稀疏数据下的交通状态估计自适应卷积网络

田 婧[1],马社强[1],宋现敏[2],赵 丹[1],陈发城[1]

(1. 中国人民公安大学 交通管理学院,北京 100038;2. 吉林大学 交通学院,长春 130022)

摘 要:卷积神经网络(CNN)是目前交通状态估计的深度学习算法中提取交通特征的关键模块,其对稀疏数据和多模式交通状态的计算不稳定,制约深度学习的状态估计精度。为进一步提升CNN的交通特征分析精度,本文建立了一种编码-解码的交通自适应卷积网络。首先,本文所提网络构建一种交通特征编码CNN,采用下采样操作聚合邻域交通信息,以从稀疏数据中提取有效的交通特征;其次,构建交通状态自适应重构CNN,利用提取的特征准确重构不同模式的交通状态。为表征多样化交通状态时空结构,该CNN引入先验知识引导卷积核形变。最后,实验采用长春市出租车GPS数据对算法在稀疏数据和不同情景下的交通状态估计性能进行验证。实验结果表明,与LSTM、GAN等先进算法相比,本文提出的改进的CNN算法估计精度提高了6.05 km/h RMSE,同时在不同交通情景下的估计精度仅差3.34% RMSE,能为深度学习估计交通状态提供有力的交通特征分析支撑。

关键词:交通管理工程;交通状态估计;稀疏数据;卷积神经网络;编码-解码结构

中图分类号:U491 **文献标志码**:A **文章编号**:1671-5497(2025)08-2579-09

DOI:10.13229/j.cnki.jdxbgxb.20231247

Adaptive convolutional network for traffic state estimation under sparse data

TIAN Jing[1],MA She-qiang[1],SONG Xian-min[2],ZHAO Dan[1],CHEN Fa-cheng[1]

(1. *School of Transportation Management, People's Public Security University of China, Beijing* 100038, *China*; 2. *School of Transportation, Jilin University, Changchun* 130022, *China*)

Abstract: Convolutional neural networks (CNN) are the key modules for extracting traffic features in deep learning algorithms for traffic state estimation. However, their computational instability on sparse data and multi-modal traffic states limits the accuracy of deep learning for state estimation. To improve the accuracy of CNN-based traffic feature analysis, this paper proposed an encode-decode traffic adaptive convolutional network. Firstly, the proposed network constructed a traffic feature encoding CNN, which uses down-sampling operations to aggregate neighboring traffic information and extracts effective traffic features from sparse data. Secondly, a traffic state adaptive reconstruction CNN is constructed to utilize the extracted features to accurately reconstruct different patterns of traffic states. To represent diverse spatio-temporal structure of traffic states, this CNN introduced prior knowledge to guide the deformation of convolutional

收稿日期:2023-11-13.

基金项目:国家重点研发计划项目(2023YFB4302702);中央高校基本科研业务费(2024JKF02ZK13).

作者简介:田婧(1995-),女,讲师,博士.研究方向:智能交通态势感知.E-mail:jingt202310@163.com

通信作者:马社强(1973-),男,副教授,博士.研究方向:道路交通安全.E-mail:masheqiang@163.com

kernels. Finally, the performance of algorithm in traffic state estimation under sparse data and different scenarios was validated using taxi GPS data in Changchun City. Experimental results show that compared with advanced algorithms such as LSTM and GAN, the improved CNN alogorithm in this paper improves the estimation accuracy by 6.05 km/h RMSE. Besides, the proposed algorithm has an accuracy difference of only 3.34% RMSE in different traffic scenarios, can provide robust traffic festure analysis support for deep learning-based traffic state estimation.

Key words: traffic management engineering; traffic state estimation; sparse data; convolutional neural network; encode-decode structure

0 引 言

近年来,出行即服务、共享出行等智能技术快速发展,对交通状态估计提出了全道路、时空分辨率精细化的更高要求,从而为出行路径规划、交通拥堵调控等提供基础数据保障[1-3]。传统交通状态估计大多采用布设在道路断面的固定检测器采集的数据(如微波、线圈数据等),仅能得到各路段粗时空粒度、平均化的交通状态,难以满足智能交通技术发展所需的连续、精细化交通状态要求[4]。随着群智感知等技术的发展,移动数据(如GPS数据、手机信令数据)包含范围更大的、时空连续的交通流信息,对支撑交通状态精细化估计具有广阔前景。因此,研究移动数据下的交通状态估计不仅对提升智能交通系统状态检测及管控效率具有重要意义,也可为快速发展的交通新技术提供工程应用的状态信息基础。

传统的交通状态估计方法(如自回归移动平均模型及其变体[5,6]、卡尔曼滤波[7]、模糊C均值聚类[8]、K最近邻算法[9]、支持向量机[10])通过分析交通状态短期变化趋势或模式特征来实现估计,计算快捷、简便。近年,新兴的深度学习方法(如张量分解[11]、长短时记忆网络[12])具有处理高维交通数据和建模复杂非线性交通动态的能力,在解决复杂交通状态的估计问题上展现出比传统方法更优的性能,目前已成为交通状态估计研究的重点。

