

文章编号:1672-3961(2025)03-0058-14

DOI:10.6040/j.issn.1672-3961.0.2024.082

基于 ETC 收费数据的高速公路交通流数据修复及实时预测

薛冰冰¹,王勇²,杨维浩¹,王川³,于迪¹,王旭^{1*}

(1.山东大学齐鲁交通学院,山东 济南 250002; 2.济南市交通工程质量与安全中心,山东 济南 250001; 3.山东高速集团有限公司,山东 济南 250098)

摘要:通过填补缺失数据提升交通流数据质量,对高速公路交通流数据进行准确实时预测,本研究首先采用低秩张量分解理论对缺失数据进行修复,利用基于注意力机制的卷积长短期记忆神经网络构建预测模型,并使用山东省高速公路收费系统实际交通流数据对本研究提出的方法进行验证。结果表明:通过对缺失数据进行分类识别,利用混淆矩阵确定识别缺失数据的阈值,引入三维张量模型采用低秩张量补全方法进行缺失数据修复,相较于拉格朗日插值法、KNN 以及 SVR 方法,本方法修复数据效果最优;本研究提出的交通流组合预测模型,相较于 SVR、CNN、LSTM 和 CNN-LSTM 四种预测方法,在不同路段、工作日和非工作日均具有更高的预测精度,流量预测的均方误差 M_{SE} 和平均绝对百分比误差 M_{APE} 分别下降 22.47% 和 8.41%,平均速度预测的 M_{SE} 和 M_{APE} 分别下降 42.83% 和 6.32%。本研究提出的模型为高速公路交通状态预测方法研究提供了新思路。

关键词:高速公路;交通数据修复;时空相关性;交通流参数预测;深度学习

中图分类号:U491.1+4 **文献标志码:**A

引用格式:薛冰冰,王勇,杨维浩,等. 基于 ETC 收费数据的高速公路交通流数据修复及实时预测[J]. 山东大学学报(工学版), 2025, 55(3): 58-71.

XUE Bingbing, WANG Yong, YANG Weihao, et al. Real-time expressway traffic data imputation and state prediction based on ETC system data[J]. Journal of Shandong University (Engineering Science), 2025, 55(3): 58-71.

Real-time expressway traffic data imputation and state prediction based on ETC system data

XUE Bingbing¹, WANG Yong², YANG Weihao¹, WANG Chuan³, YU Di¹, WANG Xu^{1*}

(1. School of Qilu Transportation, Shandong University, Jinan 250002, Shandong, China; 2. Jinan Transportation Engineering Quality and Safety Center, Jinan 250001, Shandong, China; 3. Shandong Hi-Speed Group Co., Ltd., Jinan 250098, Shandong, China)

Abstract: By imputing missing data to enhance the quality of traffic flow data, accurate real-time predictions for highway traffic flow can be achieved. This study adopted the low-rank tensor decomposition theory to repair the missing data and used the convolutional long and short term memory neural network based on the attention mechanism to build a prediction model. The actual traffic flow data of the Shandong expressway toll system were used to verify the method proposed in this study. The experimental results showed that: by classifying and identifying missing data, using the confusion matrix to determine the threshold of identifying missing data, introducing the three-dimensional tensor model, and using the low-rank tensor completion method to repair missing data, the data repair effect was the best compared with Lagrange interpolation, KNN, and SVR methods. Compared with SVR, CNN, LSTM, and CNN-LSTM, the combined traffic flow prediction model proposed in this study had higher prediction accuracy in

收稿日期:2024-04-19

基金项目:国家重点研发计划资助项目(2023YFB2603504);山东省重点研发计划资助项目(2020CXGC010117)

第一作者简介:薛冰冰(2000—),女,吉林梅河口人,硕士研究生,主要研究方向为智能交通系统、交通安全。

E-mail: xuebingbing0306@126.com

* 通信作者简介:王旭(1987—),女,山东济南人,副教授,博士生导师,博士,主要研究方向为智能交通系统、主动交通控制管理、道路交通安全、车路协同/车联网、交通大数据。E-mail: xuwang@sdu.edu.cn

different road sections, working days, and non-working days, and the M_{SE} and M_{APE} of traffic prediction decreased by 22.47% and 8.41%, respectively. The average speed forecast for M_{SE} and M_{APE} decreased by 42.83% and 6.32%, respectively. The proposed model provided new ideas for research on highway traffic state prediction methods.

Keywords: expressways; traffic data repair; spatiotemporal correlation; traffic flow parameter prediction; deep learning

0 引言

截至2022年底,全国高速公路通车里程达到17.7万km,位居全球第一^[1]。随着我国高速公路的快速发展,智慧高速公路建设随之得到了推动,智慧高速公路利用先进的交通数据分析方法,挖掘流量、密度、速度等典型表征参数的特征,通过多样化的管控手段提高交通系统的安全性和可持续性。近年来,ETC收费系统普及率大幅提升,通过对ETC收费系统采集到的收费数据进行分析处理,能够深入挖掘交通流信息,有利于制定高效合理的交通运营与管理决策。然而,高速公路收费系统数据上传存在延迟情况,即系统数据更新的速度可能比实际交通流变化的速度慢,数据缺失问题是ETC数据实时应用中不可避免的问题之一^[2]。收费数据延迟上传状况的存在会导致实时数据滞后于实际情况,从而影响交通流状态实时估计及预测效果。因此,充分利用现有高速公路信息化基础设施,针对ETC收费数据延迟问题需进行实时交通流数据的质量评估和缺失修复,以准确评估及预测高速公路运行状态,及时引导出行人员做出合理的出行决策,保障高速公路安全、便捷、高效运行,从而提高高速公路运行效率。

目前对数据缺失的修复方法主要有3类:考虑时间相关性的数据修复、考虑空间相关性的数据修复、考虑时空相关性的数据修复^[3]。基于时间相关性的修复方法中,常见的方法有历史平均法、移动平均法、指数平滑法等^[4],但仅基于时间序列的方法只能处理少量的丢失数据;空间相关性是指道路不同位置的交通流数据具有相关性,如道路上下游路段、道路横断面不同车道之间的数据有一定的相关性规律,仅基于交通数据空间相关性的修复方法反映了实际的交通流空间关联,但难以体现路网交通的非均匀时变特征。为了克服以上问题,文献^[5]综合考虑了时间和空间维度之间的关联,利用历史数据中时空相关性信息插补缺失数据,研究发现考虑时空相关性的数据修复方法可以有效提升交通数据修复精度。

