑到与流量指标相比, 速度指标的获取会产生更大的实际偏差, 本文利用去噪效果更好的高斯权重欧氏距离来量化目标路段与周边关联道路的速度相似度 dv_n :

$$dv_n = \frac{\text{Cov}(V_0(t), V_n(t))}{\sqrt{DV_0(t)}\sqrt{DV_n(t)}} = \frac{\sum_{i=t-T}^t (v_0(i) - \bar{v})(v_n(i) - \bar{v}_n)}{\sqrt{\sum_{i=t-T}^t (v_0(i) - \bar{v})^2} \sqrt{\sum_{i=t-T}^t (v_n(i) - \bar{v}_n)^2}} \quad (6)$$

其中, $\bar{v}$ 和 $\bar{v}_n$ 分别表示 $[t-T, t]$ 时段内目标路段和周边关联道路的平均车流速度。

根据式 (6) 可以计算目标路段与周边每条关

联道路之间的速度相似度。则本文提出的空间关联性度量函数可表示为:

$$\text{corr}_n = \frac{\sum_{n=1}^N S_n dq_n dv_n}{S_n dq_n dv_n} \quad (7)$$

其中, corr_n 表示第 n 条关联道路与目标路段的空间关联性度量值, corr_n 的值越大, 空间关联度越高。

3 内嵌 LSTM 神经元的 CNN 短时交通流预测模型

CNN 卷积预测算法具有良好的空间特性提取性能^[11-12], 而 LSTM 拥有优越的时间特性分析和学习能力^[13-14]。本文在 CNN 卷积预测算法框架下, 将 LSTM 内嵌至 CNN 卷积隐层结构的神经元, 使其同时具备良好的时空特性学习能力。

3.1 内嵌 LSTM 神经元的 CNN 短时交通流预测模型构建

为了保证算法的空间特性学习能力, 模型采用 CNN 卷积模型框架, 该模型框架示意图如图 2 所示。将路网交通流流量信息及空间关联性度量信息作为输入信息, 通过卷积层、池化层、全连接层等信息传递, 提取数据的空间特征, 实现流量预测。




图2 CNN 卷积模型框架示意图

在短时交通流预测中, 预测数据与历史数据在时间上的联系非常紧密, 而传统的 CNN 卷积模型通过卷积运算能够较好地提取空间特性, 但是对时间特性的学习不敏感。针对这一缺陷, 本文将 LSTM 内嵌至 CNN 卷积隐层结构的神经元。LSTM 结构中包含了输入门、遗忘门和输出门^[2], 利用 LSTM 的输入门和记忆单元, 实现对输入数据时间特性的学习和提取, 通过遗忘门剔除无关数据, 通过输出门传递时间特征和关键信息。由于内嵌 LSTM 神经元是在 CNN 卷积模型框架下传递信息的, 而传统的 CNN 卷积模型各隐层之间是以卷积运算的形式来传递信息的, 因此内嵌 LSTM 神经元也需要以卷积和哈达玛积的模式在 CNN 卷积模型各层之间传递信息, 具体的信息传递计算式如下:

$$I^t = \sigma(W_{xi} * x^t + W_{hi} * h^{t-1} + W_{ci} \circ C^{t-1} + b_i) \quad (8)$$

$$F^t = \sigma(W_{xf} * x^t + W_{hf} * h^{t-1} + W_{cf} \circ C^{t-1} + b_f) \quad (9)$$

$$C^t = F^t \circ C^{t-1} + I^t \circ \tanh(W_{xc} * x^t + W_{hc} * h^{t-1} + b_c) \quad (10)$$

$$O^t = \sigma(W_{xo} * x^t + W_{ho} * h^{t-1} + W_{co} \circ C^t + b_o) \quad (11)$$

$$h^t = O^t \circ \tanh(C^t) \quad (12)$$

其中, I^t 、 F^t 、 C^t 和 O^t 分别表示输入门、遗忘门、记忆单元和输出门; σ 表示 Sigmoid 激励函数; W_{xi} 、 W_{hi} 和 W_{ci} 分别表示输入数据与输入门、输入门与隐层以及输入门与记忆单元之间传输数据的权重参数; x^t 为输入数据, h^{t-1} 为前一隐层结构的输出数据, C^{t-1} 为前一记忆单元的输出数据, b_i 为输入门偏移量; W_{xf} 、 W_{hf} 和 W_{cf} 分别表示输入数据与遗忘门、遗忘门与隐层以及遗忘门与记忆单元之间传输数据的权重参数, b_f 为遗忘门偏移量; W_{xc} 和 W_{hc} 分别表示输入数据与记忆单元、记忆单元与隐层之间传输数据的权重参数, b_c 为记忆单元偏移量; W_{xo} 、 W_{ho} 和 W_{co} 分别表示输入数据与输出门、隐层与输出门以及记忆单元与输出门之间传输数据的权重参数, b_o 为输出门偏移量; $\circ$ 为哈达玛积, $*$ 为卷积运算。

