

DOI:10.16544/j.cnki.cn43-1494/u.20251130003

文章编号:1674-599X(2026)02-0066-13

引用格式:陈博浩.融合交通流传播特性的城市路网短时交通流预测[J].交通科学与工程,2026,42(2):66-78.

Citation: CHEN Bohao. Short-term traffic flow prediction for urban road network incorporating traffic flow propagation characteristics[J]. Journal of Transport Science and Engineering, 2026, 42(2): 66-78.

# 融合交通流传播特性的城市路网短时交通流预测

陈博浩

(辽宁省交通运输事业发展中心,辽宁 沈阳 110005)

**摘要:**【目的】寻求一种数据利用效率较高、对交通流在路网中的传播机理可解释性较强的方法来解决城市路网短时交通流的预测问题。【方法】提出了一种融合交通流传播特性的城市路网短时交通流预测(NNLTM-TGAT)模型,以路段传输模型(LTM)为路网交通流模型,将传统不可微的交通流模型转化为可微的计算图,将交通流在路网中的传播机理融入计算图模型,并引入图注意力门控循环神经网络(GAT-GRU)模型提取城市路网交通流数据中时间和空间维度的特征信息,实现城市路网交叉口流向级的短时交通流预测。【结果】使用浙江省台州市中心城区部分路网的交通流量数据进行模型性能测试。结果表明,所提出的NNLTM-TGAT模型在早高峰、平峰、晚高峰场景下的流量均方根误差 $R_{RMSE}$ 分别为6.97、6.49、6.86辆/5 min,其预测性能均比对比模型的好。【结论】所提出的NNLTM-TGAT模型可以借助深度学习模型强大的高维时空建模能力与动态特征学习能力来提取原始数据中的时空特性,同时借助交通流传播机理的先验知识,在不同场景下取得较好的预测性能。

**关键词:**短时交通流预测;城市路网;路段传输模型;计算图;图注意力门控循环神经网络

中图分类号:U491.1

文献标志码:A

## Short-term traffic flow prediction for urban road network incorporating traffic flow propagation characteristics

CHEN Bohao

(Traffic and Transportation Enterprise Development Center of Liaoning Province, Shenyang 110005, China)

**Abstract:** [Purposes] This paper aims to seek a method with high data utilization efficiency and strong interpretability of the propagation mechanism of traffic flow in a road network to solve the short-term traffic flow prediction problem in urban road networks. [Methods] The paper proposed a short-term traffic flow prediction model for urban road networks (NNLTM-TGAT) that integrated traffic flow propagation characteristics. The model used the link transmission model (LTM) as the road network traffic flow model, converted the traditional non-differentiable traffic flow model into a differentiable computational graph, incorporated the propagation mechanism of traffic flow in the road network into the computational graph model, and introduced the graph attention gated recurrent neural network (GAT-GRU) model to extract feature information in the time and spatial dimensions from urban road network traffic flow data, achieving short-term traffic flow prediction at the intersection flow level in urban road networks. [Findings] The paper uses traffic flow data from a partial road network in the central urban area of Taizhou, Zhejiang Province for model performance testing. The results show that the NNLTM-TGAT model proposed in this paper achieves root mean squared error (RMSE) values of

收稿日期:2025-11-30

基金项目:国家自然科学基金项目(71971060)

通信作者:陈博浩(1999—),男,助理工程师,主要从事智慧交通管控技术等方面的研究工作。E-mail:3097247863@qq.com

投稿网址:https://jtkxygc.csust.edu.cn/jtkxygc/home

6.97 vehicle, 6.49 vehicle, and 6.86 vehicle for 5-minute flow prediction in morning peak, off-peak, and evening peak scenarios, respectively, outperforming the comparative models in prediction performance. [Conclusions] The NNLTM-TGAT model proposed in this paper can leverage the powerful high-dimensional spatiotemporal modeling capabilities and dynamic feature learning abilities of deep learning models to extract spatiotemporal characteristics from raw data and utilize the prior knowledge of traffic flow propagation mechanisms to achieve better prediction performance in different scenarios.

**Key words:** short-term traffic flow prediction; urban road network; link transmission model; computational graph; graph attention gated recurrent neural network

近年来,随着我国经济的快速发展和城市化进程的加快,我国机动车保有量持续上升。据公安部统计,2024年全国机动车保有量达4.53亿辆,其中汽车3.53亿辆<sup>[1]</sup>。在此背景下,城市道路的交通出行需求不断增加,城市交通拥堵等问题也随之进一步加剧。城市道路智能化管理与控制是解决城市交通问题的有效途径,有助于提高城市道路交通系统的运行效率。交通流预测是实现城市道路智能化管理与控制的重要内容,如果预测到拥堵即将发生,可以根据拥堵点所在的位置,向交通管理部门提供动态路径诱导、潮汐车道调整、交通管制、信号配时优化等建议,并通过导航App、可变信息板等方式发布拥堵路段信息、预计通行时间和绕行路径建议等。因此,准确、高效的交通流预测对于缓解城市交通拥堵、提高城市道路的交通运行效率具有重要意义。

既有的交通流预测方法主要分为交通流模型驱动的方法、数据驱动的方法、融合交通流模型与数据驱动的方法<sup>[2]</sup>。其中,交通流模型驱动的方法基于交通流模型中的先验知识和部分观测的交通状态对未来的交通流进行预测;数据驱动的方法以机器学习、深度学习方法为代表,通过从完备的历史观测数据中提取数据之间的相关性,然后根据这种相关性和实时观测数据对交通状态进行预测;近几年来,融合交通流模型与数据驱动的方法开始被深入研究,其将交通流模型驱动与数据驱动的优势结合起来平衡交通流预测的精度和数据利用效率。

LIGHTHILL等<sup>[3]</sup>、RICHARDS<sup>[4]</sup>在20世纪50年代提出了一阶LWR模型,这是宏观交通流建模中最具开创性的工作之一,该模型能够描述自由流和交通拥堵在路段中的传播特性、车辆守恒等基本的交通现象。在LWR模型中,描述交通状态的变量使用了密度,而在NEWELL<sup>[5]</sup>提出的简化运动波模型中,

描述交通状态的变量则使用了累积车辆数。DAGANZO<sup>[6-7]</sup>对LWR模型进行了时空离散化,并假设路段的流量-密度基本图符合三角形关系,提出了著名的元胞传输模型(CTM),它能较好地模拟道路上流量的变化。类似于元胞传输模型,YPERMAN<sup>[8]</sup>提出了路段传输模型(LTM),它将整个路段看成一个元胞,可以降低计算成本,并能在精确度与计算时间之间取得平衡。交通流模型驱动的方法可在输入数据较少的情况下对交通状态进行预测,具有清晰的物理内涵,可解释性强,但由于包含对现实交通流传播过程的简化假设,其预测精度不高。

数据驱动的交通流预测方法主要以基于机器学习和深度学习的方法为代表。近年来,深度学习方法因其强大的高维时空建模能力,成为路网交通流预测领域的研究热点。国内外学者相继提出了基于融合图卷积网络和门控循环单元(GCN-GRU)<sup>[9]</sup>等的代表性模型,这些研究以完备的路网交通状态数据为训练集,通常用于解决路网时空交通状态的预测问题。针对路网部分路段交通状态未知的问题,ZHANG等<sup>[10]</sup>提出了兼具缺失交通状态重构与预测功能的时空图卷积循环神经网络模型。ABDELRAOUF等<sup>[11]</sup>提出了一种基于深度学习的序列-序列架构Seq2 seq GCN-LSTM(LSTM为长短期记忆神经网络),其利用低渗透率探测车队收集的短期历史交通数据,来估计和预测全路网的流量和速度。张正超<sup>[12]</sup>以城市路网中的海量交通检测数据为基础,进行了缺失数据补全处理和多步交通状态的预测。吕阳<sup>[13]</sup>提出了一种针对路段交通量和平均速度的基于改进Att-ConvLSTM的短时交通拥堵预测模型框架,并在此基础上提出了短时交通拥堵等级预测模型。曾捷<sup>[14]</sup>开发了一种融合时序点过程与深度学习模型的轨迹链建模框架,设计了一种基于路网重构的有限布局条件下的交通流预测策