卷积神经网络(Convolutional neural network,CNN)是目前大多数交通状态估计深度学习网络框架中的重要模块,能通过卷积核对交通数据的平移运算提取局部相关性的交通特征[13,14]。作为深度学习中提取分析交通状态特征的关键,CNN的结构与设计对于提升交通状态估计性能有着重要的作用,有必要对其细化研究。目前,CNN在交通状态估计中的应用还存在以下不足:首先,移动传感器在道路上的渗透率较低且采样间隔较大,其检测数据对交通状态的表征是稀疏的,难以支撑算法有效、准确地提取交通特征。一些研究指出,CNN对稀疏数据下的交通状态估计具有较大潜力,其网络参数的共享机制能够从数据中提取平移不变的交通特征,并用于估计未观测状态[15]。然而,卷积核是从局域提取交通特征的,对交通信息缺失较为敏感。因此,CNN如何从稀疏数据中有效聚合局域交通信息仍需进一步研究,以提升交通特征分析精度。其次,受道路拓扑结构、交通需求、突发事件等因素的影响,交通状态呈现出时空分布不均衡、传播模式多样化的特征。传统CNN的卷积核对交通状态特征的提取范围(即感受野)是固定不变的规则方形网格状,对多模式交通状态特征的适应力有限。为提升挖掘多态特征的能力,Dai等[16]提出了一种可变形卷积神经网络(Deformable convolutional neural network, Deformable CNN),通过在卷积核感受野中添加位置偏差,实现形变特征的自适应提取。但是,由于Deformable CNN卷积核的形变缺乏有效监督,因此该网络对多模式交通特征的表征能力有限[17]。交通领域中存在大量不同交通状态模式的先验知识,能够引导CNN有效调整感受野去捕捉多模态特征,提升交通特征分析有效性。因此,通过引入先验知识对CNN进行扩展,以提升多模式交通状态的建模能力。

综上,CNN是目前基于深度学习的交通状态估计框架中提取分析交通特征的重要方式。而交通数据采样的稀疏性以及交通状态特征的多模态性,导致了交通状态特征分析难题,从而制约交通状态估计在交通管控中的实践应用。本文以CNN为研究核心,为提升深度学习在稀疏数据下的交通状态估计精度,构建一种基于编码-解码的交通自

适应卷积神经网络(Encode decode-based traffic adaptive convolutional neural network, ED-TACNN)。该网络通过下采样操作以计算邻域内的交通特征，构造交通特征编码CNN，实现稀疏数据下的交通状态特征准确分析；通过在卷积核感受野的设定中引入先验知识，构造交通状态自适应重构CNN，实现不同时空结构的交通状态重构。

1　交通状态估计问题描述与算法结构

1.1　交通状态估计问题

考虑道路上有一组在驶浮动车对交通状态进行采样，采样数据最终记为二维交通状态时空观测矩阵$\boldsymbol{S}$，浮动车在时间间隔(t_2-t_1)内经过道路位置(x_2-x_1)，其采样的交通信息将作为观测矩阵$\boldsymbol{S}$相应时空位置的交通状态观测值。为标记交通状态时空观测矩阵$\boldsymbol{S}$中缺乏采样信息的位置，本文定义掩膜矩阵$\boldsymbol{M}$，当$\boldsymbol{S}(x,t)$未有浮动车采样的数据时，$\boldsymbol{M}(x,t)=0$；否则，$\boldsymbol{M}(x,t)=1$。为表征矩阵$\boldsymbol{S}$中未观测交通状态的不确定性，本文还在输入数据中引入了随机变量$Z\sim p(z)$。

考虑到道路交通状态受道路结构、交通事件等影响呈现出不同模式，本文将道路交通状态记为不同交通场景包含的交通模式集合$TP=\{cp_1,cp_2,\cdots,cp_{nc}\}$，其中，$cp_i=\{\kappa_i^1,\kappa_i^2,\cdots,\kappa_i^{\mathbb{F}}\}$为第$i$个交通场景中包含的交通模式$\kappa$的集合，$i\in 1,2,\cdots,nc$；$\mathbb{F}$为交通模式总数。例如，交叉口场景$cp_1=\{\kappa_1^1,\kappa_1^2,\cdots\}$，其中，$\kappa_1^1$、$\kappa_1^2$分别为信号控制下的起动波、停车波；路段场景$cp_2=\{\kappa_2^1,\kappa_2^2,\kappa_2^3,\cdots\}$，其中，$\kappa_2^1$、$\kappa_2^2$、$\kappa_2^3$分别为畅通态、拥堵态及过渡态。

ED-TACNN的交通状态估计是通过学习将随机分布$p(z)$转换为对应模式的交通状态时空分布$p(s)$，确定从含有部分交通状态信息的观测矩阵$\boldsymbol{S}$到完整交通状态估计矩阵$\hat{\boldsymbol{S}}$的映射函数g。然而，由于观测数据的稀疏性及交通状态的时空高维性，映射函数g可能不是唯一的。交通状态估计问题写可为：

$$\hat{\boldsymbol{S}}=g(\tilde{\boldsymbol{S}}),\tilde{\boldsymbol{S}}=\boldsymbol{S}\times\boldsymbol{M}+Z\times(1-\boldsymbol{M}) \quad (1)$$

1.2　基于编码-解码的交通自适应卷积神经网络结构

现有研究表明，编码-解码结构能够有效应对稀疏数据，挖掘深层特征并生成多样化样本[18]。本文设计了一种基于编码-解码的交通自适应卷积神经网络，即ED-TACNN，用于增强深度神经网络处理稀疏数据的能力，实现交通状态的准确重构。由交通特征编码CNN和交通状态自适应重构CNN组成的网络架构如图1所示。

交通特征编码CNN以稀疏采样的交通状态和噪声为输入，通过下采样操作将其映射至交通特征潜向量空间。交通状态自适应重构CNN在先验知识的引导下，将交通特征向量重建为完整的时空状态。