实时修复后的交通数据可以为交通流状态预测提供基础,方便交通管理者提前部署交通资源和引导交通流。交通流预测方法主要有基于统计理论的预测模型、基于机器学习的预测模型和组合预测模型^[6]。统计预测方法是早期交通流预测常用的方法,主要分为线性统计方法和非线性统计方法,但是此类方法通常假设历史数据之间具有平稳性和线性相关性,无法较好处理具有复杂结构的海量数据。机器学习与深度学习方法在交通流量预测领域应用日益广泛,大量研究证明其预测准确度相对较高,文献^[7]建立了基于长短期记忆神经网络(long short-term memory, LSTM)的高速公路短时交通流预测模型,能够深入挖掘预测问题中的时间相关性,具有长期预测精度较高的优点。针对日益复杂的交通状态,很多研究组合使用原有方法,以获得更加精确的预测结果,文献^[8]提出了长短期记忆网络-径向基函数(long short-term memory-radial basis function, LSTM-RBF)预测模型,对比确定了最佳预测间隔,再将LSTM-RBF方法与单一LSTM和RBF预测方法做实例比较,验证了预测方法的准确性和合理性;文献^[9]利用双向长短期记忆网络(bidirectional long short-term memory, Bi-LSTM)捕捉高速公路交通流的时间特征,将交通速度特征矩阵输入至Bi-LSTM预测模型中进行训练与学习,结果表明,相较于HA、ARIMA和LSTM等模型,该模型拥有更好的预测精度。

通过对交通流数据修复和交通流数据预测研究现状分析,以下问题仍需要进一步研究。

(1)在交通流数据修复方法研究中,插值法和统计修复方法无法充分利用路段之间的时空相关性。为了考虑交通流数据的时空特征,机器学习算法通常需要大量完整的历史交通流数据进行学习和训练,计算过程复杂,难以适用于交通流缺失数据实时修复问题。因此,本研究将针对时空相关性以及模型复杂度进行补充和改进。

(2)在交通流预测研究中,常常忽略交通流时空信息之间的潜在关联,并且多种交通流特征在不同时空维度中的影响尚未明确。大多数现有的深度学习模型具有“黑匣子”性质,对模型预测过程缺

乏可解释性^[10],因此,本研究将针对时空相关性及特征影响度进行补充和改进。

1 基于低秩张量补全的高速公路交通流数据修复方法

1.1 高速公路 ETC 数据预处理

1.1.1 数据清洗

本研究所用数据来自 2023 年 3 月 1 日—31 日山东京台高速泰安—枣庄段及其周边,包括 21 个收费站、25 个门架在内的高速公路收费系统,本研究路段路网结构及门架、收费站分布示意图如图 1 所示,图 1 使用 ArcGIS 软件绘制。当车辆通过收费站或路段门架时,收费系统将记录车辆到达相关信息,如到达时间、站点信息、收费信息、车辆信息等。



图 1 高速公路路网结构及门架、收费站分布示意图
Fig.1 Schematic diagram of highway network structure, toll gates, and toll stations distribution

收费系统受到车辆启停、设备老化以及人工操作等影响,异常数据时有发生,尤其在高峰时期,ETC 系统短时间内产生大量收费数据,更易存在异常数据。此外,若出现系统故障、信息交互断联、恶劣天气等情况也会影响数据质量。为减少干扰,需要对异常数据进行初步识别处理,主要包括数据冗余识别和数据错误识别^[11]。

数据冗余表现为不同数据之间的所有数据字段均重复。理论上讲,每辆车通过收费设备时生成的数据具有唯一性,但实际存在重复情况,需要仅保留一条有效数据,删除其他冗余数据。数据错误是指记录与常识不符的数据,主要包括以下

几种情况:部分驾驶员在经过收费站时人为躲避收费或在收费服务区掉头,导致进出收费站记录相同;收费员操作失误或收费站系统未及时同步,产生错误数据;同一位置其他方向的 ETC 门架检测到同一辆车的过车记录;同一车辆出口站时间早于入口站时间的记录等。面对这些异常数据,需要进行删除处理。

本研究以 15 min 为统计间隔,计算获得通过收费站或门架的车流量;根据门架和收费站桩号,计算相邻 ETC 门架或门架与收费站之间的路段距离;链接同一车辆在不同位置的通行记录,获得车辆平均行程时间和平均车速。

1.1.2 交通流平滑滤波处理

由于受到多种因素的影响,交通流量和速度在时间和空间上具有不确定性和波动性,这种特性对交通流特征的挖掘和模型的建立产生一定影响。因此,为了提高模型精度和数据质量,本研究选择滑动窗口法和一阶指数平滑法^[12]对数据进行平滑滤波处理,这 2 种方法计算复杂度低、处理时间短,适用于大规模 ETC 收费数据的处理。本研究设置平滑系数为 0.8、滑动窗口为 5 min、时间窗口为 15 min 的两步数据滤波算法处理交通流量和速度 2 种交通参数。

1.2 交通流数据缺失识别

交通流数据缺失的主要因素有:(1)收费数据需要通过网络进行上传和传输,如果网络连接不稳定或存在故障可能导致延迟上传数据;(2)收费数据通常需要进行处理和整理,例如数据压缩、加密或格式转换等操作,这些处理过程需要一定的时间,导致数据上传延迟;(3)当收费数据量较大或上传频率较高,需要更长的时间完成上传过程,高频率的上传可能使得数据无法及时处理和传输。以上因素导致 ETC 数据上传延迟,造成系统实时记录的交通流量远小于实际交通流量,这类数据在本研究中视为缺失数据。缺失数据可分为 3 种类型:随机性缺失、结构性缺失和混合性缺失。其中随机性缺失是由于随机因素干扰而导致的孤立点缺失^[13],这种缺失没有明显的规律;结构性缺失是由于检测故障导致交通流量在几分钟甚至几小时内出现数据丢失,这种缺失比例较大,严重影响后续的交通数据分析;混合性缺失是前 2 种缺失模式的组合。本研究在 3 月 6 日和 3 月 8 日对泰安路段 3 月 5 日交通流数据的提取结果如图 2 所示,3 月 6 日提取的数据因延迟上传造成缺失,3 月 8 日提取的数据已是上传完整的真实数据。图 2 中显示了随机

性缺失和结构性缺失情况。随机性缺失数据用黑色圆圈表示,结构性缺失数据用黑色方框中的红色线条表示。图2中显示出随机性缺失数据会在一天内的任意时段随机出现,而结构性缺失数据主要出现在早晚高峰时段和紧邻当前采集时间的前几个时段。

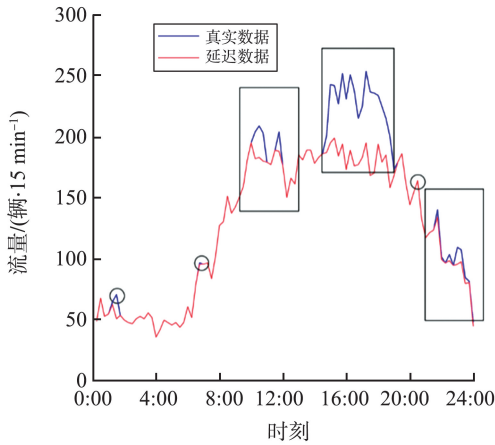


图2 3月5日交通流量数据缺失情况
Fig.2 Traffic flow data missing on March 5th

在实际应用中,ETC收费系统实时记录并更新车辆记录,虽然数据的延迟主要发生在前24h,但数据缺失的分布情况和类型是未知的,因此需要设置一定的阈值对提取的数据进行缺失识别。本研究采用以下判断依据:如果实时提取的某个时段流量少于上一周同一天一定比例或数量的流量,则可以