略,并提出了一种融合时序复杂网络与图神经网络的车道级交通流预测模型。雷斌等<sup>[15]</sup>提出了一种融合多源数据的基于多图时空图卷积模型的城市交通流长时预测模型,并提供了明确的分类依据来理解影响交通流的各种外部因素。石弘利<sup>[16]</sup>针对既有交通流预测方法建模空间关联单一以及预测精度低、效率失衡的问题,提出了时空双图交互式卷积网络(STDIGCN)模型。尽管以深度学习为代表的基于数据驱动的交通流预测方法可以取得传统交通流预测模型难以达到的精度,但是它严重依赖于大量的训练数据,缺乏对交通流传播机理的可解释性,针对数据量不足或者数据未覆盖的场景,其预测结果的可靠性不足。

融合交通流模型与数据驱动方法的研究来源于RAISSI等<sup>[17-18]</sup>提出的物理信息深度学习(physics-informed deep learning)范式,该范式旨在将物理模型中的机理信息嵌入深度学习模型中,使模型在训练数据不足的情况下,仍保持较好的泛化能力。陈喜群等<sup>[19]</sup>将路段传输模型与深度学习模型相结合,通过融合二者的输出结果实现了路段交通流状态的预测。JI等<sup>[20]</sup>提出了一种基于时空微分方程网络(STDEN)的物理引导深度学习模型。HUANG等<sup>[21]</sup>提出了一种新的基于物理信息的深度学习方法,该方法将交通流理论中的物理知识应用到深度学习神经网络中用于交通状态的重构,其在数据稀疏和含有数据噪声情况下的预测效果依然良好。LU等<sup>[22]</sup>提出了一个基于物理信息神经网络的高速公路交通状态和排队状态的联合估计框架。张杰<sup>[23]</sup>提出了一种融合交通领域知识与深度学习的城市快速路交通状态的估计与预测方法,在结合交通基本图模型(FD)的基础上,提出了基于交通基本图的时空图卷积网络(FDST-GCN)模型。

融合交通流模型与数据驱动的方法往往会遇到以下几个关键问题:1)如何将物理交通流模型转化为可微的计算图;2)如何设计交通流模型和数据驱动的结合机制;3)如何设计模型的损失函数,如何确定损失函数中各部分的权重。这些问题解决得好坏将对模型能否进行有效训练,以及训练效果的好坏产生影响。

既有的城市道路交通流预测研究按照空间层级可以划分为路段级和路网级。路段级交通流预测模型仅仅使用了路段内部的观测数据,对于多路段之间的观测约束以及车辆的路径选择考虑较少,

当路段内部观测数据充足时,其预测效果较好,但当路段内部观测数据不足时,其适应性较差;既有的路网级交通流预测模型往往对多源数据中所包含的交通状态信息的利用不够充分,存在信息损失,对于交通流在路网中传播规律的学习大多基于数据驱动,仅仅从数据的角度去寻找交通流的时空演化规律,模型参数的可解释性不强,且依赖于大量完整观测的训练数据,数据利用效率较低。

针对以上问题,本文提出了一种融合交通流传播特性的城市路网短时交通流预测(NNLTM-TGAT)模型,其以路段传输模型(LTM)为路网交通流模型,结合全连接神经网络模型,将传统不可微的交通流模型转化为可微的计算图,提高对观测数据中所包含的直接交通状态信息的利用效率;将交通流在路网中的传播机理融入计算图模型,增强模型参数的可解释性;借助计算图张量化、并行计算、自动微分的优势,提高模型参数的优化效率,并通过引入图注意力门控循环神经网络(GAT-GRU)模型提取城市路网交通流数据中时间和空间维度的特征信息,从而构建NNLTM-TGAT模型,实现城市路网交叉口流向级的短时交通流预测。针对路段传输模型时间离散、计算图在训练时梯度不能反向传播至叶子节点、待估参数无法得到有效训练的问题,本文采用了一种将全连接神经网络模型与路段传输模型组成串联式计算图框架的方法,即先将时间离散的历史累积入流、出流流量时序序列训练成为时间连续的历史累积入流、出流流量曲线,然后将时间连续的历史累积入流、出流流量曲线输入路段传输模型,进行计算图模型参数的训练。

## 1 问题描述

设城市路网图  $G = (P, E, A)$ , 其中  $P = \{p_1, p_2, \dots, p_n\}$  为城市路网中交叉口节点的集合;  $n$  为交叉口节点总数;  $E = \{(p_1, p_2), (p_1, p_3), \dots, (p_{m-1}, p_m)\}$  为城市路网中有向路段的集合;  $m$  为城市路网中有向路段的条数;  $A$  为城市路网的邻接矩阵,其元素可表示为:

$$A(i, j) = \begin{cases} 1 & p_i, p_j \in P; (p_i, p_j) \in E \\ 0 & \text{其他} \end{cases} \quad (1)$$

城市路网短时交通流预测的目标是找到一个能将  $T$  个历史时刻的城市路网交通流量数据映射到

$T'$ 个未来时刻的城市路网交通流量数据的函数,即:

$$[X_{t-T+1}, X_{t-T+2}, \dots, X_t] = f([X_{t+1}, X_{t+2}, \dots, X_{t+T'}], G) \quad (2)$$

式中: $X_t$ 为 $t$ 时刻在城市路网中各有向路段之间传输的交通流量矩阵,维度为 $m \times m$ ;  $f$ 为映射函数。

## 2 模型结构

### 2.1 LTM模型基本框架

路段传输模型(LTM)由YPERMAN<sup>[8]</sup>提出,是一种动态网络加载模型,可较为真实地刻画大规模交通路网中的交通流传播现象。类似于元胞传输模型,它将整个路段看成一个元胞,由路段模型和节点模型组成,将时间离散化处理。其中,路段模型用于确定路网中每个路段在每一时刻的发送能力和接收能力;节点模型用于计算路网中每一时刻每一对直接相连的路段间传输的流量,并对路网中每个路段到达和离去的累积流量进行更新。路段传输模型假设路段的流量-密度基本图符合三角形关系,采用由NEWELL<sup>[5]</sup>简化得到的交通波理论计算路网中每个路段在每一时刻发送和接收的流量。

在由NEWELL<sup>[5]</sup>简化得到的交通波理论中,假设只存在自由流和排队拥堵这两种交通流状态,并分别用自由流速度 $v_f$ 和反向波速度 $w_r$ 来描述,如图1所示。图1中, $q$ 为通行能力, $q_M$ 为最大通行能力, $k_c$ 为临界密度, $k$ 为密度。城市路网中不同路段的基本图不尽相同,需要通过历史数据来拟合每个路段的三角形基本图以获得相应的参数,如自由流速度 $v_f$ 、反向波速度 $w_r$ 、阻塞密度 $k_{jam}$ 等。




图1 简化的流量-密度三角形基本图

Fig. 1 Simplified flow-density triangular fundamental diagram

假设路段 $i$ 的下游连接了接收容量无限大的路段(未被施加任何约束),则定义路段 $i$ 在 $t$ 时刻的发送能力 $S_i(t)$ 为时间段 $[t, t + \Delta t]$ 内能离开该路段下游的最大流量,同时也是该时间段内路段 $i$ 的排队车辆数。根据交通波理论和路段上下游两个端点之间交通状态的一致性,有:

$$S_i(t) = \min \{ N(x_{i,0}, t + \Delta t - L_i/v_i) - N(x_{i,L_i}, t), q_{i,L_i}(t)\Delta t \} \quad (3)$$

