

基于双流递归LSTM模型的高速公路多粒度交通状态预测研究

瞿欣怡

上海城建信息科技有限公司, 上海

收稿日期: 2026年3月24日; 录用日期: 2026年4月16日; 发布日期: 2026年4月24日

摘要

针对高速公路改扩建施工期交通流呈现的高度非线性与多变量耦合特征, 以及传统断面监测存在的感知盲区问题, 本文提出了一种基于双流递归长短期记忆网络(Dual-Stream Recursive LSTM)的多粒度交通状态预测方法。首先, 构建微观-中观-宏观分层空间感知体系, 实现对100 m微观路段的精准映射与全域覆盖; 其次, 设计双流独立预测架构, 通过解耦拥堵指数与平均车速的特征学习, 有效解决了多变量量纲差异导致的梯度干扰难题; 最后, 引入递归滚动交互输入机制, 利用变量间的物理交互约束修正长时序预测轨迹。基于常虎与莞深高速改扩建工程实测数据的实验表明: 该方法在微观粒度下的拥堵指数预测精度(MAE)较单流模型提升约35%, 显著增强了对拥堵起步阶段的感知敏锐度; 同时, 在未来60分钟的长时预测中, 车速预测误差(RMSE)降低了27%, 有效克服了传统递归预测的不稳定性。该模型在宏观至微观全域范围内均表现优异, 可为施工期车道级精细化管控提供可靠的决策支持。

关键词

高速公路改扩建, 交通状态预测, 双流LSTM, 多粒度感知, 递归滚动预测

Research on Multi-Granularity Traffic State Prediction for Expressways Based on Dual-Stream Recursive LSTM Model

Xinyi Qu

Shanghai Urban-Construction Information Technology Co, Ltd., Shanghai

Received: March 24, 2026; accepted: April 16, 2026; published: April 24, 2026

Abstract

Aiming at the highly nonlinear and multi-variable coupling characteristics of traffic flow during expressway reconstruction and expansion, as well as the blind spots in traditional section-based monitoring, this paper proposes a multi-granularity traffic state prediction method based on a Dual-Stream Recursive Long Short-Term Memory (LSTM) network. First, a hierarchical “Micro-Meso-Macro” spatial sensing system is constructed to achieve precise mapping and full-domain coverage of 100m micro-segments. Second, a dual-stream independent architecture is designed to decouple the feature learning of the congestion index and average speed, effectively solving the gradient interference problem caused by dimensional heterogeneity. Finally, a recursive rolling mutual-feeding mechanism is introduced to correct long-term prediction trajectories by leveraging physical interaction constraints between variables. Experiments based on field data from the Changhu and Guanshen expressway reconstruction projects demonstrate that the proposed method improves the prediction accuracy (MAE) of the congestion index at the micro-granularity level by approximately 35% compared to single-stream models, significantly enhancing sensitivity to congestion onset. Furthermore, in the 60-minute long-term prediction, the root mean square error (RMSE) of speed prediction is reduced by 27%, effectively overcoming the instability of traditional recursive prediction. The model exhibits superior performance across macro to micro spatial granularities, providing reliable decision support for lane-level refined control during construction.

Keywords

Expressway Reconstruction, Traffic State Prediction, Dual-Stream LSTM, Multi-Granularity Sensing, Recursive Rolling Prediction

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着高速公路路网流量的日益饱和, 改扩建工程已成为提升通行能力的关键手段。然而, 施工区的存在改变了道路几何线形, 频繁的车道封闭与交通组织切换导致交通流呈现高度的非线性和波动性。准确的短时交通状态预测不仅是缓解施工期拥堵的基础, 更是降低二次事故风险的核心手段。Wang [1]等的研究表明, 通过实时预测施工区的交通流状态, 可以有效识别潜在的碰撞风险, 其对比实验显示基于深度学习的方法在捕捉施工区动态风险方面优于传统逻辑回归模型。近年来, 数据驱动的深度学习方法已成为主流, Cui [2]等提出的 SBU-LSTM 架构, 通过堆叠双向与单向 LSTM 并嵌入缺失值推断单元, 显著提升了路网级预测对数据缺失的鲁棒性; Zhang [3]等则进一步引入图卷积广义递归神经网络 (GCBNN), 在降低计算复杂度的同时有效捕捉了复杂的时空依赖关系。针对现实场景中普遍存在的数据质量问题, Wang [4]等提出的 GSTAE 模型将插补与预测视为并行任务, 证实了在数据缺失率较高的情况下, 多任务学习框架仍能保持稳定的预测性能。

尽管现有模型在宏观断面预测上表现优异, 但在面对改扩建施工期精细化管控需求时, 传统基于固定门架或检测器的预测方法暴露出了显著的盲区问题。王亦兵等[5]指出, 既有研究较少考虑非检测点位和道路拓扑变化, 导致在稀疏采样下难以实现全域状态的动态跟踪。为了突破这一局限, 研究重心逐渐向多粒度感知与多源数据融合转移。Meng [6]等利用 GPS 浮动车数据, 结合动态时间规整(DTW)算法改

进 LSTM, 成功实现了更细粒度的短时速度预测。与此同时, ETC 门架系统的普及为区间状态估计提供了新视角, Luo [7]等提出了基于 ETC 数据的多视角深度学习框架, 从不同维度刻画旅行时间的影响要素; 郭风斌[8]等进一步构建了基于 ETC 多模态数据的 XGBoost-MSTAN 模型, 验证了融合数据在短时流量与速度预测中的优越性。这些研究表明, 构建包含微观路段、中观路网类型的多层次空间感知体系, 是解决施工期监测盲区的关键。