判断为缺失数据。为了确定最佳阈值,本研究将缺失数据的比例或数量分别设置为5%、10%和20%以及5辆、10辆和20辆,利用混淆矩阵方法将模型的分类结果与实际情况进行比较^[14],将不同阈值的识别情况进行统计,如表1所示。

表1 不同阈值下的数据缺失实际识别结果
Table 1 Data missing identification results under different thresholds

缺失阈值	识别情况	真实缺失数量/辆	
		缺失数	无缺失数
5%	缺失数量	11	5
	无缺失数量	22	58
10%	缺失数量	7	3
	无缺失数量	26	60
20%	缺失数量	1	0
	无缺失数量	32	63
5辆	缺失数量	13	5
	无缺失数量	20	58
10辆	缺失数量	11	5
	无缺失数量	22	59
20辆	缺失数量	7	2
	无缺失数量	26	61

为方便评估识别效率,采用准确率、精确率、召回率、特异度、 F_1 分数作为评价指标,判断混淆矩阵分类结果准确性。使用不同的阈值分别进行了分类识别后,混淆矩阵的评价指标结果如表2所示。

表2 交通流量数据缺失评价指标结果
Table 2 Traffic flow data missing evaluation index results

阈值	评价指标/%				
	准确率	精确率	召回率	特异度	F_1 分数
5%	71.9	68.8	33.3	92.1	44.9
10%	69.8	70.0	21.2	95.2	35.4
20%	66.7	100.0	3.0	100.0	5.8
5辆	74.0	72.2	39.4	92.1	51.0
10辆	71.9	68.8	33.3	92.1	44.9
20辆	70.8	77.8	21.2	96.8	33.3

从准确率和召回率指标来看,阈值为5%、5辆和10辆比其他阈值效果好;从精确率和特异度指标来看,阈值为10%、5辆、20辆比其他阈值效果好;从 F_1 分数来看,阈值为5辆时效果最好,是最准确的一种识别方式。

对比几种指标发现,阈值为5辆时能够达到最佳的分类准确度。因此,本研究将交通流缺失数据识别的阈值设为5辆,即某个路段某时段的车流量相较于上周同一天的车流量少于5辆时,本研究将判定该时段的交通流量数据是不准确的,

即为缺失数据。

1.3 基于低秩交通数据张量补全方法

1.3.1 模型建立

交通流数据存在很强的时间相似性和空间相似性,可以以三维张量形式表示,包括时间、空间位置和交通指标三个维度。时间维度表示数据采集的时间点或时间段,可以是连续的时间间隔或离散的时间点;空间位置维度表示数据采集的地理位置,可以是点、线或区域,常见的空间位置包括路段、交叉口和道路网络;交通指标维度表示交通流

量、速度、密度等指标,可以是实时测量得到的数据或历史数据。交通流三阶张量示意图如图3所示,交通流数据可以表示为以日、周和路段为维度的一个三阶张量。

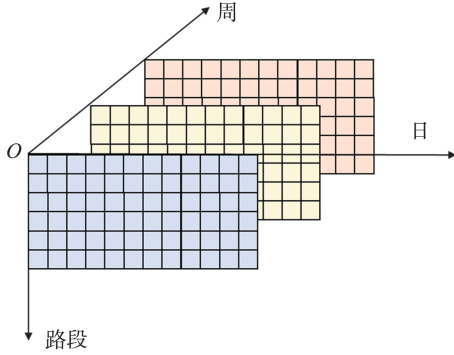


图3 交通流三阶张量示意图

Fig.3 Schematic diagram of the third-order tensor of traffic flow

由于交通流数据从日、周和空间上都具有高度的相关性,因此它们可以构造为一个近似的三阶张量。针对含有缺失数据的交通流三阶张量,可以先进行CP分解(canonical polyadic decomposition)寻找数据的本质特点,然后再进行还原从而实现数据的补全。假设 \mathbf{X} 为交通流数据相关性的 n 向张量模型, $\mathbf{X} \in \mathbf{R}^{L \times D \times W}$,其中 L 表示路段上门架的位置维度, D 表示交通数据的天维度, W 表示交通数据的周维度。根据张量补全理论,输入目标函数为

$$\begin{aligned} & \min_y \text{rank}(\mathbf{A}), \\ & \text{s.t. } \mathbf{A}_\Omega = \mathbf{X}_\Omega, \end{aligned}$$

式中, $\text{rank}(\cdot)$ 为张量的秩, \mathbf{A} 为填补交通数据后的张量, Ω 为已观测到的数据索引变量。

针对一个三阶张量的交通流数据补全问题可以建模为以下数学式,即

$$\begin{aligned} & \min_{M, X_1, X_2, X_3} \sum_{k=1}^3 \alpha_k \| \mathbf{A}_{k(k)} \|_{r_k}, \\ & \text{s.t. } \begin{cases} \mathbf{A}_k = \mathbf{M}, k=1, 2, 3 \\ \mathbf{M}_\Omega = \mathbf{A}_\Omega \end{cases}, \end{aligned}$$

式中: \mathbf{M} 为辅助变量,用来建立观测到的原始张量间的关系; \mathbf{A}_k 为填补交通数据后的张量; k 为索引。

1.3.2 模型求解

目前,很多研究常用交替最小二乘法和梯度下降法对模型进行求解优化^[15-18],但由于矩阵和张量分解都是非凸问题,因此常用的方法并不能达到全局最优。为了解决此问题,本研究使用交替方向乘法器算法(alternating direction method of multipliers, ADMM)^[19]进行模型求解,这种方法可以将全局问题分解为众多更小且更容易求解的局部子问题,从

而获得全局最优解。

采用ADMM框架优化目标函数,建立目标函数的增广拉格朗日函数,即

$$\begin{aligned} L(\mathbf{M}, \{\mathbf{A}_k, \mathbf{T}_k\}_{k=1}^3) = & \sum_{k=1}^3 (a_k \| \mathbf{A}_{k(k)} \|_{r_k, *}) + \\ & \frac{\rho_k}{2} \| \mathbf{A}_{k(k)} - \mathbf{M}_{(k)} \|_F^2 + \langle \mathbf{A}_k + \mathbf{M}, \mathbf{T}_k \rangle, \end{aligned} \quad (1)$$

式中: $\langle \cdot, \cdot \rangle$ 表示内积; \mathbf{T}_k 作为辅助变量用作ADMM算法的双重更新,即拉格朗日乘子, $\mathbf{T}_k \in \mathbf{R}^{L \times D \times W}$ 。