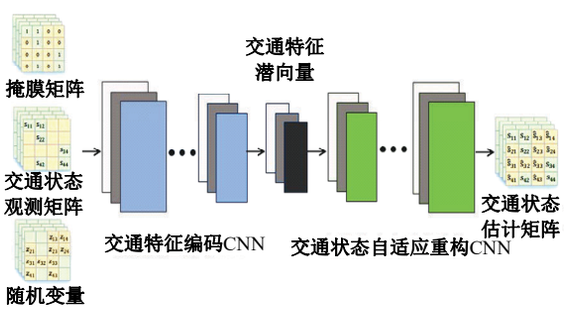

图1　ED-TANN结构

Fig. 1　ED-TACNN structure

2　编码-解码自适应卷积的交通状态估计算法

2.1　交通特征编码CNN

交通状态包括信号控制下的起动波和停车波、交通事故引起的交通拥堵等若干模式。交通特征编码CNN旨在从稀疏数据中提取分析交通模式关键特征。交通特征编码CNN由卷积运算和下采样函数组成，如图2所示。交通特征编码CNN包含若干在交通数据上进行平移运算的卷积核，记作集合$\mathcal{C}=\left\{\mathcal{C}_i\in\mathbb{R}^{H\times W\times D}|i=1,2,\cdots,\mathbb{F}\right\}$，其中，$\mathbb{F}$为卷积核总数，$H$和$W$分别为卷积核从数据中滑动提取交通特征的计算区域长度与宽度，D为卷积核输出的交通特征维度。各卷积核$\mathcal{C}_i$从输入的交通数据中提取不同模式的交通状态特征，例如，自由流和堵塞状态等。交通特征的卷积

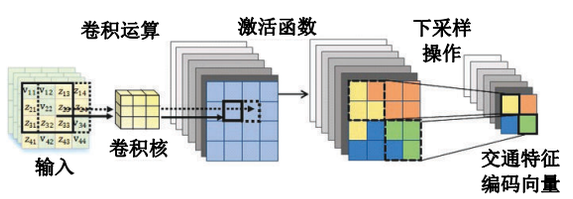

图2　交通特征编码CNN

Fig. 2　Traffic feature encoding CNN

和激活函数计算公式为:

$$\boldsymbol{h}_i^{\mathrm{ac}}=f\left(\sum_{i\in\mathbb{F}}\tilde{S}\otimes\mathcal{C}_i\right) \tag{2}$$

式中:$\boldsymbol{h}_i^{\mathrm{ac}}$为使用第$i$个卷积核输出的交通特征向量;$f$为激活函数,用于增加卷积核提取非线性交通特征的能力。

激活的交通特征图$\boldsymbol{h}^{\mathrm{ac}}$通过下采样操作来生成交通特征编码向量$\boldsymbol{h}^{\mathrm{dn}}$,作为交通状态自适应重构CNN的输入。下采样操作可以聚合邻域内的交通信息,从而获取时空交通状态各子区域的主要交通特征,能较好应对移动数据下的交通状态观测稀疏性问题[19,20]。如图2所示,交通特征计算窗口内可能存在信息缺失或偏差值,下采样操作将选取主要的交通特征作为后续交通状态估计的依据。交通特征的下采样操作可写为:

$$\boldsymbol{h}_i^{\mathrm{dn}}=\max_{p,q}\left(\boldsymbol{h}_i^{\mathrm{ac}}\cdot u(p,q)\right) \tag{3}$$

式中:$u(p,q)$为对时空交通特征进行下采样操作的二维滑动窗口,(p,q)为该窗口的大小。当p和q取值过大时,算法会同时提取来自不同模式的交通特征,从而造成估计误差;当p和q取值过小时,算法提取交通特征的计算效率较低。为避免上述情况,本文参数p和q的设置参考文献[15]。

算法能通过堆叠多层交通特征编码CNN来从交通数据中提炼深层的交通状态特征向量,例如,交通冲击波的传播等[14]。

2.2 交通状态自适应重构CNN

本节旨在利用提取不同模式的交通特征向量准确重构多模态时空交通状态。既有研究(如Deformable CNN)尝试通过构造形状可变的卷积核来自适应计算多模式特征,但其精度仍受卷积核形变缺乏引导与监督的限制。

为有效解码不同交通模式特征并准确重构状态,本文对Deformable CNN进行改进,提出了一种交通状态自适应重构卷积神经网络(Traffic state adaptive reconstruction convolutional neural network,TACNN)。TACNN利用交通状态模式相关的先验知识引导卷积核形变并计算不同结构特征,从而准确重构交通状态。TACNN的结构如图3所示。

TACNN将道路交通状态视为不同模式交通流叠加耦合的最终结果,即通过融合不同交通模式来重构完整、准确的交通状态。其中,各交通模

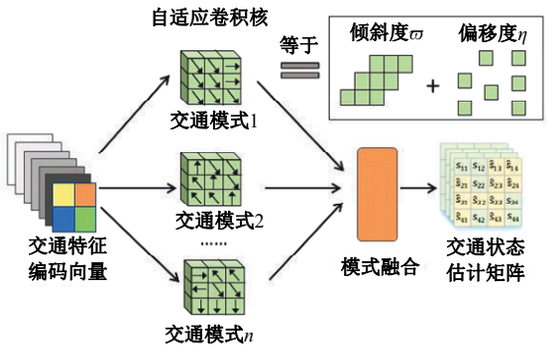

图3 TACNN结构

Fig. 3 TACNN structure

式由自适应卷积核利用编码特征$\boldsymbol{h}^{\mathrm{dn}}$中结合上采样操作以及先验知识还原。TACNN重构交通状态的计算过程为:

$$\begin{cases}\hat{\boldsymbol{S}}=\dfrac{1}{\sum\limits_{i=1}^{\mathbb{F}}\lambda_i}\sum\limits_{i=1}^{\mathbb{F}}\lambda_i\cdot\kappa_i,\\ \kappa_i=f\left(\sum\limits_{i\in\mathbb{F}}\boldsymbol{h}_i^{\mathrm{dn}}*\Gamma_i\right)\end{cases} \tag{4}$$