式中: $x_{i,0}$ 为路段 $i$ 的入流位置; $L_i$ 为路段 $i$ 的长度; $x_{i,L_i}$ 为路段 $i$ 的出流位置; $q_{i,L_i}(t)$ 为路段 $i$ 在 $t$ 时刻的最大出流流率; $N(x_{i,L_i}, t)$ 为 $t$ 时刻路段 $i$ 出流位置的累积车辆数; $v_i$ 为路段 $i$ 的自由流速度。

同理,假设路段 $j$ 的上游连接了发送容量无限大的路段(未被施加任何约束),路段 $j$ 在 $t$ 时刻的接收能力 $R_j(t)$ 可以定义为时间段 $[t, t + \Delta t]$ 内能进入路段 $j$ 上游的最大流量。根据交通波理论和路段上下游两个端点之间交通状态的一致性,有:

$$R_j(t) = \min \{ N(x_{j,L_j}, t + \Delta t - L_j/w_j) + k_{j,j}L_j - N(x_{j,0}, t), q_{j,0}(t)\Delta t \} \quad (4)$$

式中: $w_j$ 为路段 $j$ 的反向波速度; $k_{j,j}$ 为路段 $j$ 的阻塞密度; $q_{j,0}(t)$ 为路段 $j$ 在 $t$ 时刻的最大入流流率。

城市路网中的信号交叉口可以被看成是多进多出的节点,忽略车辆在交叉口的行驶时间,则在每一时刻驶入同一交叉口的总流量与驶出该交叉口的总流量是相等的。

路网中各相连路段之间当前时刻的传输流量由该流向的发送能力、接收能力、实时通行能力、实时信号灯态共同确定。考虑到城市道路交叉口的间断流场景,如果当前时刻该流向的信号灯态为红灯,那么该流向当前时刻的实时通行能力为0。路段 $i$ 流向路段 $j$ 的发送能力 $S_{ij}(t)$ 需要由历史数据确定的转向比参数 $\alpha_{ij}(t)$ 和路段 $i$ 的发送能力 $S_i(t)$ 共同确定<sup>[24]</sup>,路段 $j$ 接收来自路段 $i$ 流量的接收能力 $R_{ij}(t)$ 也需要由接收比例系数 $\beta_{ij}(t)$ 和路段 $j$ 的接收能力 $R_j(t)$ 共同确定<sup>[25]</sup>。

$$S_{ij}(t) = S_i(t)\alpha_{ij}(t) \quad (5)$$

$$R_{ij}(t) = R_j(t)\beta_{ij}(t) \quad (6)$$

$$f_{ij}(t) = \min \{ S_{ij}(t), R_{ij}(t), q_{ij}(t) \} \quad (7)$$

式中: $f_{ij}(t)$ 为 $t$ 时刻的传输流量; $q_{ij}(t)$ 为 $t$ 时刻的实时通行能力。

根据路段模型和节点模型计算得到当前时刻

路网中各相连路段之间的传输流量后,进一步更新各路段的入流和出流累积流量:

$$N(x_{i,0}, t + \Delta t) = N(x_{i,0}, t) + \sum_{i \in I_n} f_{ij}(t) \quad (8)$$

$$N(x_{j,L_j}, t + \Delta t) = N(x_{j,L_j}, t) + \sum_{j \in J_n} f_{ij}(t) \quad (9)$$

式(8)~(9)中: $I_n$ 为流量流入交叉口节点的路段集合; $J_n$ 为流量流出交叉口节点的路段集合,如图2所示。




图2 城市路网交叉口节点简化示意图

Fig. 2 Simplified node schematic diagram of urban road network intersections

### 2.2 计算图化的路段传输模型

计算图是一种直观描述计算过程的数据结构,在深度学习中扮演着十分重要的角色。计算图被定义为有向图,由节点和边构成,其中节点表示变量,边表示某种运算或操作。计算图模型的训练过程就是计算图的正向传播和反向传播过程。在正向传播过程中,数据从各个叶子节点开始,沿着有向边进行相应的运算或操作,直至根节点,最终得到模型的输出结果;在反向传播过程中,计算图模型根据模型输出结果与真实值之间的误差,从根节点向叶子节点逐步计算损失误差关于相关参数或变量的梯度。在得到所有叶子节点的梯度之后,选用合适的优化算法对参数进行更新优化,基于优化后的参数,再次进行正向传播计算损失误差,由此循环往复地进行正向传播和反向传播,直至损失误差满足精度要求。

由于路段传输模型是在离散时间下进行计算的,即只能计算得到 $t + M\Delta t$ (其中 $M$ 为正整数)时刻路网各个路段的入流与出流累积流量。离散时间片会导致计算图在误差反向传播过程中梯度无法反向传播到计算图中的叶子节点,从而使路段传输模型计算图中的待估参数无法得到有效的训练。

为了可以计算得到路网内各个流向在任意历史时刻的累积流量,需要对离散时间片进行连续化处理,将路网内各个流向的入流和出流累积流量看成时间的函数。构建两个全连接神经网络模型分别对路网中各个流向的入流、出流累积流量时间序列进行拟合训练。将时间离散的累积流量时间序列转化为时间连续的累积流量曲线,训练时全连接神经网络模型的输入为历史时间片内的时间步序号,输出为每个时间步所对应的流向到达和离去的累积流量,输入和输出的维度均为路网中流向的个数,训练的样本个数为历史时间片的时间步数 $T$ 。

用路段传输模型计算每个时间步路段间的传输流量,路段传输模型中的待估参数为路网中每个时间片内的自由流速度向量 $v$ 、反向波速度向量 $w$ 、阻塞密度向量 $k_j$ ,这些待估参数的值在每个时间片内保持不变。计算图如图3所示。图3中,实线箭头表示正向传播过程,虚线箭头表示误差反向传播至待估参数的过程; $S_{ij}^{\tau=t}$ 为 $t$ 时刻路段 $i$ 流向路段 $j$ 的发送能力矩阵; $\alpha_{ij}^{\tau < t}$ 为 $t$ 时刻之前流向 $ij$ 的转向比张量; $N_{i,in}^{\tau < t}$ 为 $t$ 时刻之前路段 $i$ 的累积流入流量张量; $N_{i,out}^{\tau < t}$ 为 $t$ 时刻之前路段 $i$ 的累积流出流量张量; $R_j^{\tau=t}$ 为 $t$ 时刻路段 $j$ 对于路段 $i$ 的接收能力矩阵; $\beta_{ij}^{\tau=t}$ 为 $t$ 时刻流向 $ij$ 的接收比张量; $R_i^{\tau=t}$ 为 $t$ 时刻路段 $i$ 的接收能力向量; $u_{ij}^{\tau=t}$ 为流向 $ij$ 在 $t$ 时刻的相位绿信比矩阵; $q_{ij}^{\tau=t}$ 为流向 $ij$ 在 $t$ 时刻的通行能力矩阵; $f_{ij,out}^{\tau=t}$ 为 $t$ 时刻由路段 $i$ 流向路段 $j$ 的流量矩阵; $\odot$ 表示哈达玛乘积,即将两个张量对应位置的元素相乘; $n_i^{\tau=0}$ 为路段 $i$ 的初始车辆数向量; $f_{\min}(\cdot)$ 表示将多个张量对应位置的元素取最小值的运算。