在特定的施工区场景下, 微观层面的状态预测更具挑战性。Morshedzadeh [9]等基于大规模微观旅行时间观测数据(约 1500 万条), 利用深度前馈神经网络对施工区进行了微观建模, 证明了引入道路设计与施工特征能显著提升预测精度。Mashhadi [10]等则针对施工区样本不均衡的问题, 提出了结合重要性采样的回归模型, 为复杂分布下的交通状态估计提供了理论支撑。尽管基于自注意力机制的 Transformer 类模型在长序列预测中表现卓越, 但其全局注意力机制在面对施工区微观交通流的局部突然变化时易产生过度平滑[11]。此外, 考虑到高速公路交通流是速度、流量与拥堵指数的多维耦合系统, 单一变量预测往往难以全面反映路况, 且拥堵指数与车速存在明显的量纲差异。Ke [12]等针对这一问题提出了双流多通道卷积神经网络(TM-CNN), 通过构建双流架构同时学习车道间速度与流量的耦合特征, 显著优于单变量模型。近年来有些研究证明, 独立建模策略能有效避免异构变量间的优化干扰并提升鲁棒性[13]。这为解决多变量耦合预测提供了重要的架构思路。

受上述研究启发, 为满足改扩建施工期百米级精细化管控需求, 本文提出了一种基于双流递归 LSTM 的高速公路多粒度交通状态预测方法。不同于传统断面级预测, 本研究首先构建了微观路段 - 中观类型 - 宏观方向的分层空间映射机制, 实现了对 100 m 微观单元的精准感知, 其次, 借鉴双流网络思想[12]设计了双流独立 LSTM 架构(Dual-Stream Recursive LSTM, DSR-LSTM), 通过对拥堵指数与平均车速的独立建模, 有效规避了多变量量纲差异干扰并保留了隐式耦合特性; 最后, 引入递归滚动推理策略与状态交互输入机制, 实现了未来 1 小时的高精度连续预测, 为施工期主动管控提供了可靠的决策支持。

2. 数据预处理与空间建模

高质量的数据输入与合理的空间建模是深度学习模型实现高精度预测的前提。鉴于高速公路改扩建期间路网结构的动态性和交通流的时空异质性, 本研究首先构建了分层分区的空间粒度模型, 并基于此对多源异构交通数据进行清洗、映射与特征重构, 为后续的双流 LSTM 模型提供标准化的张量输入。

2.1. 空间粒度定义

传统的交通状态预测往往依赖于稀疏分布的 ETC 门架或收费站节点, 这种宏观监测方式难以捕捉施工瓶颈点(Bottlenecks)在路段内部的动态迁移特征。针对常虎、莞深高速改扩建工程的实际构造特征, 本研究提出了一种微观 - 中观 - 宏观的三层空间拓扑架构, 以实现从局部路段到全域路网的多尺度管控, 具体空间粒度划分如图 1 所示。

1) 路段微观单元

微观单元是模型进行特征提取与状态预测的基础物理单元。本研究以施工区域内的门架或监测断面为参考锚点, 依据车辆行驶轨迹将连续道路离散化为固定长度为 100 m 的路段序列 $S_{micro} = \{s_1, s_2, \dots, s_N\}$ 。

$$s_i \in \mathbb{R}^L, \quad L = 100 \text{ m} \quad (1)$$

该层级旨在捕捉细粒度的交通流波动, 特别是能够精准定位由施工围蔽、车道缩减引起的排队队尾位置及其消散过程。

2) 路段中观单元

考虑到不同道路几何线形对交通流特性的显著影响(例如, 隧道入口与互通立交区的拥堵形成机理不

同), 本研究依据道路功能属性构建中观单元。将具有相同路段类型的微观路段集合定义为中观组 $S_{meso}^{(k)}$:

$$S_{meso}^{(k)} = \{s_i \mid \text{type}(s_i) = k\}, \quad k \in \{\text{主线, 匝道, 隧道, 交织区, \dots}\} \quad (2)$$

该层级主要用于分析特定道路类型的局部运行态势, 识别施工分区对不同功能路段的差异化影响。

3) 宏观路网单元

宏观单元用于反映整条高速公路在不同行驶方向上的总体服务水平。通过聚合同一高速名称与行车方向下的所有微观路段状态, 生成方向级的宏观评价指标

$$S_{macro}^{(d)} = \{s_i \mid \text{dir}(s_i) = d\}, \quad d \in \{\text{Ascending, Descending}\} \quad (3)$$