ADMM算法以迭代的方式将原优化问题转换为以下子问题,公式为

$$\mathbf{A}_k^{l+1} = \arg \min_{\mathbf{A}} L(\mathbf{M}, \{\mathbf{A}_k^{l+1}, \mathbf{T}_k^l\}_{k=1}^3), \quad (2)$$

$$\mathbf{M}_k^{l+1} = \arg \min_{\mathbf{M}} L(\mathbf{M}, \{\mathbf{A}_k^{l+1}, \mathbf{T}_{k+1}^l\}_{k=1}^3), \quad (3)$$

$$\mathbf{T}_k^{l+1} = \mathbf{T}_k^l + \rho_k (\mathbf{A}_k^{l+1} - \mathbf{M}^{l+1}), \quad (4)$$

变量的更新顺序为 $\mathbf{A}_1^{l+1} \rightarrow \mathbf{A}_2^{l+1} \rightarrow \mathbf{A}_3^{l+1} \rightarrow \mathbf{M}^{l+1} \rightarrow \mathbf{T}_1^{l+1} \rightarrow \mathbf{T}_2^{l+1} \rightarrow \mathbf{T}_3^{l+1}$ 。

1.3.3 模型对比

为验证所提出模型的优越性,本研究将提出的修复方法分别与拉格朗日插值法、 K 最近邻法(K -nearest neighbor, KNN)、支持向量回归(support vector regression, SVR)等几种模型进行对比。为了方便与其他预测模型进行比较,本章选取平均绝对误差(mean absolute error, MAE) M_{AE} 和平均绝对百分比误差(mean absolute percentage error, MAPE) M_{APE} 作为预测效果评价指标。不同模型的修复效果如表3所示,低秩张量补全模型在4个路段的修复对比结果如表4所示。

表3 各算法整体修复结果对比

Table 3 Comparison of the overall repair results of each algorithm

模型类型	评价指标	
	$M_{AE}/(\text{辆} \cdot 15 \text{ min}^{-1})$	$M_{APE}/\%$
拉格朗日插值	27.187	13.631
KNN	19.187	10.092
SVR	12.750	6.475
低秩张量补全	6.656	3.926

表4 低秩张量补全模型各路段修复结果对比

Table 4 Comparison of repair results of each road section in low-rank tensor completion model

路段名称	评价指标	
	$M_{AE}/(\text{辆} \cdot 15 \text{ min}^{-1})$	$M_{APE}/\%$
泰安	8.562	4.188
满庄	7.250	4.123
曲阜	6.500	3.417
滕州	4.312	3.977

由表3知,在4类模型中,低秩张量补全模型的 M_{AE} 和 M_{APE} 均为最低值,与其他模型中效果最好的SVR模型对比, M_{AE} 和 M_{APE} 分别降低47.80%和39.37%,整体修复效果最好。由表4可知,本研究提出的模型在各个路段上的各项指标,各项指标都相对较低,表明模型具有一定稳定性。

2 基于注意力机制的卷积长短期神经网络交通流参数预测方法

2.1 CNN

卷积神经网络(convolutional neural networks, CNN)是深度学习领域的代表算法之一,是一种包含卷积计算和深度结构的前馈神经网络,可以实现端到端的学习。CNN通常包含数据输入层、卷积层、激活层、池化层和全连接层,可通过对各个层的迭代计算

形成完整的CNN结构^[20]。在交通预测方面,CNN能够从交通数据中提取有效的特征,通过卷积操作和池化操作自动学习和提取数据中的空间特征和局部模式。其次,CNN适用于时空建模,通过多层卷积和池化操作构建深度网络结构,能有效地捕捉交通数据中的时空依赖性。

2.2 LSTM

LSTM是循环神经网络(recurrent neural network, RNN)的一种变体,用于解决一般递归神经网络中普遍存在的长期依赖问题,其核心概念在于细胞状态以及“门”结构^[21]。LSTM可以根据历史交通数据学习交通状态的变化规律,并预测未来的交通情况。LSTM模型将历史交通数据作为输入序列,将未来的交通数据作为输出序列,通过捕捉交通流的复杂动态变化特征,从而实现准确的交通流预测。LSTM模型流程图如图4所示。

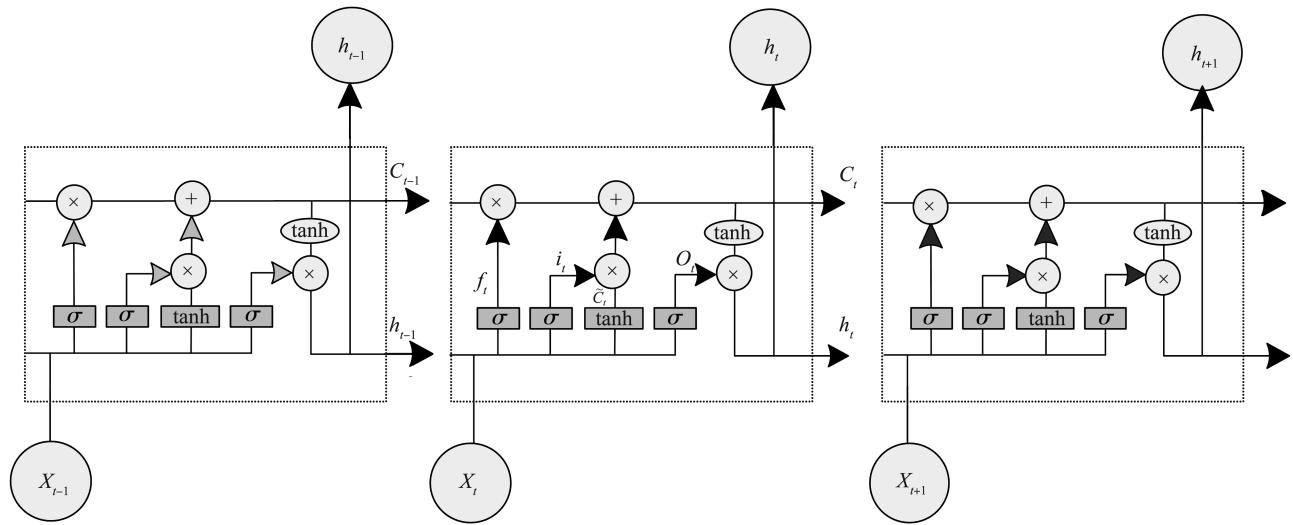


图4 LSTM模型流程图
Fig.4 The flowchart of LSTM model

在时间步 t 处,假设输入为 x_t ,前一时刻的隐藏状态为 h_{t-1} ,单元状态为 c_{t-1} ,LSTM的计算过程如下:首先,计算遗忘门 f_t ,控制前一时刻单元状态的遗忘程度,公式为

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f), \quad (5)$$

式中, W_f 是输入 x_t 的权重矩阵, U_f 是前一时刻隐藏状态 h_{t-1} 的权重矩阵, b_f 是偏置向量, σ 是sigmoid函数。

其次,计算输入门 i_t ,控制新信息的输入程度,公式为

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i), \quad (6)$$

式中, W_i 是输入 x_t 的权重矩阵, U_i 是前一时刻隐藏状态 h_{t-1} 的权重矩阵, b_i 是偏置向量。

再次,计算新单元状态 \tilde{c}_t ,用于更新当前单元状态,公式为

$$\tilde{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c), \quad (7)$$

式中, W_c 是输入 x_t 的权重矩阵, U_c 是前一时刻隐藏状态 h_{t-1} 的权重矩阵, b_c 是偏置向量, \tanh 是双曲正切函数。

最后,计算当前时刻的单元状态 c_t ,并更新隐藏状态 h_t ,从而得到模型的输出,公式为

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t, \quad (8)$$

$$h_t = o_t \odot \tanh(c_t), \quad (9)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o), \quad (10)$$