图4所示为路段传输模型计算图的训练流程。为了保证在计算图训练过程中NNLTM参数的可识别性与物理合理性,本文采用重参数化方法对NNLTM计算图中的待估参数施加约束。

对于自由流速度 $v$ ,设置一个合理的上下限 $v_{\max}$ 、 $v_{\min}$ ,通过sigmoid激活函数变换将 $v'$ 的取值范围控制在 $(v_{\min}, v_{\max})$ 内:

$$v' = v_{\min} + (v_{\max} - v_{\min}) \text{sigmoid}(v) \quad (10)$$

在本文中,将 $v_{\min}$ 设置为10 m/s, $v_{\max}$ 则由各路段的限速确定,一般取20 m/s。这样,无论如何优化 $v$ ,始终可以将 $v'$ 的取值控制在 $(v_{\min}, v_{\max})$ 内。

同样,对于阻塞密度 $k_{jam}$ ,也设置一个合理的上下限 $k_{j,\max}$ 和 $k_{j,\min}$ ,通过sigmoid激活函数变换将 $k'_{jam}$

的取值范围控制在  $(k_{j\_min}, k_{j\_max})$  内:

$$k'_{jam} = k_{j\_min} + (k_{j\_max} - k_{j\_min}) \text{sigmoid}(k_{jam}) \quad (11)$$

阻塞密度  $k_{jam}$  的取值通常与车道内车辆的平均长度、相邻车辆之间的安全距离有关。在本文中,将  $k_{j\_min}$  设置为 0.11 辆/m,将  $k_{j\_max}$  设置为 0.15 辆/m。这样,无论  $k_{jam}$  如何优化,可以始终将  $k'_{jam}$  的取值范围控制在  $(k_{j\_min}, k_{j\_max})$  内。

对于反向波速度向量  $w$ ,需要通过设置比例系数  $r$  来构建它与自由流速度向量  $v$  之间的比例关系,同时要对比例系数  $r$  进行 sigmoid 激活函数变换得到  $r'$ ,并设置合理的上下限  $r_{max}$  和  $r_{min}$ ,将  $r'$  的取值控制

在  $(r_{min}, r_{max})$  内:

$$r' = r_{min} + (r_{max} - r_{min}) \text{sigmoid}(r) \quad (12)$$

$$w = r'v \quad (13)$$

在本文中,将  $r_{min}$  设置为 0.2,将  $r_{max}$  设置为 0.5。

至此,传统不可微的路段传输模型与全连接神经网络模型共同组成了串联式的计算图框架,实现了两部分参数的集成学习,该计算图模型(NNLTM)的整体训练流程如下:

步骤 1:进入研究时段内的第一个时间片  $T_{s,1}$ 。

步骤 2:初始化当前时间片  $T_{s,i}$  下的计算图模型参数  $\lambda_m, \lambda_{LTM}$ ,以及优化器的超参数。

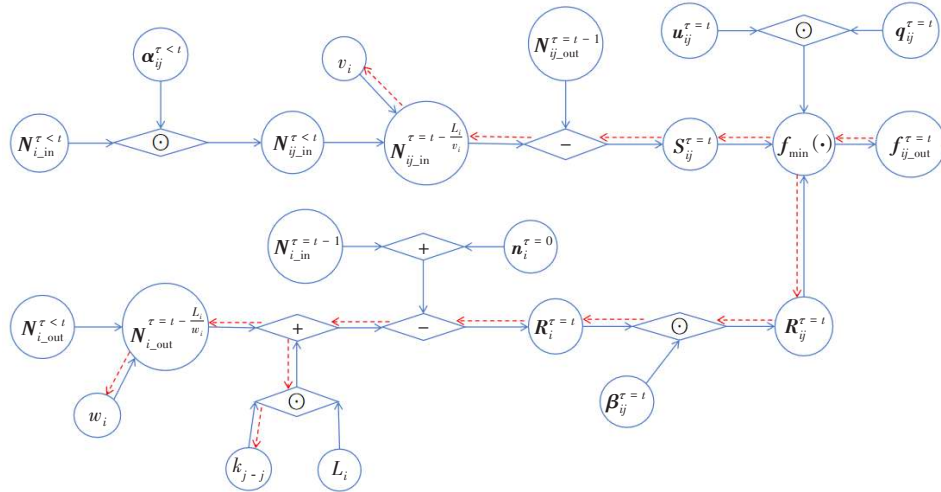


图 3 路段传输模型计算图

Fig. 3 Computational graph of link transmission model

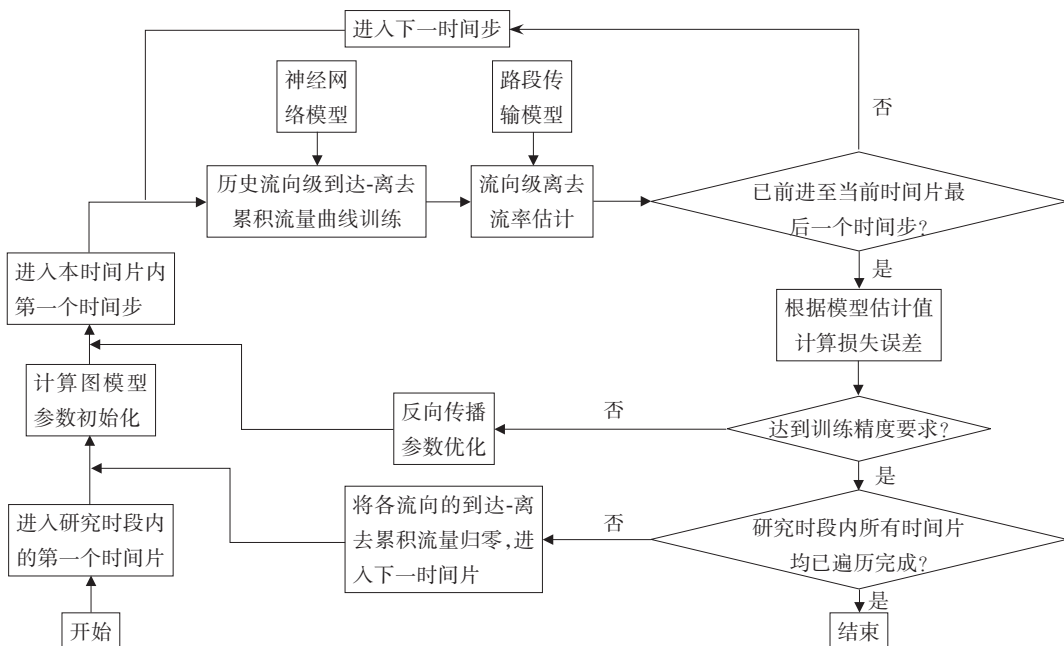


图 4 路段传输模型计算图的训练流程

Fig. 4 Training process of computational graph for link transmission model

步骤3:进入当前时间片  $T_{s,i}$  内的第一个时间步  $t_1$ 。

步骤4:使用全连接神经网络模型对当前时间步  $t_j$  的前15 min 流向级离去与到达流量累积曲线进行拟合训练。

步骤5:根据NNLTM计算图模型计算当前时间步  $t_j$  下各流向的离去流量。

步骤6:若已前进至当前时间片  $T_{s,i}$  内的最后一个时间步,进入步骤7;否则进入下一时间步  $t_{j+1}$ ,返回步骤4。

步骤7:根据NNLTM计算图模型在当前时间片  $T_{s,i}$  内每个时间步的各流向离去流量估计值,更新各流向在当前时间片  $T_{s,i}$  内的到达与离去流量曲线。