3.2 内嵌 LSTM 神经元的 CNN 短时交通流预测实现步骤

本文利用地感线圈、浮动车等采集所需的流量、速度等交通数据, 并对采集到的数据进行分析 and 预处理, 进而实现内嵌 LSTM 神经元的 CNN 短时交通流预测。该方法主要步骤如下。

步骤 1 采集短时交通流样本数据, 主要包括目标路段的历史交通流流量和速度参数、周边关联道路与目标路段的空间距离、周边关联道路的历史交通流流量和速度参数等交通数据。

步骤 2 根据式 (3) 计算目标路段与周边每条关联道路之间的流量相似度, 根据式 (6) 计算目标路段和周边每条关联道路之间的速度相似度, 根据式 (7) 计算目标路段与周边每条关联道路的空间关联度。

步骤 3 构建内嵌 LSTM 神经元的 CNN 短时交通流预测模型, 设置包括卷积层、池化层、全连接层等的显隐层结构, 各层神经元利用 LSTM 模型构建, 初步设定显隐层节点数、隐层层数等参数指标。

步骤 4 选取空间关联度、关联道路流量数据及目标路段流量数据为训练集和测试集。利用训练集训练预测模型, 根据式 (8)~式 (12) 实现数据信息时空特性的传递和学习, 输出短时交通流预测数据。

步骤 5 利用测试集测试训练好的预测模型, 根据测试结构微调模型参数指标, 进一步提高预测效果。

步骤 6 将预测结果与真实值进行对比, 检查预测精度是否达到预期目标, 如达标则输出预测结果, 未达标则返回步骤 3, 对模型结构参数指标进行重置, 观察预测输出值的变化, 直至预测精度达标。

4 实验结果与分析

4.1 研究范围和交通数据的采集及选取

本次实验研究范围为福州市中心城区, 道路网络由福新路、福新中路、五一北路、五一中路、国货西路、国货东路、连江北路、福马路和古田路等道路构成, 研究对象关联范围内的路网结构示意图如图 3 所示。本实验以福马路某断面为预测对象, 研究范围内的其他道路为其关联道路。




图3 研究对象关联范围内的路网结构示意图

依托福建省北斗导航与智慧交通协同创新中心科研平台提供的浮动车基础实验数据获取相关速度信息, 利用福州市公安局交通巡逻警察支队提供的路口地感线圈采集数据获取相关流量信息, 经分析和预处理得到 2019 年 11 月 4 日至 12 月 9 日共 36 天的实验研究范围内各道路流量和速度数据, 并将其作为实验样本, 样本采集间隔为 5 min。考虑到工作日的交通特性与周末的交通特性有一定的差异, 本文对工作日和周末分别进行短时交通流预测, 全

面验证算法性能。将前 34 天中的工作日和周末这两个时间段作为两个训练样本集, 结合该时间段内的空间关联度集、各道路流量和速度集分别训练相应的模型; 将 12 月 8 日(周末)和 12 月 9 日(周一)的福马路流量数据作为测试集, 测试算法的预测性能。

4.2 预测算法性能指标的选取

为了客观地评价算法的短时交通流预测性能, 本文选取较为通用的最大相对熵(max relative entropy, MRE)^[15]、平均绝对误差(mean absolute error, MAE)^[16]和均方根误差(root mean square error, RMSE)^[17]这 3 个指标来评价预测结果, 计算式分别为:

$$\text{MRE} = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \tilde{y}_i|}{y_i} \quad (13)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \tilde{y}_i| \quad (14)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2} \quad (15)$$


其中, i 表示样本的数量, y_i 表示交通流量的实际值, $\tilde{y}_i$ 表示短时交通流预测值。

4.3 评估度量空间关联性对预测性能的影响


为了评估本文使用的度量空间关联性方法对算法预测性能的影响, 将含有空间关联性指标输入数据的内嵌 LSTM 神经元的 CNN 短时交通流预测模型(以下简称 S-LSTM-CNN)与不含有空间关联性指标输入数据的内嵌 LSTM 神经元的 CNN 短时交通流预测模型(以下简称 LSTM-CNN)的预测性能进行对比, 根据性能指标对算法的有效性进行验证。