式中: \odot 表示逐元素乘积; o_t 是输出门,用于控制输出程度; W_o 是输入 x_t 的权重矩阵; U_o 是前一时刻

隐藏状态 h_{t-1} 的权重矩阵; \mathbf{b}_o 是偏置向量。

2.3 注意力机制

注意力机制 (attention mechanism, ATT) 是一种在机器学习和自然语言处理中广泛应用的技术^[22]。它模拟了人类在处理信息时的注意力分配过程,通过对输入序列中不同位置的信息赋予不同的权重,从而集中关注对当前任务有用的部分^[23]。其主要目的是使模型能够在处理输入序列或集合数据时更加灵活地关注重要的部分,而不是一概而论。在深度学习领域,ATT 通过动态地分配权重给输入的不同部分,使得模型能够在不同的时间步或位置上分配不同的关注度。在深度学习中,ATT 通常用于处理序列数据,可以帮助模型在处理长序列时更好地捕捉关键信息,有效地解决长期依赖问题。

注意力机制可以分为硬注意力和软注意力^[24]。在硬注意力机制中,模型明确选择一个输入元素作为注意力的焦点,忽略其余元素。这种确定性可能会带来局限性,特别是在处理复杂的输入数据和任务时。软注意力机制为每个输入元素分配一个连续的注意力权重,并将这些权重用于对输入进行加权聚合。软注意力机制根据输入数据的上下文和任务要求动态地分配注意力,能够关注多个元素,并将注意力权重分配到不同程度。这种灵活性使得软注意力具有更好的适应性和表达能力。本研究使用的是软注意力机制,将对其进行重点介绍。

软注意力机制得到的是所有输入向量在注意

力分布下的期望,公式表示为

$$\alpha_n = p(z=n|X, \mathbf{q}) = \text{softmax}(s(x_n, \mathbf{q})) = \frac{\exp(s(x_n, \mathbf{q}))}{\sum_{j=1}^N \exp(s(x_j, \mathbf{q}))}, \quad (11)$$

$$s(x_n, \mathbf{q}) = \mathbf{v}' \tanh(\mathbf{W}x_n + \mathbf{U}\mathbf{q}), \quad (12)$$

式中: α_n 为第 n 个向量的权重; X 是一个长度为 N 的输入序列, $X = \{x_1, x_2, \dots, x_N\}$; \mathbf{q} 为查询向量; $s(x_n, \mathbf{q})$ 为注意力打分函数; \mathbf{v} 、 \mathbf{W} 、 \mathbf{U} 为可学习的参数。

最后,软注意力机制得到的加权向量可以表示为

$$\text{att}(X, \mathbf{q}) = \sum_1^N \alpha_n x_n. \quad (13)$$

2.4 ATT-CNN-STM

交通流数据涵盖了时空信息,包括交通流量、速度、道路状态等,具有高度复杂性和时空相关性^[25]。在交通流参数预测中,CNN 通过卷积和池化操作能够自动提取空间特征和局部模式,而 LSTM 则擅长捕捉长序列的时间依赖性。ATT 通过动态分配权重,使模型能够聚焦于重要特征,提升预测准确性和可解释性。

因此,基于以上 3 个方法对于交通流参数预测的优势,本研究提出一种基于注意力机制的卷积长短期记忆神经网络 (ATT-CNN-LSTM) 的高速公路交通流参数预测模型,框架图如图 5 所示。

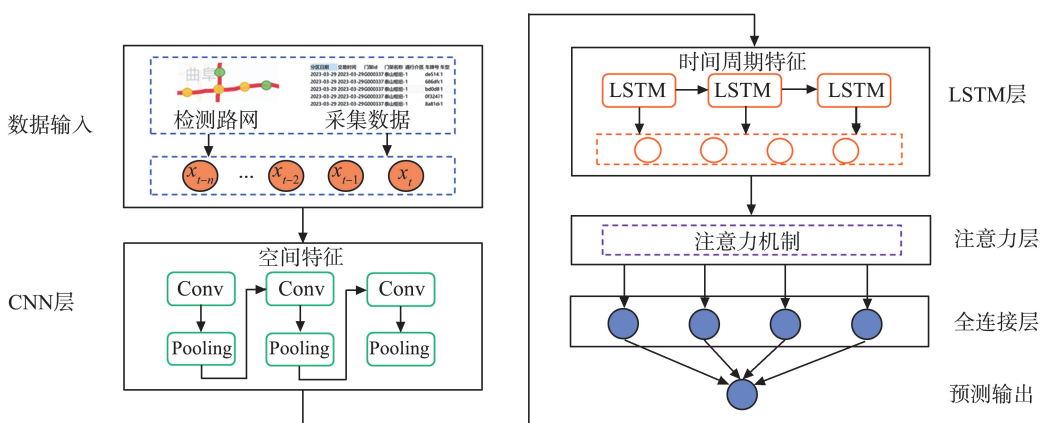


图5 ATT-CNN-LSTM 预测模型框架图

Fig.5 Frame diagram of the ATN-CNN-LSTM prediction model

该模型充分考虑了交通流参数的时空特性,挖掘了数据随时间和空间的变化特征,能够更准确地捕捉交通系统的动态变化,并且能够更好地捕捉输入数据中的重要特征并分配权重,有助于提高预测精度。该预测模型共设计了 4 个层次的结构,其详细构建过程如下所述。

(1)输入层:将训练数据输入预测模型。输入数

据的格式为 $N \times M$ 的矩阵,其中 N 表示训练数据的时间序列长度, M 表示每个时间段的交通特征信息。

(2)CNN 层:通过三层卷积层、池化层和一层全连接层提取输入数据的时空特征。在 CNN 层中引入 ATT,增强序列之间的时空特征相关性,并将加强后的序列数据传递给后续模型。其中卷积核数目为 50,大小为 3×3 ,步长为 1。池化层对输入的高维特

征数据进行降维处理,以提高卷积神经网络的计算速度,并防止过拟合。并且采用最大池化策略,池化核大小为 2×2 ,步长为2。在池化层和LSTM层之后添加Dropout层,以有效防止过拟合。全连接层作为回归输出层,输出时空特征数据,减少特征位置对分类结果的影响,提升整个网络的鲁棒性。

(3)LSTM层:挖掘输入数据序列的时间相关性,选用三层LSTM网络能更好地捕捉长序列数据中的长期依赖关系,提升序列数据的建模能力,LSTM神经元的个数为128个。