步骤8:计算当前时间片  $T_{s,i}$  下NNLTM计算图模型的输出与可观测位置的真实值之间的误差,求和得到总的损失函数值  $f_{loss}$ 。

步骤9:进行当前时间片  $T_{s,i}$  下NNLTM计算图模型误差的反向传播,并更新NNLTM计算图模型的参数。

步骤10:若已达到训练精度要求或最大训练次数,训练结束,得到当前时间片  $T_{s,i}$  下的NNLTM计算图模型参数及所有欠观测位置的交通状态,进入步骤11;否则返回步骤3,继续进行下一轮训练。

步骤11:若研究时段内所有时间片均已遍历完成,训练流程结束;否则将当前时间片  $T_{s,i}$  各流向起始时间步的到达、离去累积流量归零,进入下一时间片  $T_{s,i+1}$ ,返回步骤2。

### 2.3 注意力神经网络

对传输流量张量  $X_{ij}$  的流入维求和,得到路网中每个路段的流出流量张量  $X_{out}$ :

$$X_{out} = \{X_{out,1}, X_{out,2}, \dots, X_{out,m}\} \quad (14)$$

式中: $X_{out,i}$  为元素个数为  $N_1$  的向量; $N_1$  为交通流时间序列中数据的个数; $m$  为路网中有向路段的个数。

路段  $i, j$  流出流量之间的注意力系数  $e_{ij}$  为:

$$e_{ij} = a(W_{out} X_{out,i}, W_{out} X_{out,j}) \quad (15)$$

式中: $W_{out}$  为  $N' \times N$  的矩阵; $a$  表示路网中所有路段共享的自注意力机制,是一个单层前馈神经网络,计算方法如下:

$$e_{ij} = \text{LeakyReLU}(a^T [W_{out} X_{out,i} \parallel W_{out} X_{out,j}]) \quad (16)$$

式中: $a$  为权重向量; $\parallel$  为拼接操作;LeakyReLU为激活函数。

利用 softmax 函数对路网中所有相连路段的注

意力进行归一化,归一化后的注意力权重系数不再具有对称性:

$$a_{ij} = \text{softmax}(e_{ij}) \quad (17)$$

使用归一化后的注意力权重系数对路段间的传输流量进行更新:

$$X'_{ij} = \sigma(a_{ij} W'_{out} X_{out}) \quad (18)$$

式中: $\sigma$  为 sigmoid 激活函数。

### 2.4 门控循环单元

GRU是LSTM的变体,它有两个门,分别是重置门和更新门。其中,重置门控制上一时刻的隐藏状态在当前时刻的信息重置程度,更新门决定上一时刻的隐藏状态和当前时刻新候选状态的权重比例,将新旧信息加权平均之后作为输出。

$$r_t = \sigma(W_r [X_t, h_{t-1}] + b_r) \quad (19)$$

$$z_t = \sigma(W_z [X_t, h_{t-1}] + b_z) \quad (20)$$

$$\tilde{h}_t = \tanh(W_h [X_t, (r_t h_{t-1})] + b_h) \quad (21)$$

$$h_t = z_t h_{t-1} + (1 - z_t) \tilde{h}_t \quad (22)$$

式(19)~(22)中: $X_t$  为在  $t$  时刻的交通流量,在输入前由二维展平为一维; $h_t$  为  $t$  时刻隐藏状态的输出; $\tilde{h}_t$  为  $t-1$  时刻的候选隐藏状态; $W_r, W_z, W_h$  均为权重系数矩阵; $b_r, b_z, b_h$  为对应的偏置张量。

### 2.5 损失函数构建

用  $F_{nn}, F_{LTM}, F_{TGAT}$  分别表示全连接神经网络模型、路段传输模型和GAT-GRU模型,  $\lambda_{nn}, \lambda_{LTM}, \lambda_{TGAT}$  为对应模型中的待估参数。用  $\ell_1$  表示流量状态可观测的路段或流向,  $\ell_2$  表示流量状态不可观测的路段或流向。

全连接神经网络模型在某历史时刻在流量可观测流向离去和到达的累积流量的损失函数为:

$$M_{SE,1} = \frac{1}{|\ell_1|} \sum_{\ell_1} \sum_{\tau \leq t} [N_{i \in \ell_1}^\tau - F_{nn}(\hat{N}_{i \in \ell_1}^\tau | \lambda_{nn})]^2 \quad (23)$$

LTM模型在当前时刻在流量可观测流向离去流量的损失函数为:

$$M_{SE,2} = \frac{1}{|\ell_1|} \sum_{\ell_1} [f_{i \in \ell_1}^t - F_{LTM}(\tilde{f}_{i \in \ell_1}^t | \lambda_{LTM}, \lambda_{nn})]^2 \quad (24)$$

GAT-GRU模型在当前时刻在流量可观测流向离去流量的损失函数为:

$$M_{SE,3} = \frac{1}{|\ell_1|} \sum_{\ell_1} [f_{i \in \ell_1}^t - F_{TGAT}(\tilde{f}_{i \in \ell_1}^t | \lambda_{TGAT})]^2 \quad (25)$$

在流量不可观测流向,对NNLTM和GAT-GRU模型进行内部校核的损失函数为:

$$M_{SE,4} = \frac{1}{|\ell_2|} \sum_{\ell_2} [F_{LTM}(\tilde{f}_{i \in \ell_2} | \lambda_{LTM}, \lambda_m) - F_{TGAT}(\tilde{f}_{i \in \ell_2} | \lambda_{TGAT})]^2 \quad (26)$$

则NNLTM-TGAT模型的综合损失函数为:

$$f_{loss} = M_1 M_{SE,1} + M_2 M_{SE,2} + M_3 M_{SE,3} + M_4 M_{SE,4} \quad (27)$$

式中: $M_1, M_2, M_3, M_4$ 均为损失函数的权重,满足:

$$M_1 + M_2 + M_3 + M_4 = 1 \quad (28)$$

NNLTM-TGAT模型综合损失函数的示意图见图5,其中,全连接神经网络模型与LTM模型为串联关系,NNLTM模型与GAT-GRU模型为并联关系。

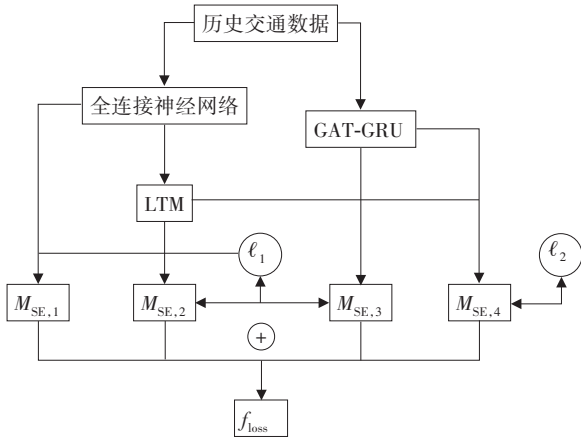


图5 模型综合损失函数示意图

Fig. 5 Schematic diagram of comprehensive loss function of the model

### 3 试验

#### 3.1 测试路网与测试数据

考虑到在进行模型测试验证时,需要评估模型在不同交通状况下的性能表现,因此测试路网需要具备以下特点:1)存在早晚高峰现象和拥堵区域;2)需要覆盖一定的空间范围;3)路网中需要具有较为完整、密集、运行状况良好的车辆号牌检测设备,为研究提供数据支撑。因此,本文选用浙江省台州市中心城区的部分路网作为研究对象。在QGIS的openstreetmap图层中导入研究区域各广义交叉口的经纬度坐标并进行可视化,如图6所示。

研究区域的路网覆盖面积约为17 km<sup>2</sup>,西起台州市中心大道,东至疏港大道,南起开发大道,北至云西路,东西向覆盖了云西路、市府大道、东海大道、开发大道、解放南路五条主干路和枫南路、体育场路、东平路三条次干路以及若干条支路,南北向覆盖了中心大道、东环大道、疏港大道三条主干路