本文提出的短时交通流预测算法的主要参数选择如下。LSTM 神经元由 2 层隐层结构构成, 每层 300 个隐层单元。CNN 框架中共包含 4 层隐层结构, 每层的神经元数量分别为 100、200、300、400。离线训练相关模型, 并利用过去 1 h 的历史数据在线预测未来 15 min 的道路流量。分别对工作日和周末进行预测, 并与测试集中的真实值进行比较, 结果如图 4 所示, 具体指标见表 1 和表 2。

由图 4、表 1 和表 2 可以看出, 无论是工作日还是周末, S-LSTM-CNN 模型的预测效果均优于 LSTM-CNN, 可见本文使用的度量空间关联性方法可行、有效, 有利于提高预测精度。



(a) 工作日预测结果对比



(b) 周末预测结果对比

图 4 工作日及周末预测结果对比

表 1 工作日预测结果对比

评价指标	S-LSTM-CNN	LSTM-CNN
MAE	22.421	34.584
MRE	10.45%	14.85%
RMSE	32.435	37.488

表 2 周末预测结果对比

评价指标	S-LSTM-CNN	LSTM-CNN
MAE	24.362	37.578
MRE	12.35%	16.76%
RMSE	36.273 8	40.566

4.4 S-LSTM-CNN 预测性能与经典算法性能比较

将本文提出的 S-LSTM-CNN 与其他较为经典的改进的 LSTM (IWPA-LSTM)^[18]和改进的 DBN (DBN-SVR)^[19]的短时交通流预测效果进行比较, 利用性能指标对预测结果进行评估。所有算法均采用

用与第4.3节相同的参数指标和测试集,预测结果如图5所示,具体指标见表3和表4。

由图5和表3、表4可以看出,本文提出的S-LSTM-CNN模型在工作日和周末的预测效果均





图5 S-LSTM-CNN模型与经典深度学习模型预测结果比较

表3 工作日预测结果对比

评价指标	S-LSTM-CNN	IWPA-LSTM	DBN-SVR
MAE	22.421	28.031	35.062
MRE	10.45%	13.69%	15.81%
RMSE	32.435	37.023	41.238

表4 周末预测结果对比

评价指标	S-LSTM-CNN	IWPA-LSTM	DBN-SVR
MAE	24.362	32.372	39.891
MRE	12.35%	16.93%	20.45%
RMSE	36.273 8	46.129	52.431

优于其他两种经典的预测算法。可见,S-LSTM-CNN模型能够同时考虑空间关联性和交通流的时间关联性,因此预测精度要优于仅考虑了时间关联性的IWPA-LSTM和仅考虑空间数据维度的DBN-SVR。由此可见,在实际应用中,同时关注时空关联特性有利于提升算法的预测性能。同时,S-LSTM-CNN模型在工作日的预测结果优于周末,说明在训练数据更充足的条件下,该方法的预测效果更好。而从周末的预测结果可以看出,S-LSTM-CNN模型明显优于其他算法,说明在更少量的训练数据条件下,与经典算法相比,该方法的优势更突出,可以通过学习数据的时空特性取得更好的预测效果。

5 结束语

本文提出一种考虑时空关联的深度学习短时交通流预测方法,通过构建预测目标路段与周边关联道路的空间关联性度量函数,增强预测目标的空间关联特性的量化描述。同时,为了进一步提升对交通流数据时空关联特性的分析能力,提出一种内嵌LSTM神经元的CNN短时交通流预测模型,以预测目标路段和周边关联道路的空间关联度以及各自流量为输入值,通过深度学习找出数据的时空特性规律,从而实现短时交通流预测。利用实际交通数据进行验证得出,本文提出的短时交通流预测方法预测精度优于经典的IWPA-LSTM和DBN-SVR,具有较好的实用前景。

参考文献:

- [1] 张孜,黄钦炎,冯川.广州市城市智能交通大数据体系研究与实践[J].大数据,2019,5(4):113-120.
ZHANG Z, HUANG Q Y, FENG C. Research and practice on traffic big data application system of urban intelligent transportation in Guangzhou[J]. Big Data Research, 2019, 5(4): 113-120.
- [2] JONATHAN M, JOHN F, ROCCO Z. An evaluation of HTM and LSTM for short-term arterial traffic flow prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 20(5): 1847-1857.
- [3] 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 W H, DONG B T, WANG Z S. Short-term traffic flow prediction based on CNN-SVR hybrid deep learning model[J]. Journal of Transportation Systems Engineering and Information Technology, 2017, 17(5): 68-74.
- [4] ZHANG Y Y, HUANG G. Traffic flow prediction model based on deep belief network and genetic algorithm[J]. IET Intelligent Transport Systems, 2018, 12(6): 533-541.
- [5] 冯宁,郭晟楠,宋超,等.面向交通流量预测的多组件时空图卷积