(4)输出层:输出模型的预测结果。

3 交通流参数预测方法验证

3.1 模型对比

为了验证模型的有效性,本研究选择SVR、CNN、LSTM、CNN-LSTM等4种预测模型作为对比模型,与本研究提出的ATT-CNN-LSTM预测模型进行比较。高速公路路段交通流参数预测模型的输入数据分为训练数据和测试数据,其中训练数据占比为80%,测试数据占比为20%。文献[26]针对LSTM模型对交通流预测研究方面做过相关分析,通过比较5、10、15 min的预测步长的预

测效果,发现当预测水平为5 min时,模型的预测精度最高,预测范围越长时,误差越大。综合考虑预测精度以及在实际应用中数据上传延迟的问题,本研究选择15 min作为预测步长。此外,进行模型训练和预测前后还需要对数据进行归一化与反归一化处理,归一化处理是指将数据处理为 $[0, 1]$ 的数据分布,反归一化处理是指将归一化后的数据还原为原始的数据。为了方便与其他预测模型进行比较,本研究选取 M_{SE} 和 M_{APE} 作为预测效果评价指标。

3.2 试验结果与分析

3.2.1 数据补全效果预测结果分析

本研究选取泰安枢纽路段将未经数据补全的预测模型与采用低秩张量进行数据修复后的预测模型进行结果对比,预测效果误差对比如表5所示。由表5可以看出,经过数据修复后的模型在预测误差方面有显著减小,在流量预测上 M_{SE} 和 M_{APE} 分别降低72%和36%;在平均速度预测方面 M_{SE} 和 M_{APE} 分别降低46.5%和25.0%。这是由于缺失的数据无法真实反映实际交通运行状况。交通流数据体现了时间和空间位置上的变化,采用低秩张量补全数据的方法考虑了交通流数据的时空特征,更加适用于实时的交通流异常数据修复问题。

表5 数据补全预测结果误差对比
Table 5 Comparison of error in data completion results

预测模型	流量		平均速度	
	$M_{SE}/(\text{辆} \cdot 15 \text{ min}^{-1})^2$	$M_{APE}/\%$	$M_{SE}/(\text{km} \cdot \text{h}^{-1})^2$	$M_{APE}/\%$
ATT-CNN-LSTM	313.909	12.052	14.104	2.723
Pre-ATT-CNN-LSTM	87.335	7.757	7.535	2.031

3.2.2 不同时段预测结果分析

为评估模型在不同时段的预测效果,基于泰安—枣庄13个路段的收费数据,对比工作日(3月29日,周三)和非工作日(3月26日,周日)的交通流量与速度预测误差。本研究所选日期均无节假日、恶劣天气或特殊活动干扰。13个路段工作日和

非工作日使用5种模型的平均预测误差结果如表6和表7所示。由表6和表7可知,ATT-CNN-LSTM方法的误差均值低于其他对比方法。综合来看,预测流量的 M_{SE} 和 M_{APE} 分别下降22.47%和8.41%,预测平均速度的 M_{SE} 和 M_{APE} 分别下降42.83%和6.32%。

表6 泰安—枣庄13个路段3月29日(周三)不同模型平均预测误差
Table 6 Average prediction error of different models in 13 sections from Taian to Zaozhuang on March 29th (Wednesday)

预测模型	流量		平均速度	
	$M_{SE}/(\text{辆} \cdot 15 \text{ min}^{-1})^2$	$M_{APE}/\%$	$M_{SE}/(\text{km} \cdot \text{h}^{-1})^2$	$M_{APE}/\%$
SVR	253.245	13.215	23.035	3.604
CNN	257.404	12.183	17.540	3.165
LSTM	195.832	10.942	15.523	3.005
CNN-LSTM	91.451	8.094	14.534	2.942
CNN-LSTM-ATT	53.650	6.837	8.612	2.456


表7 泰安—枣庄13个路段3月26日(周日)不同模型平均预测误差

Table 7 Average prediction error of different models in 13 sections from Taian to Zaozhuang on March 26th (Sunday)


预测模型	流量		平均速度	
	$M_{SE}/(\text{辆}\cdot 15\text{ min}^{-1})^2$	$M_{APE}/\%$	$M_{SE}/(\text{km}\cdot\text{h}^{-1})^2$	$M_{APE}/\%$
SVR	197.673	12.042	24.933	4.483
CNN	112.614	8.048	29.697	3.140
LSTM	57.094	7.124	22.310	2.702
CNN-LSTM	54.368	6.928	17.245	2.473
CNN-LST-MATT	52.403	6.838	9.500	2.569

泰安路段3月26日—31日真实交通流参数与ATT-CNN-LSTM方法预测得到的交通流量、平均

速度结果的对比情况如图6所示。



(a) 流量预测结果



(b) 平均速度预测结果

图6 泰安路段3月26日—31日真实交通流参数与ATT-CNN-LSTM预测结果

Fig.6 Real traffic flow parameters and ATT-CNN-LSTM prediction results for the Taian road section from March 26th to 31st

由图6可知,本研究提出的模型ATT-CNN-LSTM的预测结果与实际交通流参数整体较吻合,能够实时反映高峰期交通流的瞬间波动情况,可以捕捉交通流微小变化,预测拟合度和灵敏度较高。图6中误差曲线分析表明,流量预测误差集中在 ± 20 辆范围内,平均速度预测误差控制在 ± 10 km/h以内。流量拟合度略低于平均速度,主要因流量波动性较高(尤其是高峰时段突变),而平均速度变化相对平缓。

3.2.3 不同路段预测结果分析

为评估不同路段的模型预测效果,选取泰安、满庄、曲阜、滕州4个枢纽路段进行测试。基于3月

26日—31日的收费数据,利用5种模型进行交通流预测,其误差对比结果如表8~11所示。试验结果表明,传统机器学习模型SVR作为浅层模型,其非线性建模能力显著弱于深度学习模型。CNN-LSTM通过融合时空特征,预测效果较单一CNN或LSTM模型略有提升。然而,无论是流量还是平均速度,ATT-CNN-LSTM的预测效果都有显著改善,总体优于其他几种对比模型。这体现了时空结合的优越性,表明注意力机制在关注对交通流预测具有较高相关性的时空因素时起到了重要作用,赋予了这些因素较高的权重。

表8 泰安路段预测结果误差对比
Table 8 Comparison of error in prediction results of Taian Road section

预测模型	流量		平均速度	
	$M_{SE}/(\text{辆}\cdot 15\text{ min}^{-1})^2$	$M_{APE}/\%$	$M_{SE}/(\text{km}\cdot\text{h}^{-1})^2$	$M_{APE}/\%$
SVR	348.933	14.957	35.068	3.521
CNN	200.785	12.640	14.219	2.819
LSTM	283.780	11.589	9.946	2.425
CNN-LSTM	112.768	8.149	9.129	2.316
ATT-CNN-LSTM	87.335	7.757	7.535	2.031

表9 满庄路段预测结果误差对比
Table 9 Comparison of error in prediction results of Manzhuang Road section