这一分层设计不仅保证了微观预测的精度, 同时通过自底向上的聚合机制, 实现了与实际管控层级(如路段管理中心、路网调度中心)业务需求的无缝对接。

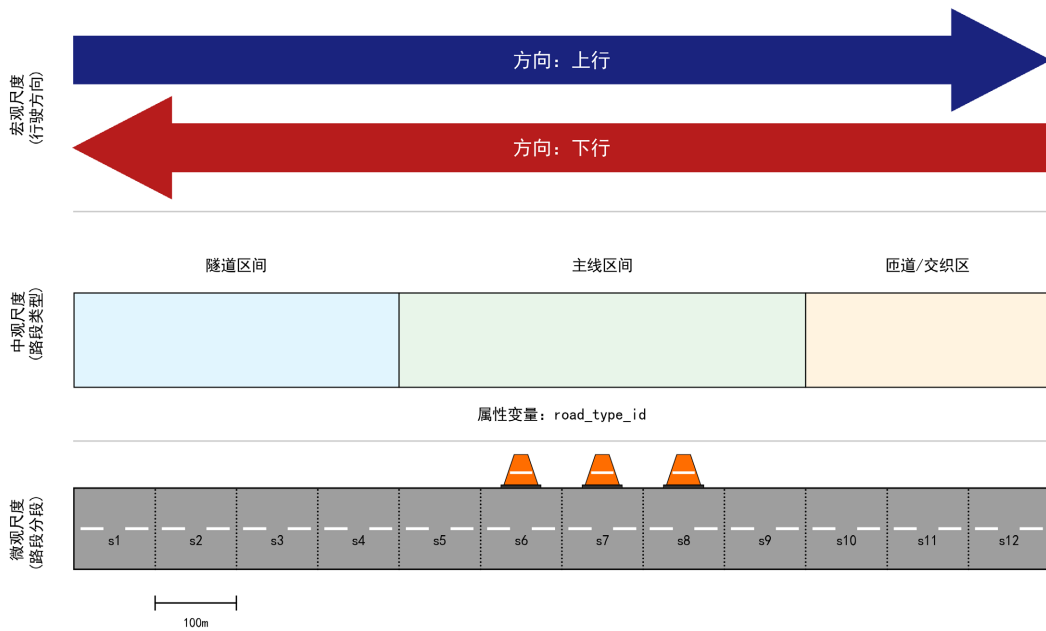


Figure 1. Schematic diagram of hierarchical spatial granularity division for expressway reconstruction
图 1. 高速公路改扩建期分层空间粒度划分示意图

2.2. 数据来源与特征工程

2.2.1. 数据

本研究的原始数据来源于常虎高速与莞深高速改扩建路段的综合交通监测系统, 涵盖了 ETC 门架交易流水、道路卡口监测数据。时间跨度覆盖施工关键期, 采样频率统一规整为 5 分钟。

为了构建高质量的微观数据集, 数据清洗与映射流程如下:

轨迹映射: 基于车辆经过门架的时刻与行驶速度, 利用线性插值算法重构车辆在各 100 m 微观路段 s_i 上的时空轨迹, 从而计算该路段在 t 时刻的平均断面车速与拥堵指数。

异常值处理: 首先依据物理极值阈值剔除车速与拥堵指数的明显错误记录, 并结合 1 小时滑动窗口的拉依达法则 (3σ 准则) 滤除局部异常跳变点。针对清洗后的缺失数据, 为保留交通流的时空激波传递特性, 本文引入时空 K 近邻加权插值法 (ST-KNN) 进行补充。具体而言, 选取目标缺失值 $x_{s,t}$ 的时空相邻节点构建近邻样本空间 Ω , 并利用反距离加权计算插值:

$$\hat{x}_{s,t} = \frac{\sum_{(i,j) \in \Omega} w_{i,j} x_{i,j}}{\sum_{(i,j) \in \Omega} w_{i,j}} \quad (4)$$

其中, $x_{i,j}$ 为近邻节点的有效观测值; 权重 $w_{i,j}$ 为时空欧氏距离的倒数, 即 $w_{i,j} = (\alpha \Delta d^2 + \beta \Delta t^2)^{-1/2}$ ($\Delta d, \Delta t$ 分别为时空距离差, 经验系数设为 $\alpha = 1.0, \beta = 0.5$)。该方法有效克服了常规插值在拥堵波传递中的失真缺陷, 保障了时空特征的物理连贯性。

数据对齐: 将处理后的数据按(高速名称, 方向, 单元路段编号, 时间)四元组进行索引对齐, 剔除样本量不足 24 小时的边缘路段。

2.2.2. 高维特征张量构建

为了充分捕捉交通流的时变特性与周期性规律, 模型输入不仅仅包含历史交通状态, 还融合了外部时间上下文信息。对于任意路段 s_i 在时刻 t , 构建特征向量 $x_t \in \mathbb{R}^D$ ($D = 5$), 两类特征见下表 1。

Table 1. Description of input features for the microscopic traffic prediction model

表 1. 微观交通预测模型输入特征描述

特征类别	变量名称	符号	取值范围	描述与处理策略
交通状态特征	拥堵指数	CI	0~10	反映路段的饱和程度与服务水平。
	平均车速	V	km/h	反映路段的实际通行效率。
时间上下文特征	时段编码	T_{period}	{0,1,2,3}	<ul style="list-style-type: none"> • 早高峰(07:00~09:00) • 平峰期(09:00~17:00) • 晚高峰(17:00~19:00) • 夜间低谷(其他时段)
	周末标识	T_{week}	{0,1}	<ul style="list-style-type: none"> • 0: 工作日 • 1: 周末
	节假日类型	T_{hol}	{0, ..., 7}	<ul style="list-style-type: none"> • 0: 非节假日 • 1: 元旦; 2: 春节……7: 国庆

2.2.3. 样本构造与划分

基于上述特征, 构建历史观测窗口为 $T = 10$ (即过去 50 分钟)的时间序列输入 $X_t = [x_{t-T+1}, \dots, x_t] \in \mathbb{R}^{T \times 5}$ 。预测目标为为下一步/下一时刻, 并通过递归滚动得到未来 $H = 12$ (即未来 1 小时)的状态序列 $Y_t = [y_{t+1}, \dots, y_{t+H}]$ 。在数据集划分上, 为严格杜绝未来信息泄露, 本研究摒弃了传统的随机打乱划分, 而是采用按时间轴外推的策略:

训练集: 前 70%的时间序列, 用于模型参数学习;

验证集: 中间 15%的数据, 用于超参数微调与早停判断;

测试集: 最后 15%的数据, 用于评估模型在未知未来场景下的泛化能力。

3. 预测模型构建

针对高速公路改扩建期间交通流呈现的高度非线性、时变性及多变量耦合特征, 本研究构建了基于长短期记忆网络的双流递归预测模型(Dual-Stream Recursive LSTM, DSR-LSTM)。该模型主要由三个核心模块组成: LSTM 特征提取单元、双流独立预测架构以及递归滚动推理机制。