式中:$\mathbb{F}$为交通模式的总数;κ_i为估计的第i个模式的交通状态;λ_i为第i个交通模式的加权权重,由该模式κ_i与当前状态$\boldsymbol{S}$间的距离确定,即$\mathrm{sigmoid}(\|\boldsymbol{S}-\kappa_i\|)$[21];$\Gamma_i\in\mathbb{R}^{H'\times W'}$为第$i$个交通模式对应的自适应卷积核,采用常见的最近邻上采样函数[22],H'和W'的设定取决于矩阵$\hat{\boldsymbol{S}}$的尺寸,将放大特征$\boldsymbol{h}^{\mathrm{dn}}$至矩阵$\hat{\boldsymbol{S}}$;·代表张量的内积。

为准确重构交通状态,自适应卷积核Γ利用先验交通知识来引导感受野(即提取交通特征的位置)能够自适应形变,以契合不同模式交通状态的多样化时空分布结构,如图3所示。

先验交通知识指描述交通流特性、规律的专家经验、数学模型、常识等。本文涉及的先验交通知识以交通波模型为主体,按交通场景可以分为信号控制下的起动波与停车波、路段上的拥堵波等。先验知识表示为元组形式$k=(\varsigma,\varpi,\gamma)$,其中,$\varsigma$为知识类型,$\varpi$为交通波波速,代表扰动在交通流中传播的速度,$\gamma$为交通波的起始位置。

具体可以参考Deformable CNN,自适应卷积核的感受野在常见方形感受野$\mathfrak{R}$的基础上改进为带有偏差的位置元组,记作$\mathfrak{R}'=\{a_{\mathrm{d}},\Delta a\}_{a_{\mathrm{d}}\in\mathfrak{R}}$,其中,$a_{\mathrm{d}}$为卷积核感受野的基础位置元素,呈规则网格状,$\Delta a$为感受野位置的偏差量,用于控制卷积核的感受野产生形变,以适应交通特征

结构[16]。

偏差量Δa的计算主要依据先验交通知识中的交通波参数ϖ与辅助参数η。如图3所示，交通波波速ϖ的物理意义为流量-密度曲线中的梯度，用于控制卷积核感受野的倾斜程度。偏移度η，作为交通波波速的补充，用于调整感受野以匹配交通波位置，捕捉交通流传播过程中非线性、不规则的时空偏移。因此，偏差量Δa的计算以及式(5)中交通模式κ_i的自适应卷积运算可写为：

$$\begin{cases}\kappa_i=\sum\limits_{a_{\text{add}}\in\Lambda}W_i(a_o)\cdot\tilde{S}(a_o+a_d+\Delta a_i)+b_i\\ \Delta a=\left(\dfrac{a_{\text{add}}^x}{\varpi_x+\tau_x}+\eta_x,\ \dfrac{a_{\text{add}}^t}{\varpi_t+\tau_t}+\eta_t\right)\end{cases}\tag{5}$$

式中：W_i和b_i为分别第i个交通模式对应卷积核的权重及偏差；a_o为卷积核计算的交通特征在输入中的位置；τ_x、τ_t为防止分母为0的常数。

计算得到的Δa需要取整[16]。参数ϖ和η可由全连接层通过学习交通状态与参数间的映射关系估计得到，也可依据先验知识直接给定。

本文以交叉口信号控制引起的起动波和停车波为例，解释先验知识引导下自适应卷积核的构造。如图4所示，信号控制下起动波和停车波时空结构的斜率，即交通波的传播速度ϖ_s和ϖ_e，与饱和流率、阻塞密度等有关，具体计算方式见文献[23]。两种波之间存在时间差(即红绿灯时长)。因此，为能准确重构两种交通模式，自适应卷积核以信号控制下交通波波速为卷积核的倾斜度，以红灯时长r、绿灯时长g为偏移度，构造为：

$$\begin{cases}\Delta a_s=\left(0,\ \dfrac{a_{\text{d}}^x}{\varpi_s+\tau_1}+r\right)\\ \Delta a_e=\left(0,\ \dfrac{a_{\text{d}}^x}{\varpi_e+\tau_2}+g\right)\end{cases}\tag{6}$$

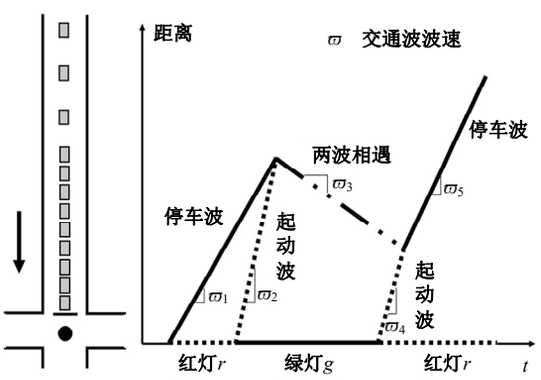

图4　信号控制下交叉口停车波与起动波

Fig. 4　Stopping and starting waves at intersections under signal control

2.3　网络训练策略

ED-TACNN的训练参考自编码器[24]，交通特征编码CNN和交通状态自适应重构CNN以端对端的方式进行统一训练优化。网络参数的优化通过梯度下降方法即可实现。ED-TACNN的损失函数选择均方误差(Mean square error，MSE)为：

$$MSE=\frac{1}{n}\sum_i^n m_i(s_i-\hat{s}_i)^2\tag{7}$$

式中：m_i、s_i、$\hat{s}_i$分别为掩膜矩阵$\boldsymbol{M}$、交通状态观测矩阵$\boldsymbol{S}$、估计矩阵$\hat{\boldsymbol{S}}$中的第i个元素。