和白云山路、机场路、广场南路、岩屿路四条次干路以及若干条支路,共包含79个广义交叉口(图6中红色圆点)。

本文使用的是2023年10月23日至2023年10月29日浙江省台州市中心城区的车辆号牌数据。卡口设备产生的车辆号牌识别数据在交通流预测中的应用十分广泛。通过车辆号牌识别数据可得到三方面信息:第一,在装有卡口设备的路段或交叉口,摄像机记录了通过该位置车辆完整精确的时间戳;第二,通过车辆号牌识别数据可统计通过该位置的交通流量信息;第三,车辆号牌识别数据还可提供时空关联信息,通过对号牌识别数据的匹配,可在上下游交叉口之间跟踪同一车辆的行驶情况。

对车辆号牌识别数据进行预处理,剔除重复和无效的车辆号牌识别数据,然后通过匹配指定时间段内上下游交叉口的车辆号牌识别数据,得到该时段内所研究路网中各个流向的交通流量。




图6 测试路网

Fig. 6 Test link network

#### 3.2 性能评价指标

本文采用平均绝对误差 $R_{MAE}$ 、均方根对数误差 $R_{RMSLE}$ 、均方根误差 $R_{RMSE}$ 评价模型的预测性能。

$$R_{MAE} = \frac{1}{NT'} \sum_{i=1}^N \sum_{t=1}^{T'} |\hat{X}_i - X_i| \quad (29)$$

$$R_{RMSLE} = \sqrt{\frac{1}{NT'} \sum_{i=1}^N \sum_{t=1}^{T'} \left[ \ln \left( \frac{\hat{X}_i + \epsilon}{X_i + \epsilon} \right) \right]^2} \quad (30)$$

$$R_{\text{RMSE}} = \sqrt{\frac{1}{NT'} \sum_{i=1}^N \sum_{t=1}^{T'} (\hat{X}_i - X_i)^2} \quad (31)$$

式(29)~(31)中: $\hat{X}_i$ 为交通流预测值; $X_i$ 为交通流真实值; $N$ 为交通流时间序列中数据的个数; $T'$ 为预测的时间步数; $\epsilon$ 是为了保证分母不为0而设置的平滑项,在本文中取为1。

### 3.3 试验设置

本文使用Python软件进行数据处理和模型求解分析,使用深度学习框架PyTorch构建动态计算图。在正向传播过程中,每条运算语句都会在计算图中动态地添加节点和边,并立即执行正向传播得到计算结果,无需等待计算图创建完毕;在反向传播后立即销毁计算图,在下次调用时需要重新构建计算图。反向传播的误差项通过优化算法中的学习率进行调节,误差项被传递给计算图模型中的每个待估参数,从而更新计算图模型中每个待估参数的值,减小误差。学习率决定了每轮更新时各个参数的调整幅度,即在每次迭代中各个参数沿着负梯度方向调整步长的大小。

按照80%和20%的比例将交通流量数据划分为训练集和测试集。在训练过程中模型基于 $R_{\text{MAE}}$ 对参数进行更新。将初始学习率 $l_i$ 设置为0.001,将dropout层的丢弃率设置为0.1,在训练过程中使用Adam优化器动态调整学习率的大小,将GAT和GRU的层数均设置为1层。

### 3.4 试验结果分析

NNLTM计算图模型的预测精度可能会受时间窗长度的影响。本文设计了几组对比试验来测试时间窗长度的敏感性。不同时间窗参数组合下模型预测性能的对比见表1。

表1 不同时间窗参数组合下模型预测性能对比

Table 1 Comparison of model prediction performance under different combinations of time window parameters

序号	时间窗组合			误差/[辆·(5 min) <sup>-1</sup> ]		
	$T_u/\text{min}$	$\Delta T/\text{s}$	$T_p/\text{min}$	$R_{\text{MAE}}$	$R_{\text{RMSE}}$	$R_{\text{RMSE}}$
1	5	2	5	15.18	0.45	19.14
2	15	2	5	13.95	0.42	17.86
3	30	2	5	13.92	0.42	17.81
4	15	6	5	17.69	0.51	22.03
5	15	10	5	23.04	0.58	28.57
6	15	2	10	14.07	0.43	17.98
7	15	2	15	14.21	0.44	18.19

注: $T_u$ 为训练时间片长度; $\Delta T$ 为更新时间窗长度; $T_p$ 为预测时间窗长度

由表1可知,训练时间片长度 $T_u$ 过小会造成模型欠学习,影响城市路网交通流预测精度,而当 $T_u$ 达到一定值后,即使再继续增大,模型的预测精度也没有明显提升;预测时间窗长度 $T_p$ 越大,模型的预测误差越大;更新时间窗长度 $\Delta t$ 越大,累积车辆数更新的精细化程度越低,模型的预测误差越大。因此,本文选择第2种时间窗参数组合( $T_u=15 \text{ min}$ ,  $\Delta t=2 \text{ s}$ ,  $T_p=5 \text{ min}$ )作为最优参数组合。

研究区域路网早高峰、平峰和晚高峰某15 min时段,部分上下游流量可观测路段NNLTM计算图模型的参数估计结果见表2。

本文采用历史平均模型(HA)、自回归移动平均模型(ARIMA)、图注意力神经网络模型(GAT-GRU)、长短期记忆网络模型(LSTM)、计算图化的路段传输模型(NNLTM)作为与本文提出的NNLTM-TGAT模型的对比模型。各个模型在早高峰、平峰、晚高峰时段的预测性能对比见表3。

由表3可知,NNLTM-TGAT模型在早高峰、平峰、晚高峰场景下的 $R_{\text{RMSE}}$ 分别为6.97、6.49、6.86辆/5 min,预测性能均对比模型的好。与其他对比模型相比,NNLTM模型尽管有效地结合了全连接神经网络模型,但是其预测精度仍然有所欠缺。这是由于NNLTM模型融合了交通流的传播机理,包含对现实交通流传播过程的简化假设,限制较多。尽管NNLTM模型的预测精度有所欠缺,但是NNLTM-TGAT模型可以借助深度学习模型强大的高维时空建模能力与动态特征学习能力提取原始数据中的时空特性,在NNLTM模型的基础上对预测结果进行进一步校准,通过两部分的融合,提高了城市路网短时交通流的预测精度。通过NNLTM-TGAT模型与GAT-GRU模型流量预测效果的对比也可以看出融合的有效性。混合模型具备融合交通流传播机理的优势,可以推演路段间交通流的交互过程,增加模型的可解释性。对于一些突发事件(如占道施工、交通事故等)的场景,由于训练数据量不足,深度学习模型的预测性能会受到一定的影响。但NNLTM模型仍然可以通过交通流传播机理的先验知识实现这些场景下的模拟推演,从而保持较好的预测性能。与早晚高峰时段相比,在平峰时段模型的预测性能更好。

NNLTM-TGAT模型针对多步预测任务的测试误差见表4。由表4可知,随着预测步数的增加,预测误差呈稳步上升趋势,但是增幅较小。

表 2 部分上下游流量可观测路段模型参数估计结果

Table 2 Estimation results of model parameters for some links with observable upstream and downstream traffic flow