3.1. LSTM 网络原理

交通流数据是一类典型的长程相关时间序列。传统的循环神经网络(RNN)在处理长序列输入时, 随着

时间步的增加，反向传播过程中极易出现梯度消失或梯度爆炸现象，导致模型难以捕捉长时间跨度下的依赖关系。LSTM 网络通过引入精巧的门控机制和细胞状态，有效解决了上述问题，特别适用于具有周期性规律和突发性扰动的高速公路交通状态预测。

如图 2 所示，LSTM 单元的核心在于通过三个门结构来控制信息的保留与遗忘。对于微观路段 s_i 在时刻 t 的输入特征向量 x_t (包含拥堵指数、车速及时间编码)，LSTM 单元的计算流程如下：

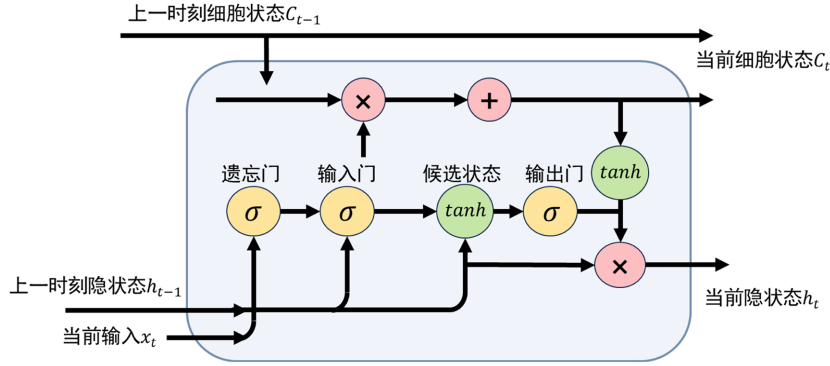


Figure 2. Schematic diagram of LSTM unit structure
图 2. LSTM 单元结构示意图

1) 遗忘门

遗忘门决定了从上一时刻的细胞状态 C_{t-1} 中丢弃哪些冗余信息。其输出 f_t 是一个数值在 (0,1) 之间的向量，由当前输入 x_t 和上一时刻隐藏状态 h_{t-1} 共同决定：

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \tag{5}$$

其中， σ 为激活函数， W_f 和 b_f 分别为遗忘门的权重矩阵与偏置项。

2) 输入门

输入门决定了当前时刻的新信息中哪些会被存储到细胞状态中。该步骤包含两个部分：首先由 Sigmoid 层决定更新值的权重 i_t ，其次由 Tanh 层生成候选细胞状态 \tilde{C}_t ：

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \tag{6}$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \tag{7}$$

3) 细胞状态更新

结合遗忘门与输入门的输出，对细胞状态进行更新。旧状态 C_{t-1} 被 f_t 筛选，新状态 \tilde{C}_t 被 i_t 加权，两者相加得到当前时刻的细胞状态 C_t 。这一过程是信息长距离传输的关键高速公路：

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \tag{8}$$

其中， \odot 表示哈达玛积(Hadamard Product，即按元素点乘)。

4) 输出门

输出门控制当前细胞状态 C_t 中有多少信息被传递给隐藏状态 h_t (即当前时刻的输出)

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \tag{9}$$

$$h_t = o_t \odot \tanh(C_t) \tag{10}$$

最终， h_t 将作为当前时间步的预测隐变量，并传递至下一时间步或全连接输出层。

3.2. 双流独立训练架构

在多变量交通预测任务中，传统的做法通常采用单流多输出(Single-Stream Multi-Output)结构，即通过共享的 LSTM 隐藏层同时输出拥堵指数与平均车速。然而，在本研究场景下，预测目标变量存在显著的量纲异质性：

拥堵指数(CI)：归一化指标，取值范围严格限制在 0~10；

平均车速(V)：物理指标，取值通常在 0~120 km/h，且方差较大。

若在同一网络中进行联合优化，数值量级较大的车速变量往往会主导损失函数，导致模型在反向传播过程中优先优化速度误差，而忽略了拥堵指数的微小梯度变化，最终造成车速准、拥堵指数不准的现象。

近年来，尽管基于 Transformer 的先进多元预测模型通过变量注意力融合机制在诸多领域表现优异，但在面对具有极大量纲差异的交通流变量时，这种联合融合机制反而会放大大量纲变量的梯度主导效应，导致模型性能退化。因此，基于双流架构理论的物理隔离架构成为解决该问题的选择。

为此，本研究设计了双流独立预测架构，如图 3 所示。该架构包含两个拓扑结构相同但权重参数完全独立的并行网络流：拥堵预测流与速度预测流。

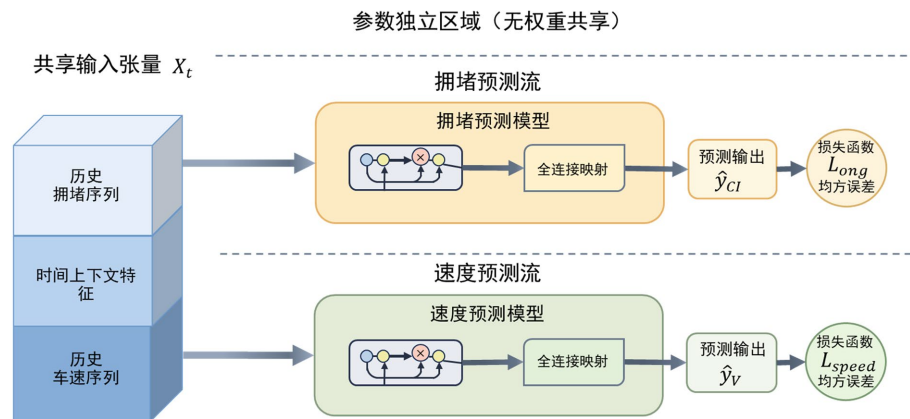


Figure 3. Schematic diagram of dual-stream independent architecture
图 3. 双流独立预测架构示意图