3　实验验证与分析

3.1　实验数据集

本文选取长春市出租车GPS数据作为典型浮动车数据，验证本文提出的ED-TACNN算法的交通状态估计性能。实验选取车辆在特定时间间隔内的平均速度作为交通状态的表征指标。该速度指标是涵括交通管控、事故等交通事件对车流运行影响的综合指标，能够有效反映路段交通状态。实验路段选取长春市同志街路口至南湖广场间的路段，该路段途经大型购物中心、公园等，交通流状态具有典型的时变、空间异质等特征，能很好适用于验证ED-TACNN算法交通状态估计结果。实验出租车GPS数据集选取每日06:30至19:00时间段数据，日期范围为2022年6月、7月、8月中的若干天以及9月6日至9月20日时间段。

本文构建了不同稀疏程度的出租车数据集，便于讨论算法对稀疏数据的有效性。考虑到长春出租车GPS数据的采样时间间隔约为3～5 s且出租车车速相对较快，因此出租车数据空间间隔取50 m网格化为二维矩阵。而数据聚合的时间间隔分别取20、30、60、120、180 s，以观测数据点占总体交通状态数据点的比例作为衡量数据稀疏性的指标[4]，上述时间间隔的数据稀疏率分别约为20%、25%、35%、50%、55%。

数据集以前75%的数据作为训练集，余下数据作为测试集。实验在测试集中随机移除了20%的数据点，通过比较这些数据点的观测值和估计值来评价算法估计精度。

3.2　估计算法性能评估指标

本文选取衡量道路状态估计精度的指标包括

平均绝对误差(Mean absolute error,MAE)、均方根误差(Root mean square error,RMSE)、标准化平均误差(Normalized mean square error,NMSE),这3个误差指标越小,说明估计精度越高。RMSE、MAE及NMSE的计算公式分别为:

$$RMSE=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(s_i-\hat{s}_i)^2} \tag{8}$$

$$MAE=\frac{1}{n}\sum_{i=1}^{n}|s_i-\hat{s}_i| \tag{9}$$

$$NMSE=\frac{1}{\sum_{i=1}^{n}s_i^2}\sum_{i=1}^{n}(s_i-\hat{s}_i)^2 \tag{10}$$

式中:n为测试数据点的数量;s_i和$\hat{s}_i$分别为第i个速度点的观测值与估计值。

3.3 稀疏数据下的算法估计结果分析

本节讨论ED-TACNN在不同稀疏程度数据下的交通状态估计性能。此外,实验对比了ED-TACNN与普通CNN的交通状态估计,以验证本文提出算法的编码-解码结构对CNN交通估计精度的提升作用。

图5为ED-TACNN与CNN在不同稀疏度出租车数据集下交通状态估计的绝对误差箱线图。总体上,ED-TACNN的估计误差中位数与CNN相近(平均相差1.45 km/h),但其误差分布较CNN更为集中。实验结果表明ED-TACNN对CNN的改进能有效提升算法在稀疏数据下的估计精度。然而,随着数据采样率从55%下降到20%,ED-TACNN的交通状态估计MAE下降3.86 km/h,算法的估计精度在数据极端稀疏的情况下依然会受到影响。

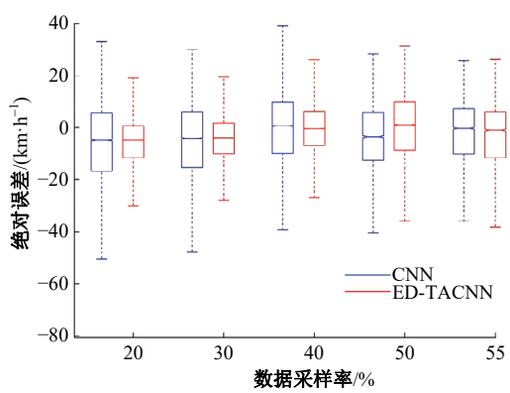

图5 不同稀疏程度数据下的ED-TACNN估计误差箱线图

Fig. 5 Boxplot of ED-TACNN estimation error under data with different sparsity levels

图6为在实验路段上,车辆平均速度的频率分布图。灰色区域为出租车数据观测的平均速度频率分布,黑色实线为由ED-TACNN算法估计的平均速度频率分布。图6(a)(b)分别为利用采样率30%和60%的出租车GPS数据观测和估计的平均速度频率分布结果。对比发现,在该实验路段上,车辆平均速度集中于20 km/h以下。此外,ED-TACNN估计的速度分布形态与观测分布大体一致,但会出现高速度的长尾,从而导致速度分布峰值的频率估计偏低。

3.4 不同算法对比与分析

实验将本文提出的方法与以往研究中常用的交通状态估计模型进行对比,以充分讨论ED-TACNN的有效性。对比方法包括:模糊C均值聚类(Fuzzy c means,FCM)[8]、低秩张量补全(Low-rank tensor completion,LRTC)[25]、双向长短时记忆网络(Bidirectional long short-term memory,BD-LSTM)[26]、基于并行数据的生成式对抗网络(Parallel data-based generative adversarial network,PD-GAN)[27]、行程时间填补生成