路段名称	上游交叉口	下游交叉口	时间段	早晚高峰及平峰	$v_f/(m \cdot s^{-1})$	$w_f/(m \cdot s^{-1})$	$k_{jam}/(辆 \cdot m^{-1})$
市府大道	市府大道-东环大道	市府大道-经中路	8:00—8:15	早高峰	9.847	3.156	0.127
中心大道	市府大道-中心大道	中心大道-广场西路	8:00—8:15	早高峰	9.679	3.204	0.128
开发大道	开发大道-经东路	开发大道-疏港大道	8:00—8:15	早高峰	10.128	3.171	0.125
市府大道	市府大道-东环大道	市府大道-经中路	10:00—10:15	平峰	11.786	3.012	0.126
中心大道	市府大道-中心大道	中心大道-广场西路	10:00—10:15	平峰	11.697	3.008	0.121
开发大道	开发大道-经东路	开发大道-疏港大道	10:00—10:15	平峰	12.185	2.997	0.123
市府大道	市府大道-东环大道	市府大道-经中路	18:00—18:15	晚高峰	9.765	3.165	0.127
中心大道	市府大道-中心大道	中心大道-广场西路	18:00—18:15	晚高峰	9.827	3.189	0.128
开发大道	开发大道-经东路	开发大道-疏港大道	18:00—18:15	晚高峰	10.244	3.225	0.128

表 3 不同模型交通流量预测性能对比

Table 3 Prediction performance comparison of traffic flow among different models

模型	误差(早高峰)/[辆·(5 min) <sup>-1</sup> ]			误差(平峰)/[辆·(5 min) <sup>-1</sup> ]			误差(晚高峰)/[辆·(5 min) <sup>-1</sup> ]		
	$R_{MAE}$	$R_{RMSLE}$	$R_{RMSE}$	$R_{MAE}$	$R_{RMSLE}$	$R_{RMSE}$	$R_{MAE}$	$R_{RMSLE}$	$R_{RMSE}$
NNLTM-TGAT	5.35	0.27	6.97	4.84	0.24	6.49	5.23	0.26	6.86
NNLTM	14.47	0.44	18.35	13.41	0.41	17.12	14.36	0.43	18.23
GAT-GRU	5.46	0.31	7.19	5.09	0.28	6.73	5.32	0.32	7.01
ARIMA	7.21	0.38	9.05	6.81	0.36	8.66	7.03	0.39	8.87
LSTM	5.69	0.33	7.58	5.35	0.29	6.98	5.57	0.31	7.34
HA	5.74	0.36	7.76	5.42	0.32	7.27	5.68	0.35	7.55

表 4 模型多步预测误差

Table 4 Multi-step prediction errors of the model

预测时长/min	误差(早高峰)/[辆·(5 min) <sup>-1</sup> ]			误差(平峰)/[辆·(5 min) <sup>-1</sup> ]			误差(晚高峰)/[辆·(5 min) <sup>-1</sup> ]		
	$R_{MAE}$	$R_{RMSLE}$	$R_{RMSE}$	$R_{MAE}$	$R_{RMSLE}$	$R_{RMSE}$	$R_{MAE}$	$R_{RMSLE}$	$R_{RMSE}$
5	5.35	0.27	6.97	4.84	0.24	6.49	5.23	0.26	6.86
10	5.43	0.29	7.04	4.91	0.25	6.55	5.31	0.28	6.93
15	5.47	0.30	7.08	4.95	0.26	6.59	5.34	0.29	6.98
20	5.52	0.31	7.13	4.99	0.26	6.64	5.38	0.30	7.02
25	5.58	0.32	7.21	5.03	0.27	6.72	5.42	0.31	7.09
30	5.65	0.33	7.29	5.12	0.28	6.81	5.48	0.32	7.17

为了更加清晰直观地展现NNLTM-TGAT模型的预测效果,本文随机选取几个路段,分别绘制其不同时段5 min流量的真实值与模型预测值随时间的变化趋势图,见图7。由图7可知,NNLTM-TGAT模型较为准确地预测了流量的变化趋势,预测效果良好。

为了进一步深入分析模型在不同流量区间的预测效果,在早晚高峰时段内随机选择1 000个流量在100辆/5 min以上的数据点,绘制模型预测误差的频数分布直方图,见图8(a)。同样地,在平峰时

段内随机选择1 000个流量在100辆/5 min以下的数据点,绘制频数分布直方图,见图8(b)。

从预测误差频数分布直方图可以看出,预测误差整体上呈单峰分布,且峰值对应的预测误差接近于0,说明在大多数情况下,模型的预测没有产生系统性偏差,准确度较高。预测误差频数分布直方图的形状窄而高,且大体上呈对称分布(以0为对称轴),说明预测结果的误差较为集中,模型受数据噪声的影响较小,预测结果的确定性较高,稳定性较好,预测误差主要为随机误差。

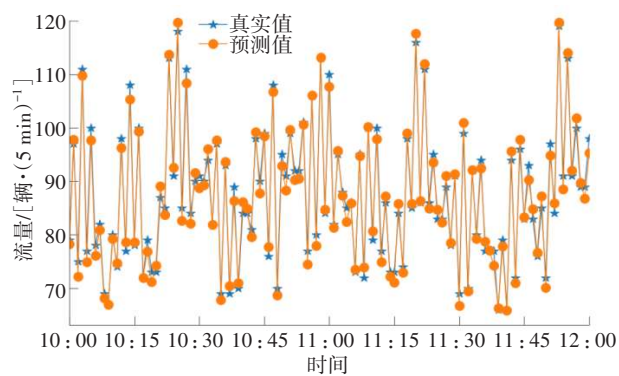

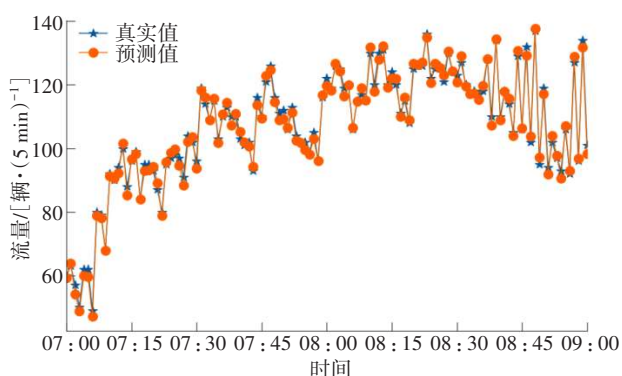


图7 流量真实值与预测值随时间的变化趋势

Fig. 7 Trend charts of real and predicted traffic flow values over time





图8 模型预测误差频数分布直方图

Fig. 8 Histograms of frequency distribution of model prediction errors

### 4 结论

准确、高效的交通流预测对于缓解城市交通拥堵、提高城市道路的交通运行效率具有重要意义。本文提出了一种融合交通流传播特性的城市路网短时交通流预测模型(NNLTM-TGAT),并使用浙江省台州市中心城区部分路网的交通流数据进行模型性能测试,得到如下结论:

1) 本文提出的NNLTM-TGAT模型在早高峰、平峰、晚高峰场景下的预测性能均比对比模型的好,说明NNLTM-TGAT模型可以借助深度学习模型强大的高维时空建模能力与动态特征学习能力提取原始数据中的时空特性,同时借助交通流传播机理的先验知识,在不同场景下取得更好的预测性能。

2) 与早晚高峰时段相比,模型在平峰时段的预测性能更好,随着预测步数的增加,模型的预测误差呈现出稳步上升的趋势,但是增幅较小。

3) 由预测误差的频数分布直方图可知,模型预测没有产生系统性偏差,模型受数据噪声的影响较小,其预测结果的准确性较高,稳定性较好。

本文提出的城市路网短时交通流预测方法也存在一定的局限性,主要体现在:

1) 全连接神经网络有时很难使由信号配时产生的交通流状态随时间的变化特征得到充分学习;

2) 本文对NNLTM计算图模型中所有参数的估计均为确定性估计,考虑到交通流传播的不确定性,在后续的研究中,可以尝试对NNLTM计算图模型中与交通流传播特性相关的参数进行不确定性