1) 共享输入机制

尽管两个预测流在参数空间上是解耦的，但在特征空间上保持全信息耦合。对于时刻 t ，两个流均接收相同的输入特征张量 X_t ：

$$X_t = \{CI_{t-T+1:t}, V_{t-T+1:t}, T_{time}\} \tag{11}$$

这意味着，在训练拥堵模型时，模型依然能看到历史的车速变化；反之亦然。这种设计确保了模型能够捕捉变量间存在的物理交互机理(例如：车速的骤降往往是拥堵指数攀升的前兆)。

2) 独立优化目标

双流架构采用分别优化的策略，避免了多任务学习中损失权重的调参难题。

Stream-C 优化目标：最小化拥堵指数的均方误差(MSE)：

$$\mathcal{L}_{cong} = \frac{1}{N} \sum_{i=1}^N (y_{CI}^{(i)} - \hat{y}_{CI}^{(i)})^2 \tag{12}$$

Stream-V 优化目标：最小化平均车速的均方误差(MSE)：

$$\mathcal{L}_{speed} = \frac{1}{N} \sum_{i=1}^N \left(y_V^{(i)} - \hat{y}_V^{(i)} \right)^2 \quad (13)$$

其中， N 为批量大小， \hat{y} 为模型输出值。

3) 网络配置

为了保证对比实验的公平性，两个流采用一致的超参数配置。每个流包含 2 层堆叠 LSTM，隐藏单元数设为 64，并在层间引入丢弃率为 0.2 的 Dropout 层以增强泛化能力。最终，通过全连接层将高维隐状态映射为标量输出。

3.3. 递归滚动预测策略

为了满足改扩建施工期主动管控对未来态势的预判需求，模型不仅需要输出下一时刻的状态，还需推演未来 $H = 12$ 个时间步(即未来 1 小时)的完整演变轨迹。鉴于直接多步预测存在参数量大、训练困难且难以捕捉序列动态相关性的缺陷，本研究采用递归滚动预测策略，并设计了双流交互输入机制。

1) 递归预测原理

递归策略的核心思想是将单步预测模型 $F(\cdot)$ 串行化。即利用 t 时刻的预测值 \hat{y}_{t+1} 作为伪真实值，构造 $t+1$ 时刻的输入特征，从而驱动模型预测 $t+2$ 时刻的状态。该过程不断迭代，直至生成长度为 H 的预测序列。

2) 变量交互输入与时空耦合

双流架构虽然切断了量纲干扰，但从交通流理论上割裂了多变量间的动力学耦合关系。现有的深度学习模型往往通过增加网络深度与海量数据来隐式地重新学习这种耦合，而在局部高噪、非线性的施工区场景下，这种方式极易导致长时预测的发散与过拟合。为此，本文非简单拼凑模块，而是设计了针对交通流特性的交互输入机制。

在传统的单变量递归预测中，误差容易随时间步累积。而在本文的双流架构中，拥堵指数与车速虽然由不同网络分别预测，但在递归过程中实现了信息互馈：

速度流对拥堵流的反馈：预测出的低车速 \hat{V}_{t+k} 会作为特征输入到拥堵模型中，促使下一时刻的拥堵指数 \hat{C}_{t+k+1} 上升。

拥堵流对速度流的反馈：预测出的高拥堵指数 \hat{C}_{t+k} 会作为特征输入到速度模型中，抑制下一时刻车速 \hat{V}_{t+k+1} 的恢复。

这种预测 - 重构 - 再预测的闭环机制(如图 4 所示)，隐式地强加了物理约束，保证了长时序预测结果中速度与拥堵状态的逻辑一致性。

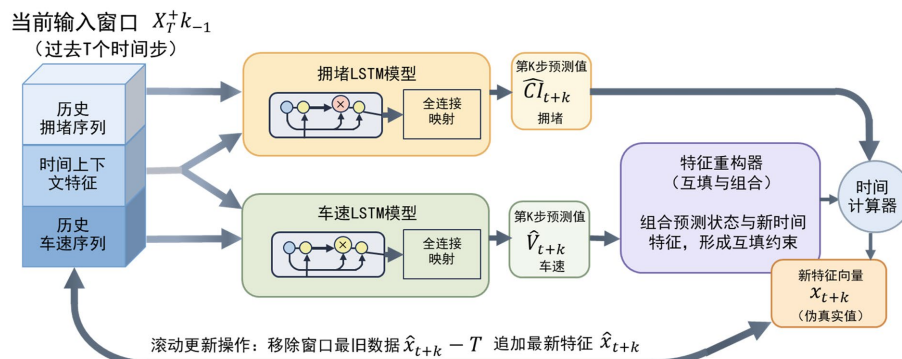


Figure 4. Flowchart of recursive rolling mutual-feeding inference strategy
图 4. 递归滚动交互输入推理策略流程图

3) 算法流程描述

设双流模型分别为 $F_{cong}(\cdot)$ 和 $F_{speed}(\cdot)$ ，对于起始时刻 t ，历史输入序列为 $\mathbf{X}_t \in \mathbb{R}^{T \times D}$ 。预测未来 $k \in \{1, \dots, H\}$ 步的具体迭代步骤如下：