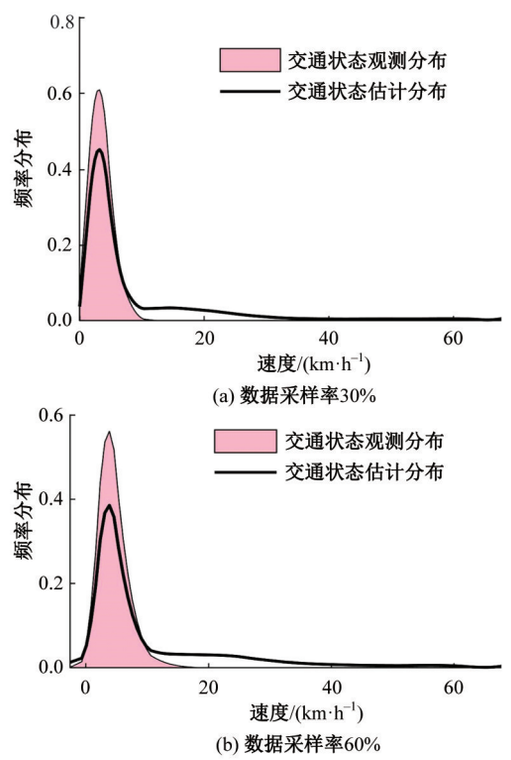

图6 出租车GPS观测的交通速度分布与ED-TACNN算法估计的交通速度分布图

Fig. 6 Traffic speed distribution observed by taxi GPS and estimated by ED-TACNN

式对抗网络（Travel times imputation generative adversarial network，TTI-GAN）[28]。

图 7 为上述算法在不同采样率的稀疏出租车 GPS 数据集上的交通状态估计误差。可以看出，ED-TACNN 的估计精度随数据采样率的增加而上升。与 BD-LSTM、PD-GAN、TTI-GAN 相比，ED-TACNN 在不同稀疏程度数据下的估计精度都更优，平均高 55.42% RMSE、57.02% MAE、83.58% NMSE。这展示了本文算法在应对稀疏数据时的优越性能。而与 FCM、LRTC 相比，ED-TACNN 在采样率为 20%、30% 数据下的 RMSE 和 MAE 更大（分别高 3.79、5.39 km/h），但 NMSE 小 0.34 km/h，表明 ED-TACNN 在数据极其稀疏的情况下，对交通特征的拟合程度更高，但估计的交通状态数据方差偏大。

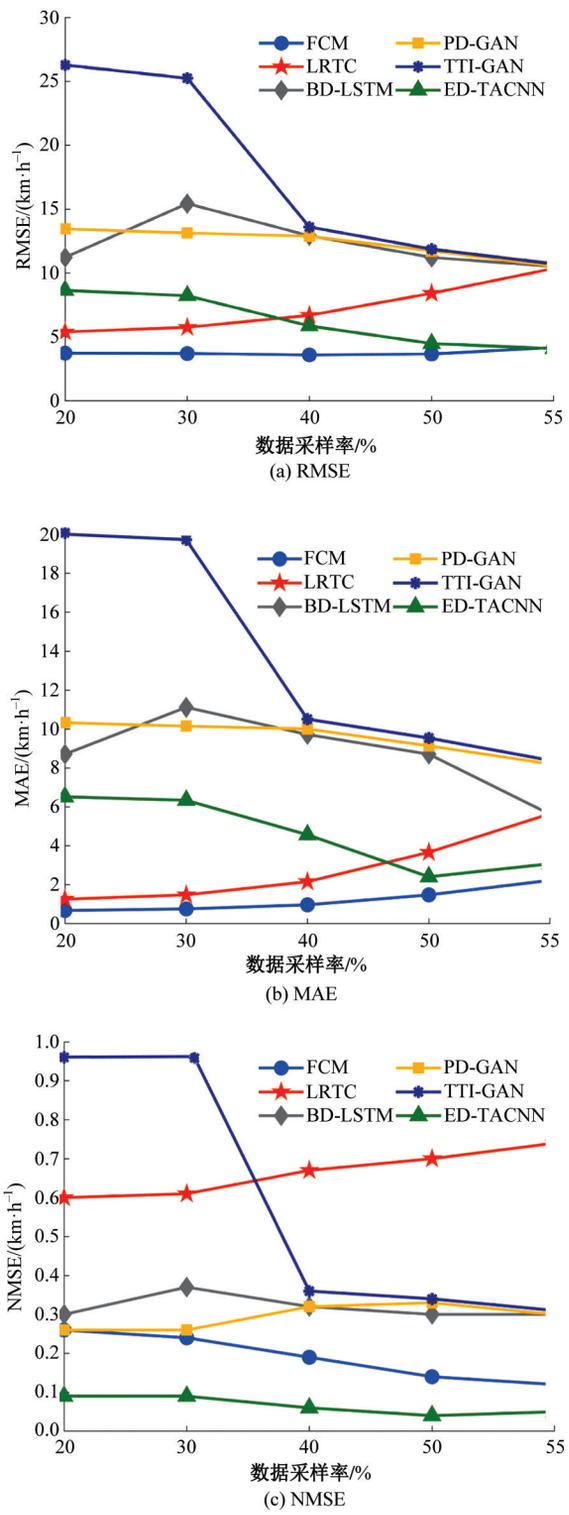

图 7　不同算法在稀疏数据下的交通状态估计精度对比

Fig. 7　Comparison of traffic state estimation accuracy between different algorithms in sparse data