- 网络[J]. 软件学报, 2019, 30(3): 759-769.
- FENG N, GUO S N, SONG C, et al. Multi-component spatial-temporal graph convolution networks for traffic flow forecasting[J]. Journal of Software, 2019, 30(3): 759-769.
- [6] SUN B, CHENG W, PRASHANT G, et al. Short-term traffic forecasting using self-adjusting k-nearest neighbours[J]. IET Intelligent Transport Systems, 2018, 12(1): 41-48.
- [7] WU Y K, TAN H C, QIN L Q, et al. A hybrid deep learning based traffic flow prediction method and its understanding[J]. Transportation Research Part C: Emerging Technologies, 2018: 166-180.
- [8] CUI Z Y, KE R M, WANG Y H. Traffic graph convolutional recurrent neural network: a deep learning framework for network-scale traffic learning and forecasting[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(11): 4883-4894.
- [9] HAO P, WANG H F, DU B W, et al. Spatial temporal incidence dynamic graph neural networks for traffic flow forecasting[J]. Information Sciences, 2020, 521: 277-290.
- [10] 陈汐, 王印海, 代壮, 等. 基于多源城市交通出行数据的定制公交需求辨识方法研究[J]. 大数据, 2020, 6(6): 105-118.
- CHEN X, WANG Y H, DAI Z, et al. Research on demand identification for customized bus based on multi-source mobility data[J]. Big Data Research, 2020, 6(6): 105-118.
- [11] HU Y C, LU X B. Learning spatial-temporal features for video copy detection by the combination of CNN and RNN[J]. Journal of Visual Communication and Image Representation, 2018, 12(6): 533-541.
- [12] 刘文华, 李滢东, 王涛, 等. 基于高维特征表示的交通场景识别[J]. 智能科学与技术学报, 2019, 1(4): 392-399.
- LIU W H, LI Y D, WANG T, et al. Transportation scene recognition based on high level feature representation[J]. Chinese Journal of Intelligent Science and Technology, 2019, 1(4): 392-399.
- [13] 杜圣东, 李天瑞, 杨燕, 等. 一种基于序列到序列时空注意力学习的交通流预测模型[J]. 计算机研究与发展, 2020, 57(8): 1715-1728.
- DU S D, LI T R, YANG Y, et al. A sequence-to-sequence spatial-temporal attention learning model for urban traffic flow prediction[J]. Journal of Computer Research and Development, 2020, 57(8): 1715-1728.
- [14] MA X L, TAO Z M, WANG Y H, et al. Long short-term memory neural network for traffic speed prediction using remote microwave sensor data[J]. Transportation Research Part C: Emerging Technologies, 2015, 54: 187-197.
- [15] ZHANG Y, XIN D R. Dynamic optimization long short-term memory model based on data preprocessing for short-term traffic flow prediction[J]. IEEE Access, 2020: 91510-91520.
- [16] 温惠英, 张东冉, 陆思园. GA-LSTM 模型在高速公路交通流预测中的应用[J]. 哈尔滨工业大学学报, 2019, 51(9): 81-87, 95.
- WEN H Y, ZHANG D R, LU S Y. Application of GA-LSTM model in highway traffic flow prediction[J]. Journal of Harbin Institute of Technology, 2019, 51(9): 81-87, 95.
- [17] ZHANG L Z, NAWAF R A, LUO G C, et al. A hybrid forecasting framework based on support vector regression with a modified genetic algorithm and a random forest for traffic flow prediction[J]. Tsinghua Science and Technology, 2018, 23(4): 479-492.
- [18] 张阳, 杨书敏, 辛东嵘. 改进小波包与长短时记忆组合模型的短时交通流预测[J]. 交通运输系统工程与信息, 2020, 20(2): 204-210.
- ZHANG Y, YANG S M, XIN D R. Short-term traffic flow forecast based on improved wavelet packet and long short-term memory combination model[J]. Journal of Transportation Systems Engineering and Information Technology, 2020, 20(2): 204-210.
- [19] 傅成红, 杨书敏, 张阳. 改进支持向量回归机的短时交通流预测[J]. 交通运输系统工程与信息, 2019, 19(4): 130-134, 148.
- FU C H, YANG S M, ZHANG Y. Promoted short-term traffic flow prediction model based on deep learning and support vector regression[J]. Journal of Transportation Systems Engineering and Information Technology, 2019, 19(4): 130-134, 148.

[作者简介]



张阳（1983—），男，博士，福建工程学院交通运输学院副教授，主要研究方向为智能交通信息处理、交通大数据处理、交通流预测。



胡月（1997—），女，福建工程学院交通运输学院硕士生，主要研究方向为交通运输规划与管理。



辛东嵘（1986—），女，博士，福建工程学院土木工程学院副教授，主要研究方向为人工智能、智能交通。