Step 1: 状态推演

利用当前输入窗口 \mathbf{X}_{t+k-1} ，并行计算第 k 步的预测值：

$$\widehat{CI}_{t+k} = F_{cong}(\mathbf{X}_{t+k-1}) \quad (14)$$

$$\widehat{V}_{t+k} = F_{speed}(\mathbf{X}_{t+k-1}) \quad (15)$$

Step 2: 特征向量重构

构建 $t+k$ 时刻的新特征向量 $\hat{\mathbf{x}}_{t+k}$ 。其中，交通状态特征采用上述预测值 \widehat{CI}_{t+k} 和 \widehat{V}_{t+k} ；时间上下文特征(时段、节假日等)则根据实际时间戳 $Time_{t+k}$ 重新计算生成：

$$\hat{\mathbf{x}}_{t+k} = \left[\widehat{CI}_{t+k}, \widehat{V}_{t+k}, \text{Embedding}(Time_{t+k}) \right] \quad (16)$$

Step 3: 滑动窗口更新

更新输入序列以用于下一步预测。移除窗口最前端的历史数据 \mathbf{x}_{t+k-T} ，将新构造的特征向量 $\hat{\mathbf{x}}_{t+k}$ 拼接到窗口末端：

$$\mathbf{X}_{t+k} = \text{Concat}(\mathbf{X}_{t+k-1}[2:T], \hat{\mathbf{x}}_{t+k}) \quad (17)$$

重复上述步骤直至 $k = H$ ，最终输出序列 $Y_{pred} = \left[\left(\widehat{CI}_{t+1}, \widehat{V}_{t+1} \right), \dots, \left(\widehat{CI}_{t+H}, \widehat{V}_{t+H} \right) \right]$ 。

4. 实验与结果分析

为了验证本文提出的双流递归 LSTM 模型在高速公路施工区微观交通状态预测中的有效性，本研究基于常虎高速与莞深高速改扩建路段的实际监测数据进行了系统性实验。

4.1. 实验设置

4.1.1. 数据集描述与划分

实验数据来源于常虎高速与莞深高速改扩建工程路段的综合交通监测系统，该系统集成了 ETC 门架交易数据和路侧卡口监测数据。

1) 数据规模与空间覆盖

原始数据经清洗与时空对齐后，采样频率严格规整为 5 分钟(即每日 288 个时间片)。在空间维度上，研究区域覆盖了改扩建工程的核心路段，依据 2.1 节定义的微观空间粒度，共划分出 5006 个独立的 100 m 微观路段单元。

上行方向：包含 2513 个微观路段；

下行方向：包含 2493 个微观路段。

数据集不仅包含基础的交通状态变量(拥堵指数、平均车速)，还完整保留了道路的拓扑属性。其中包括高速公路主线名称、中观类型(如主线基本段、匝道合流区、互通立交区等)。这种高精度的空间覆盖为模型学习不同道路几何条件下的交通流特性提供了丰富的样本支持。

2) 数据集划分策略

考虑到交通流数据具有严格的时序依赖性，随机打乱划分会导致未来信息泄露问题。因此，本研究采用按时间轴顺序切分的策略。将 31 天的连续时间序列划分为训练集、验证集和测试集，具体比例设定

为 7:1.5:1.5。

训练集(前 70%): 包含约 21 天的历史数据, 用于双流 LSTM 模型的权重学习与参数更新;

验证集(中间 15%): 包含约 5 天的数据, 用于监控模型训练过程中的损失下降情况, 并执行早停机制 (Early Stopping) 以防止过拟合;

测试集(后 15%): 包含最后 5 天的数据, 用于在完全未知的未来场景中评估模型的预测精度与泛化能力。

最终, 构建的模型输入张量覆盖了超过 4000 万个时空数据点 (5006 segments \times 288 steps \times 31 days), 充分满足深度学习模型对大数据量的训练需求。

4.1.2. 对比基准模型

为了全面评估双流递归 LSTM 模型在高速公路微观交通状态预测任务中的性能, 本研究选取了三种具有代表性的基准模型进行对比实验。这些基准涵盖了从简单的统计学方法到传统机器学习, 再到标准深度学习模型的不同层次, 旨在验证本文提出模型在处理非线性、长时依赖及多变量耦合特征方面的优越性。

1) 历史平均模型(Historical Average, HA)

历史平均法是一种基于统计规律的经典预测方法。该模型假设交通状态具有显著的周度或日度周期性, 将历史同期(例如: 过去四周同一工作日的相同时刻)观测值的算术平均数作为当前时刻的预测值。选取理由: HA 模型能够捕捉交通流的基础周期性特征, 通常作为评估预测模型性能的基准下界。若复杂模型的预测误差高于 HA, 则说明其未能有效学习到数据中的时序规律。

2) 支持向量回归(Support Vector Regression, SVR)

SVR 是一种基于统计学习理论的浅层机器学习算法, 在交通预测领域应用广泛。本研究采用径向基函数(RBF)作为核函数, 将输入特征映射到高维空间以解决非线性回归问题。为了适应多步预测任务, 采用多输出回归策略。选取理由: SVR 代表了传统数据驱动方法的性能水平。将其与 LSTM 系列模型对比, 旨在验证深度学习方法在捕捉改扩建施工期高度非线性与波动性特征方面的必要性。

3) 标准单流长短期记忆网络(Standard LSTM)

标准 LSTM 模型采用与本文模型相同的层数与隐藏单元配置, 但在输入层结构上存在本质区别。该模型采用单流多输出架构, 即将拥堵指数(CI)与平均车速(Speed)直接拼接为单一的特征向量 $x_t = [CI_t, V_t, \dots]$ 输入网络, 通过共享的隐藏层权重同时学习两种变量的时序特征, 最后在输出层分离预测结果。选取理由: 这是本研究最重要的对比基准。通过对比双流独立架构与单流共享架构的表现, 可以直接验证本文提出的变量解耦策略是否能够有效缓解多变量量纲差异带来的梯度干扰问题, 从而证明双流设计的有效性。