3.5　不同交通情景下的算法估计结果分析

本节讨论本文算法在城市道路典型交通情景下的状态估计精度。具体地，实验选取了路段和信号交叉口情景，其中的交通状态分别具有连续交通流传播、信号控制下车流排队及释放等不同特征。

总体来看，ED-TACNN 在路段情景和信号交叉口情景下的状态估计精度相近，分别相差 3.34% RMSE、4.66% MAE。可以得出，ED-TACNN 的估计性能在不同的交通情景下具有一定的稳定性。但在数据采样率为 20% 和 30% 时，算法的估计精度有一定的下降，如表 1 所示。

图 8 为路段和交叉口情景下现有算法利用采样率为 50% 的稀疏出租车 GPS 数据估计交通状态的误差。ED-TACNN 算法在路段和交叉口情景下的估计误差最小，较其他算法分别平均低 0.92、0.57 km/h MAE。

表 1　ED-TACNN 在不同交通情景下的交通状态估计误差

Table 1　Traffic state estimation error of ED-TACNN under different traffic scenarios

交通情景	稀疏率 误差指标	20%	30%	40%	50%	55%
路段	RMSE	8.85	7.95	4.80	4.67	4.15
	MAE	6.77	6.18	3.71	2.60	3.06
	NMSE	0.12	0.10	0.05	0.05	0.05
交叉口	RMSE	9.02	8.74	5.20	4.67	3.84
	MAE	7.24	6.90	4.04	2.36	2.87
	NMSE	0.17	0.16	0.07	0.05	0.05

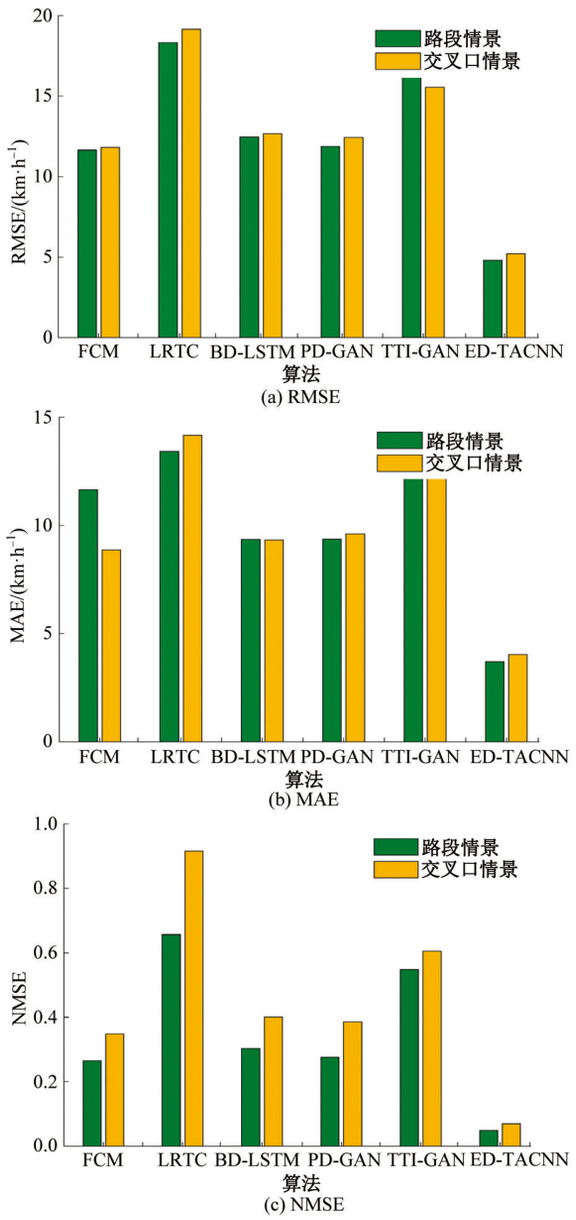

图8 不同交通情景下的各类算法估计误差对比

Fig. 8 Comparison of estimation error of various algorithms under different traffic scenarios

4 结 论

(1)本文提出了一种编码-解码结构的自适应卷积网络。首先,为有效从稀疏数据中提取交通特征,该网络构造一种交通特征编码CNN,通过下采样操作来聚合邻域关键特征。其次,为准确重构不同模式的交通状态,TACNN引入先验知识来引导卷积核形变,还原不同交通状态的时空结构。最后,利用长春市出租车GPS数据进行了实验验证。

(2)各类交通状态估计算法对比分析方面:本文提出的ED-TACNN与BD-LSTM、PD-GAN、TTI-GAN相比,估计精度提高了55.42% RMSE。在采样率为20%、30%的数据下,ED-TACNN与其他算法相比,数据拟合度更好但误差方差较大。总体而言,ED-TACNN对于提升深度学习在稀疏数据下的交通状态估计性能具有较大的潜力。

(3)算法在稀疏数据和不同交通情景下的估计性能方面:与基础CNN相比,本文提出的ED-TACNN在稀疏数据下的估计精度有所提升。此外,ED-TACNN在路段情景和信号交叉口情景下的状态估计精度相近,表明本文对CNN的改进在稀疏数据下的估计有效性及计算稳定性。

(4)未来的研究,还需进一步讨论分析先验知识中理想线性假设对交通状态估计的影响。同时,算法对交通状态模式的显式判别能更加准确地指导自适应卷积估计交通状态。

参考文献:

[1] Yu J J Q, Gu J. Real-time traffic speed estimation with graph convolutional generative autoencoder[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 20(10): 3940-3951.

[2] Zhang L, Chen T, Yu B, et al. Suburban demand responsive transit service with rental vehicles[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(4): 2391-2403.