预测模型	流量		平均速度	
	$M_{SE}/(\text{辆}\cdot 15\text{ min}^{-1})^2$	$M_{APE}/\%$	$M_{SE}/(\text{km}\cdot\text{h}^{-1})^2$	$M_{APE}/\%$
SVR	292.890	15.646	13.227	2.864
CNN	502.472	13.791	12.420	2.749
LSTM	487.822	11.486	10.020	2.517
CNN-LSTM	239.665	8.085	9.176	2.426
ATT-CNN-LSTM	50.574	5.286	8.612	2.366

表10 曲阜路段预测结果误差对比
Table 10 Comparison of error in prediction results of Qufu Road section


预测模型	流量		平均速度	
	$M_{SE}/(\text{辆}\cdot 15\text{ min}^{-1})^2$	$M_{APE}/\%$	$M_{SE}/(\text{km}\cdot\text{h}^{-1})^2$	$M_{APE}/\%$
SVR	161.212	11.477	29.199	3.128
CNN	17.093	4.040	15.436	2.985
LSTM	16.307	3.965	10.457	2.549
CNN-LSTM	6.985	2.655	9.411	2.445
ATT-CNN-LSTM	4.895	2.103	8.985	2.429

表11 滕州路段预测结果误差对比
Table 11 Comparison of error in prediction results of Tengzhou Road section


预测模型	流量		平均速度	
	$M_{SE}/(\text{辆}\cdot 15\text{ min}^{-1})^2$	$M_{APE}/\%$	$M_{SE}/(\text{km}\cdot\text{h}^{-1})^2$	$M_{APE}/\%$
SVR	139.323	12.709	39.344	3.728
CNN	27.804	6.804	16.933	3.373
LSTM	29.058	6.934	10.710	2.738
CNN-LSTM	14.982	4.931	9.990	2.629
ATT-CNN-LSTM	10.730	4.161	9.500	2.569

泰安—枣庄区域 13 个路段在 3 月 29 日(周三)和 3 月 26 日(周日)的实际交通流量热力图、ATT-CNN-LSTM 预测得到的交通流量热力图以及实际平均速度热力图、ATT-CNN-LSTM 预测得到的平均速度热力图如图 7~10 所示。工作日周三的交通流量如图 7 所示,凌晨 0:00—6:00 的交通流量最小,6:00 之后交通流量逐渐增加。在 8:00—12:00 和 14:00—18:00,交通流量达到高峰。20:00 之后,交通流量逐渐下降并趋于平缓。工作日的交通平均速度如图 8 所示,在白天时段较高。非工作日周日的交通流量如图 9 所示,早

高峰时段车辆较少,而晚高峰持续高位状态,一直延续到 20:00。非工作日的交通平均速度如图 10 所示,这段时间车流畅通,因为人们通勤需求较大。夜间平均速度较低,主要归因于安全限速措施及货车通行比例较高。每张图的上半部分显示了实际交通流量和平均速度热力图,下半部分显示了 ATT-CNN-LSTM 预测得到的交通流量和平均速度热力图。通过对比可以发现,ATT-CNN-LSTM 预测的结果与实际情况非常吻合,它能准确预测交通流量的微小变化,并且在低速时段的拟合度也较高。




(a) 3月29日(周三)13个路段实际交通流量热力图




(b) 3月29日(周三)13个路段ATT-CNN-LSTM 预测交通流量热力图

图7 3月29日(周三)13个路段实际与ATT-CNN-LSTM 预测交通流量热力图

Fig.7 Heatmap of actual and ATT-CNN-LSTM predicted traffic flow for 13 road sections on March 29th




(a) 3月29日(周三)13个路段实际平均速度热力图




(b) 3月29日(周三)13个路段ATT-CNN-LSTM 预测平均速度热力图

图8 3月29日(周三)13个路段实际与ATT-CNN-LSTM 预测平均速度热力图

Fig.8 Heatmap of actual and ATT-CNN-LSTM predicted average speed for 13 road sections on March 29th




(a) 3月26日(周日)13个路段实际交通流量热力图




(b) 3月26日(周日)13个路段ATT-CNN-LSTM 预测交通流量热力图

图9 3月26日(周日)13个路段实际与ATT-CNN-LSTM 预测交通流量热力图

Fig.9 Heatmap of actual and ATT-CNN-LSTM predicted traffic flow for 13 road sections on March 26th



(a) 3月26日(周日)13个路段实际平均速度热力图



(b) 3月26日(周日)13个路段 ATT-CNN-LSTM 预测平均速度热力图

图10 3月26日(周日)13个路段实际与ATT-CNN-LSTM 预测平均速度热力图

Fig.10 Heatmap of actual and ATT-CNN-LSTM predicted average speed for 13 road sections on March 26th

4 结束语

本研究基于 ETC 收费数据实现了考虑时空特性的高速公路交通流数据修复和实时状态预测。首先,本研究对山东省京台高速泰枣路段的 ETC 收费数据进行了预处理,并对高速公路交通流表征参数进行了分析,采用混淆矩阵确定了交通流缺失数据的识别阈值,并建立了基于低秩张量补全的数据修复方法,随后结合注意力机制,构建了 ATT-CNN-LSTM 组合预测模型,实现交通流参数预测。本研究的主要结论如下:

(1) 针对实际应用中交通流实时数据缺失问题,提出一种基于低秩张量补全的高速公路数据修复方法。选择高速公路实测交通流数据作为研究对象,对比插值法、KNN、SVR 的修复效果。结果表明,相比于传统的数据修复方法,采用低秩张量补全模型的修复效果优于其他对比算法,平均绝对误差和平均绝对百分比误差分别下降 47.80% 和 39.37%。

(2) 由于交通流数据中存在复杂多层次的时空依赖性,本研究提出一种基于注意力机制的卷积长短期记忆神经网络高速公路交通流参数预测方法。通过不同时段、不同路段下的交通流量和平均速度试验预测对比,本研究所提出的 ATT-CNN-LSTM 组合模型相比传统机器学习 SVR 模型以及 CNN、LSTM 和 CNN-LSTM 三种深度学习模型,预测流量的均方误差和平均绝对百分比误差分别下降 22.47% 和 8.41%,预测平均速度的均方误差和平均绝对百分比误差分别下降 42.83% 和 6.32%。

本研究仍存在一定不足,仅以干线道路为实例验证方法有效性,而未考虑网状或环状路网等复杂路网结构,并且未考虑多种交通事件对交通流的影响,因此,下一步研究将针对复杂路网结构及多种交通事件对所提出方法进行验证和优化,并与多种最新的深度学习方法对比分析。

参考文献:

[1] 交通运输部. 2022 年交通运输行业发展统计公报 [N/OL]. 中国交通报, 2023-06-16 [2025-03-18]. https://xxgk.mot.gov.cn/2020/jigou/zhghs/202306/t20230615_3847023.htm

[2] 李世忠. ETC 门架车牌识别及交易数据上传不及时问题探讨[J]. 中国交通信息化, 2020(10): 112-116.
LI Shizhong. Discussion on the delayed upload of ETC gantry license plate recognition and transaction data [J].