4.1.3. 评价指标

为了全面、客观地评估模型在高速公路改扩建施工期交通状态预测中的性能, 本研究选取了三个广泛应用于时间序列预测领域的统计学指标: 平均绝对误差 (Mean Absolute Error, MAE)、均方根误差 (Root Mean Square Error, RMSE)和平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE)。

假设测试集样本总量为 N , 第 i 个时间步的真实观测值为 y_i , 模型的预测值为 \hat{y}_i , 各指标的定义及计算公式如下:

1) 平均绝对误差(MAE)

MAE 衡量了预测值与真实值之间绝对偏差的平均水平, 能够直观反映模型预测结果的准确性(Accuracy)。MAE 值越小, 说明模型的整体偏差越小。

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (18)$$

2) 均方根误差(RMSE)

RMSE 是预测误差平方均值的算术平方根。与 MAE 相比, RMSE 对较大误差样本具有更高的惩罚权重(即对离群点更敏感)。在施工区交通安全管控中,突发性的严重拥堵或车速骤降往往意味着更高的事故风险,因此 RMSE 是评估模型在极端工况下鲁棒性的关键指标。

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (19)$$

3) 平均绝对百分比误差(MAPE)

MAPE 衡量了预测误差相对于真实值的占比,消除了数据量纲的影响,能够反映预测结果的相对可靠性。

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (20)$$

指标适用性说明:考虑到本研究中两个预测变量的分布特性差异,在结果分析中侧重点有所不同:对于拥堵指数:由于其取值范围较小且存在大量接近 0 的畅通样本,MAPE 计算容易产生数值不稳定。因此,主要采用 MAE 和 RMSE 评估其预测精度。对于平均车速:车速具有明确的物理意义且数值较大,MAPE 能更好地直观反映预测偏差对实际出行体验的影响。

4.1.4. 参数配置

1) 网络超参数设置

为了保证对比实验的公平性,本文提出的双流模型(DSR-LSTM)与基准模型(Standard LSTM)在网络层配置上保持一致。

输入与输出:历史时间窗长度设定为 $T = 10$ (即利用过去 50 分钟的信息),预测步长设定为 $H = 12$ (即预测未来 60 分钟的轨迹)。

LSTM 结构:双流架构中的拥堵预测流与速度预测流均包含 2 层堆叠 LSTM,隐藏层单元数统一设定为 64。

正则化:为了防止模型在训练集上过拟合,在 LSTM 层与全连接层之间引入 Dropout 机制,丢弃概率设定为 0.2。

2) 优化与训练策略

模型训练采用端到端的监督学习方式。损失函数选用均方误差来衡量预测值与真实值之间的差异。优化器选用 Adam (Adaptive Moment Estimation),因其能够自适应调整学习率,具有较快的收敛速度。具体训练策略如下:

学习率(Learning Rate):初始学习率设为 0.001,同时采用 Reduce LR On Plateau 调度器,当验证集 Loss 在 5 个 Epoch 内未下降时,将学习率衰减为原来的 0.1 倍。

批次大小(Batch Size):设定为 1024,以充分利用 GPU 显存并保证梯度的稳定性。

迭代轮数(Epochs):最大训练轮数设为 100。

早停机机制(Early Stopping):设置耐心值(Patience)为 10。若验证集损失在连续 10 个 Epoch 内未出现改善,则提前终止训练,并保存验证集表现最优的模型权重作为最终模型。

实验涉及的主要参数汇总如表 2 所示。

Table 2. Summary of model hyperparameters and training configurations
表 2. 模型超参数与训练配置汇总

参数类别	参数名称	参数值
输入配置	历史时间步(T)	10 (50 mins)
	预测时间步(H)	12 (60 mins)
	特征维度(D)	>3 (CI, Speed, Time)
网络结构	LSTM 层数(Layers)	2
	隐藏单元数(Hidden Units)	64
	Dropout 比率	0.2
训练策略	优化器(Optimizer)	Adam
	初始学习率(Learning Rate)	0.001
	批量大小(Batch Size)	1024
	最大轮数(Max Epochs)	100
	早停耐心值(Patience)	10

4.2. 整体预测性能对比

不同空间粒度的性能评估

为了全面验证模型在微观 - 中观 - 宏观多层空间架构下的预测优势，本研究评估了不同模型在三个空间聚合尺度下的性能表现。具体评估策略如下：

微观粒度：直接计算所有 100 m 单元路段预测结果的平均误差，反映模型对局部交通波动的捕捉能力；

中观粒度：将属于同一中观组(如同一分合流区或连续基本段)内的微观路段状态进行空间聚合(加权平均)，计算中观单元的预测误差；

宏观粒度：将整条高速公路在单一方向上的所有路段状态进行聚合，计算全域宏观指标的预测误差。

表 3 展示了在未来 60 分钟预测步长下，本文模型(DSR-LSTM)与基准模型(HA, Std-LSTM)在不同空间粒度上的性能对比。

Table 3. Performance comparison of different models at different spatial granularities
表 3. 不同空间粒度下的模型性能对比

空间粒度	模型	拥堵指数		平均车速		
		MAE	RMSE	MAE	RMSE	MAPE (%)
微观	HA	1.85	2.42	8.92	12.55	11.24%
	SVR	1.55	2.10	7.85	11.15	9.85%
	Std-LSTM	1.25	1.89	6.89	9.75	8.95%
	DSR-LSTM	0.82	1.35	4.56	7.12	5.85%
中观	HA	1.65	2.15	7.85	10.85	9.50%
	SVR	1.32	1.85	6.55	9.45	8.25%
	Std-LSTM	1.05	1.58	5.45	8.25	7.20%
	DSR-LSTM	0.68	1.12	3.85	6.05	4.92%
宏观	HA	1.20	1.65	5.50	8.15	7.50%
	SVR	0.92	1.35	4.65	6.85	6.15%
	Std-LSTM	0.75	1.15	3.95	5.85	5.10%
	DSR-LSTM	0.45	0.78	2.55	4.25	3.25%