[3] Li X, Wang T, Xu W, et al. A novel model for designing a demand-responsive connector (DRC) transit system with consideration of users' preferred time windows[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(4): 2442-2451.

[4] 田婧. 知识感知下的道路交通状态重构方法研究[D]. 长春: 吉林大学交通学院, 2023.
Tian Jing. Research on road traffic state reconstruction method in perspective of knowledge-aware[D]. Changchun: School of Transportation, Jilin University, 2023.

[5] Ahmed M S, Cook A R. Analysis of freeway traffic time-series data by using box-jenkins techniques[J]. Transportation Research Record, 1979, 722: 1-9.

[6] 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.

[7] 陈喜群,曹震,莫栋. 融合卡尔曼滤波的高速公路状态估计误差界限分析[J]. 交通运输系统工程与信息, 2022, 22(4): 72-78.

Chen Xi-qun, Cao Zhen, Mo Dong. Analyzing error bounds of highway traffic state estimation via Kalman filter fusion[J]. Journal of Transportation Systems Engineering and Information Technology, 2022, 22(4): 72-78.

[8] Tang J, Zhang G, Wang Y, et al. A hybrid approach to integrate fuzzy C-means based imputation method with genetic algorithm for missing traffic volume data estimation[J]. Transportation Research Part C: Emerging Technologies, 2015, 51(4): 29-40.

[9] 陈佳良,胡钊政,李飞. 基于时空特征序列匹配的交通流状态估计方法[J]. 交通信息与安全, 2021, 39(3): 68-76.
Chen Jia-liang, Hu Zhao-zheng, Li Fei. An estimation method of traffic flow state based on matching of temporal-spatial feature sequences[J]. Journal of Transport Information and Safety, 2021, 39(3): 68-76.

[10] Xiao J, Wei C, Liu Y. Speed estimation of traffic flow using multiple kernel support vector regression [J]. Physica A: Statistical Mechanics and its Applications, 2018, 509(11): 989-997.

[11] Chen X, He Z, Sun L. A bayesian tensor decomposition approach for spatiotemporal traffic data imputation [J]. Transportation Research Part C: Emerging Technologies, 2019, 98: 73-84.

[12] Tian Y, Zhang K, Li J, et al. LSTM-based traffic flow prediction with missing data[J]. Neurocomputing (Amsterdam), 2018, 318: 297-305.

[13] Zhang S, Zhou L, Chen X, et al. Network-wide traffic speed forecasting: 3D convolutional neural network with ensemble empirical mode decomposition[J]. Computer-Aided Civil and Infrastructure Engineering, 2020, 35(10): 1132-1147.

[14] Rempe F, Franeck P, Bogenberger K. On the estimation of traffic speeds with deep convolutional neural networks given probe data[J]. Transportation Research Part C: Emerging Technologies, 2022, 134(1): 103448.

[15] Ouafa B, Bilal T T, Hwasoo Y, et al. Traffic data imputation using deep convolutional neural networks [J]. IEEE Access, 2020, 8: 104740-104752.

[16] Dai J, Qi H, Xiong Y, et al. Deformable convolutional networks[C]//Proceeding of the IEEE International Conference on Computer Vision. Los Alamitos: IEEE Computer Society, 2017: 764-773.

[17] Zhu X, Hu H, Lin S, et al. Deformable convnets V2: More deformable, better results[C]//Proceeding of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society, 2020: 9300-9308.

[18] Doersch C. Tutorial on variational autoencoders[J]. Arxiv Preprint, 2016, 6: 160605908.

[19] Dilip D M, Freris N M, Jabari S E. Sparse estimation of travel time distributions using Gamma kernels [C]//Transportation Research Board 96th Annual Meeting. Washington: Transportation Research Board, 2017: 01628670.

[20] Jabari S E G, Dilip D M, Lin D, et al. Learning traffic flow dynamics using random fields[J]. IEEE Access, 2019, 7: 130566-130577.

[21] Treiber M, Kesting A, Wilson R E. Reconstructing the traffic state by fusion of heterogeneous data[J]. Computer-Aided Civil and Infrastructure Engineering, 2011, 26(6): 408-419.

[22] Scherer D, Müller A, Behnke S. Evaluation of pooling operations in convolutional architectures for object recognition[C]//Lecture Notes in Computer Science. Berlin: Springer, 2010: 92-101.

[23] Tan C P, Yao J R, Tang K S, et al. Cycle-based queue length estimation for signalized intersections using sparse vehicle trajectory data[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(1): 91-106.

[24] Masci J, Meier U, Ciresan D, et al. Stacked convolutional auto-encoders for hierarchical feature extraction[C]//Proceeding of the International Conference on Artificial Neural Networks. Berlin: Springer, 2011: 52-59.

[25] Chen X, Yang J, Sun L. A nonconvex low-rank tensor completion model for spatiotemporal traffic data imputation[J]. Transportation Research Part C: Emerging Technologies, 2020, 117(8): 102673.

[26] Cui Z, Ke R, Pu Z, et al. Stacked bidirectional and unidirectional LSTM recurrent neural network for forecasting network-wide traffic state with missing values[J]. Transportation Research Part C: Emerging Technologies, 2020, 118(9): 102674.

[27] Chen Y, Lv Y, Wang F Y. Traffic flow imputation using parallel data and generative adversarial networks [J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(4): 1624-1630.

[28] Zhang K, He Z, Zheng L, et al. A generative adversarial network for travel times imputation using trajectory data[J]. Computer-Aided Civil and Infrastructure Engineering, 2021, 36(2): 197-212.