分析。

### 参考文献(References):

- [1] 中华人民共和国公安部. 全国机动车保有量达4.53亿辆 驾驶人达5.42亿人[EB/OL].<https://www.mps.gov.cn/n2254314/n6409334/n9194010/c9939035/content.html>.  
The Ministry of Public Security of the People's Republic of China. The number of motor vehicles nationwide reached 453 million, and the number of drivers reached 542 million [EB/OL]. <https://www.mps.gov.cn/n2254314/n6409334/n9194010/c9939035/content.html>.
- [2] SEO T, BAYEN A M, KUSAKABE T, et al. Traffic state estimation on highway: a comprehensive survey [J]. *Annual Reviews in Control*, 2017, 43: 128-151. DOI:10.1016/j.arcontrol.2017.03.005.
- [3] LIDTHILL M J, WHITHAM G B. On kinematic waves II: a theory of traffic flow on long crowded roads [J]. *Proceedings of the Royal Society of London Series A: Mathematical and Physical Sciences*, 1955, 229 (1178): 317-345. DOI:10.1098/rspa.1955.0089.
- [4] RICHARDS P I. Shock waves on the highway [J]. *Operations Research*, 1956, 4(1): 42-51.
- [5] NEWELL G F. A simplified theory of kinematic waves in highway traffic, part I: general theory [J]. *Transportation Research (Part B: Methodological)*, 1993, 27 (4): 281-287. DOI: 10.1016/0191-2615 (93) 90038-C.
- [6] DAGANZO C F. The cell transmission model: a dynamic representation of highway traffic consistent with the hydrodynamic theory [J]. *Transportation Research (Part B: Methodological)*, 1994, 28 (4): 269-287. DOI:10.1016/0191-2615(94)90002-7.
- [7] DAGANZO C F. A finite difference approximation of the kinematic wave model of traffic flow [J]. *Transportation Research (Part B: Methodological)*, 1995, 29 (4): 261-276. DOI: 10.1016/0191-2615 (95) 00004-W.
- [8] YPERMAN I. The link transmission model for dynamic network loading [D]. Leuven: Catholic University of Leuven, 2007.
- [9] ZHAO L, SONG Y J, ZHANG C, et al. T-GCN: a temporal graph convolutional network for traffic prediction [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 21 (9): 3848-3858. DOI:10.1109/TITS.2019.2935152.
- [10] ZHANG Z C, LIN X, LI M, et al. A customized deep learning approach to integrate network-scale online traffic data imputation and prediction [J]. *Transportation Research (Part C: Emerging Technologies)*, 2021, 132: 103372. DOI:10.1016/j.trc.2021.103372.
- [11] ABDELRAOUF A, ABDEL-ATY M, MAHMOUD N. Sequence-to-sequence recurrent graph convolutional networks for traffic estimation and prediction using connected probe vehicle data [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2023, 24(1): 1395-1405. DOI:10.1109/TITS.2022.3168865.
- [12] 张正超. 考虑数据缺失的路网级多步交通状态预测及路径规划方法[D]. 北京: 清华大学, 2022.  
ZHANG Zhengchao. Network-wide multistep traffic state prediction and dynamic routing considering missing data problem [D]. Beijing: Tsinghua University, 2022.
- [13] 吕阳. 基于浮动车轨迹数据的城市道路交通拥堵判别及预测方法研究[D]. 南京: 东南大学, 2023.  
LYU Yang. Research on state identification and prediction methods for urban road traffic congestion based on floating car trajectory data [D]. Nanjing: Southeast University, 2023.
- [14] 曾捷. 基于车辆出行轨迹链挖掘的城市路网车道级交通流预测[D]. 长沙: 中南大学, 2024.  
ZENG Jie. Lane-level traffic flow prediction in urban road network based on trajectory modeling [D]. Changsha: Central South University, 2024.
- [15] 雷斌, 李佳璐, 张鹏, 等. 基于多图时空图卷积模型的城市交通流长时预测[J]. *公路交通科技*, 2024, 41 (4): 204-213. DOI: 10.3969/j.issn.1002-0268.2024.04.021.  
LEI Bin, LI Jialu, ZHANG Peng, et al. Long term prediction on urban traffic flow based on multi-source spatio-temporal graph convolutional neural network model [J]. *Journal of Highway and Transportation Research and Development*, 2024, 41 (4): 204-213. DOI:10.3969/j.issn.1002-0268.2024.04.021.
- [16] 石弘利. 基于时空数据与深度学习的城市路网交通流预测方法研究[D]. 石家庄: 石家庄铁道大学, 2025.  
SHI Hongli. Research on traffic flow prediction for urban road network based on spatial-temporal data and deep learning [D]. Shijiazhuang: Shijiazhuang Tiedao University, 2025.
- [17] RAISSI M, KARNIADAKIS G E. Hidden physics models: machine learning of nonlinear partial differential equations [J]. *Journal of Computational Physics*, 2018, 357: 125-141. DOI: 10.1016/j.jcp.2017.11.039.
- [18] RAISSI M. Deep hidden physics models: deep learning of nonlinear partial differential equations [EB/OL]. <https://arxiv.org/abs/1801.06637>.
- [19] 陈喜群, 曹震, 沈楼涛, 等. 融合路段传输模型和深度学习的城市路网短时交通流状态预测[J]. *中国公路学报*, 2021, 34(12): 203-216. DOI:10.19721/j.cnki.1001-7372.2021.12.015.  
CHEN Xiqun, CAO Zhen, SHEN Loutao, et al. Short-

- term traffic-state prediction of urban road networks based on the fusion of a link-transmission model and deep learning [J]. *China Journal of Highway and Transport*, 2021, 34 (12): 203-216. DOI: 10.19721/j.cnki.1001-7372.2021.12.015.
- [20] JI J H, WANG J Y, JIANG Z, et al. STDEN: towards physics-guided neural networks for traffic flow prediction [J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2022, 36(4): 4048-4056. DOI: 10.1609/aaai.v36i4.20322.
- [21] HUANG A J, AGARWAL S. Physics-informed deep learning for traffic state estimation: illustrations with LWR and CTM models [J]. *IEEE Open Journal of Intelligent Transportation Systems*, 2022, 3: 503-518. DOI: 10.1109/OJITS.2022.3182925.
- [22] LU J W, LI C N, WU X B, et al. Physics-informed neural networks for integrated traffic state and queue profile estimation: a differentiable programming approach on layered computational graphs [J]. *Transportation Research (Part C: Emerging Technologies)*, 2023, 153: 104224. DOI: 10.1016/j.trc.2023.104224.
- [23] 张杰. 融合交通领域知识与深度学习的城市快速路交通状态估计与预测[D]. 杭州: 浙江大学, 2023. ZHANG Jie. Expressway traffic state estimation and prediction based on traffic knowledge and deep learning [D]. Hangzhou: Zhejiang University, 2023.
- [24] VAN-DER-GUN J P T, PEL A J, VAN-AREM B. The link transmission model with variable fundamental diagrams and initial conditions [J]. *Transportmetrica B: Transport Dynamics*, 2019, 7 (1): 834-864. DOI: 10.1080/21680566.2018.1517060.
- [25] 龙建成, 高自友, 赵小梅. 基于路段传输模型的道路出口渠化[J]. *吉林大学学报(工学版)*, 2009, 39(增刊2): 41-46. DOI: 10.13229/j.cnki.jdxbgxb2009.s2.021. LONG Jiancheng, GAO Ziyu, ZHAO Xiaomei. Channelization at road exit based on link transmission model [J]. *Journal of Jilin University (Engineering and Technology Edition)*, 2009, 39(sup 2): 41-46. DOI: 10.13229/j.cnki.jdxbgxb2009.s2.021.

(责任编辑:石月珍;校对:熊怡)