China Transportation Informatization, 2020 (10): 112-116.

[3] 张涛, 张健, 祁欣月, 等. 交通缺失数据插补方法研究综述[J]. 现代交通与冶金材料, 2023, 3(4): 69-81.
ZHANG Tao, ZHANG Jian, QI Xinyue, et al. A review of imputation methods for missing traffic data[J]. Modern Transportation and Metallurgical Materials, 2023, 3(4): 69-81.

[4] RABBANI M B A, MUSARAT M A, ALALOUL W S, et al. A comparison between seasonal autoregressive integrated moving average (SARIMA) and exponential smoothing (ES) based on time series model for forecasting road accidents[J]. Arabian Journal for Science and Engineering, 2021, 46(11): 11113-11138.

[5] 许书红, 王雯雯, 冯远宏, 等. 交通流数据时空相关修复方法评价分析[J]. 武汉理工大学学报(交通科学与工程版), 2023, 47(3): 408-413.
XU Shuhong, WANG Wenwen, FENG Yuanhong, et al. Evaluation and analysis of spatiotemporal correlation repair methods for traffic flow data[J]. Journal of Wuhan University of Technology (Transportation Science and Engineering Edition), 2023, 47(3): 408-413.

[6] 孟闯, 王慧, 林浩, 等. 道路交通流数据预测方法研究综述[J]. 计算机工程与应用, 2023, 59(14): 51-61.
MENG Chuang, WANG Hui, LIN Hao, et al. Review of research on prediction methods for road traffic flow data [J]. Computer Engineering and Applications, 2023, 59(14): 51-61.

[7] 张潇潇, 龚龔. 基于 LSTM 的沪渝高速公路短时交通流预测研究[J]. 中国交通信息化, 2022(9): 133-137.
ZHANG Xiaoxiao, GONG Yan. Research on short-term traffic flow prediction of huyu expressway based on LSTM [J]. China Transportation Informatization, 2022 (9): 133-137.

[8] 韦佳. 基于时空特性的城市道路交通运行状态预测及评价方法研究[D]. 广州: 华南理工大学, 2020.
WEI Jia. Research on prediction and evaluation methods of urban road traffic operation status based on spatiotemporal characteristics [D]. Guangzhou: South China University of Technology, 2020.

[9] 黄来荣, 谷庆, 林凤榕, 等. 基于深度学习的高速公路交通速度预测模型研究[J]. 中国交通信息化, 2022 (9): 129-132.
HUANG Lairong, GU Qing, LIN Fengrong, et al. Research on highway traffic speed prediction model based on deep learning [J]. China Transportation Informatization, 2022(9): 129-132.

[10] KARLAFTIS M G, VLAHOGIANNI E I. Statistical methods versus neural networks in transportation research: differences, similarities and some insights[J].

- Transportation Research Part C-Emerging Technologies, 2011, 19(3): 387-399.
- [11] 赵怀鑫, 邓然然, 张英杰, 等. 一种用于高速公路通行情况分析的收费数据挖掘方法[J]. 中国公路学报, 2018, 31(8): 155-164.
ZHAO Huaixin, DENG Ranran, ZHANG Yingjie, et al. A toll data mining method for analyzing highway traffic conditions[J]. China Journal of Highway and Transport, 2018, 31(8): 155-164.
- [12] DUAN Y, LV Y, LIU Y L, et al. An efficient realization of deep learning for traffic data imputation [J]. Transportation Research Part C-Emerging Technologies, 2016, 72: 168-181.
- [13] 唐莺萍, 商强. 基于GPS数据的高速公路行程时间估计与可靠性分析[J]. 山东理工大学学报(自然科学版), 2024, 38(3): 14-19.
TANG Yingping, SHANG Qiang. Estimation and reliability analysis of highway travel time based on GPS data[J]. Journal of Shandong University of Technology (Natural Science Edition), 2024, 38(3): 14-19.
- [14] HAY A M. The derivation of global estimates from a confusion matrix [J]. International Journal of Remote Sensing, 1988, 9(8): 1395-1398.
- [15] 李琳, 王培培, 谷鹏, 等. 基于LU分解和交替最小二乘法的分布式奇异值分解推荐算法[J]. 模式识别与人工智能, 2020, 33(1): 32-40.
LI Lin, WANG Peipei, GU Peng, et al. A distributed singular value decomposition recommendation algorithm based on LU decomposition and alternating least squares [J]. Pattern Recognition and Artificial Intelligence, 2020, 33(1): 32-40.
- [16] 张晓飞. 解张量分解问题的信赖域交替最小二乘法[D]. 南京:南京师范大学, 2014.
ZHANG Xiaofei. A trust-region alternating least squares method for solving tensor decomposition problems[D]. Nanjing: Nanjing Normal University, 2014.
- [17] 王昕. 梯度下降及优化算法研究综述[J]. 电脑知识与技术, 2022, 18(8): 71-73.
WANG Xin. A review of gradient descent and optimization algorithms [J]. Computer Knowledge and Technology, 2022, 18(8): 71-73.
- [18] WU J, WANG Z, WU Y, et al. A tensor cp decomposition method for clustering heterogeneous information networks via stochastic gradient descent algorithms[J]. Scientific Programming, 2017, 28(3): 1058-1071.
- [19] SHENG X, WEN Q, FAN L, et al. Low-rank tensor completion by truncated nuclear norm regularization [J]. 2018 24th International Conference on Pattern Recognition (ICPR), 2018: 2600-2605.
- [20] 季长清, 高志勇, 秦静, 等. 基于卷积神经网络的图像分类算法综述[J]. 计算机应用, 2022, 42(4): 1044-1049.
JI Changqing, GAO Zhiyong, QIN Jing, et al. A review of image classification algorithms based on convolutional neural networks[J]. Journal of Computer Applications, 2022, 42(4): 1044-1049.
- [21] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.
- [22] 常昊. 基于LSTM神经网络的地铁短时客流量预测研究[D]. 西安:西京学院, 2022.
CHANG Hao. Research on short-term passenger flow prediction of subway based on LSTM neural network [D]. Xi'an: Xijing University, 2022.
- [23] ZHANG G, ZHU S, BAI X. Federated learning-based multi-energy load forecasting method using CNN-Attention-LSTM model [J]. Sustainability, 2022, 14(19): 12843-12857.
- [24] LAN T, ZHANG X, QU D, et al. Short-Term traffic flow prediction based on the optimization study of initial weights of the attention mechanism[J]. Sustainability, 2023, 15(2): 1374-1390.
- [25] XU C, ZHANG Z, FU F, et al. Analysis of spatiotemporal factors affecting traffic safety based on multisource data fusion [J]. Journal of Transportation Engineering Part A-Systems, 2023, 149(10): 1653-1662.
- [26] XUE B, WANG X, HAN Z. A combined short- and medium-term traffic flow prediction method for proactive traffic control at expressway toll stations[J]. Canadian Journal of Civil Engineering, 2024, 51(11): 1226-1239.

(编辑:郭少华)