1) 微观层面的绝对优势 在最具挑战性的微观粒度下，交通流受施工干扰随机性最强，传统方法难以适应。如表 3 所示，HA 与 SVR 的预测误差显著偏高，其中 HA 的车速 MAPE 高达 11.24%，SVR 虽然通过核函数引入了非线性映射能力，将误差降至 9.85%，但仍难以捕捉复杂的时变特征。相比之下，深度学习模型表现出显著优势，特别是本文提出的 DSR-LSTM 模型，凭借双流架构对拥堵特征的独立提取能力，将微观拥堵指数的 MAE 降低至 0.82，显著优于 Std-LSTM 的 1.25。这表明 DSR-LSTM 并非简单拟合整体趋势，而是真正具备了在 100 m 细粒度下精准感知局部排队与消散的能力，能有效满足施工区“百米级”精细化管控需求。

2) 多粒度下的一致性优越 随着空间粒度从微观向宏观提升，所有模型的预测误差均呈现下降趋势。这是因为宏观指标通过空间聚合消除了微观路段中因换道、加减速产生的随机噪声，呈现出更强的规律性。尽管如此，DSR-LSTM 在所有粒度上均保持了最优性能。特别是在宏观粒度下，DSR-LSTM 的车速 MAPE 仅为 3.25%，远低于 HA (7.50%)和 SVR (6.15%)，说明模型在捕捉全域交通演变趋势方面同样具有极高的可靠性。值得注意的是，SVR 在中观和宏观层面的表现虽然优于 HA，但与 LSTM 系列模型相比仍有差距，进一步验证了在处理长序列依赖问题时，循环神经网络结构的必要性。

3) 双流架构的鲁棒性验证 对比 Std-LSTM 与 DSR-LSTM 在三个层级上的表现差值可以发现，在微观粒度上，DSR-LSTM 的提升幅度最大(拥堵指数 MAE 降低约 34%)。随着粒度变粗(宏观)，两者差距略有缩小。这一现象反向印证了双流独立架构设计的初衷：即通过解耦拥堵与速度变量，模型能更敏感地捕捉微观层面的数值波动(拥堵指数)，从而克服了单流模型(Std-LSTM)在处理高噪微观数据时的钝化现象，展现出在复杂工况下更强的鲁棒性。

4.3. 消融实验分析

为了深入探究双流独立架构与递归交互输入机制对模型性能的具体贡献，本节设计了消融实验。在保持网络层数、隐藏单元数、优化器配置等超参数完全一致的前提下，构建了两个变体模型与本文提出的完整模型(DSR-LSTM)进行对比。

4.3.1. 变体模型定义

变体 A：单流共享模型即前文所述的 Standard LSTM。该变体移除了双流独立架构，将拥堵指数与平均车速拼接为单一特征向量输入，通过共享的 LSTM 权重同时进行多任务预测。

实验目的：验证双流独立训练是否能有效解决多变量量纲差异导致的梯度干扰问题。

变体 B：无交互输入独立模型保留了双流独立架构，但在递归推理阶段切断了变量间的交互路径。即：拥堵预测流仅利用历史拥堵序列推演未来，速度预测流仅利用历史速度序列推演未来，两者在预测过程中互不感知，仅在最终输出时并列展示。

实验目的：验证状态交互输入机制在长时序预测中对物理一致性的约束作用。

4.3.2. 实验结果分析

图 5 展示了不同变体模型在 60 分钟长时预测(Step = 12)任务下的性能对比，表 4 为消融实验详细数据对比结果。

4.3.3. 结果讨论

双流架构的抗干扰作用：对比变体 A 与本文模型可以看出，移除双流架构后，拥堵指数的预测误差显著增加(MAE 从 0.82 恶化至 1.25，增幅达 52%)。这有力地证实了本文的假设：在单流模型中，由于车速数值(0~120)远大于拥堵指数(0~10)，损失函数主要由车速误差主导，导致模型在反向传播过程中倾向于优先优化车速特征，而牺牲了对拥堵指数微小波动的捕捉。双流独立架构通过参数解耦，成功隔离了

这种量纲干扰，显著提升了拥堵指数的预测精度。

交互输入机制的纠偏作用：对比变体 B 与本文模型可以看出，虽然变体 B 在保留双流架构后性能有所提升，但在缺乏交互输入机制的情况下，其长时预测的车速 RMSE (8.45)仍显著高于本文模型(7.12)。原因在于，交通流是一个强耦合系统。在长时序递归预测中，如果缺乏变量间的相互校验，单一变量的预测轨迹容易偏离物理事实(例如：模型可能预测出拥堵指数持续上升但车速却不下降的矛盾状态)。交互输入机制通过将上一时刻的预测值交叉输入到对方网络中，隐式地强加了拥堵 - 速度的反比物理约束，从而在每一步递归中对轨迹进行纠偏，保证了长时预测结果的逻辑自治性与稳定性。




Figure 5. Performance comparison of ablation study
图 5. 消融实验性能对比

Table 4. Detailed data comparison of ablation study
表 4. 消融实验详细数据对比

模型变体	拥堵指数		车速	
	MAE	RMSE	MAE	RMSE
变体 A	1.25	1.89	6.89	9.75
变体 B	0.95	1.52	5.85	8.45
本文模型	0.82	1.35	4.56	7.12

5. 结论

5.1. 研究总结

针对高速公路改扩建施工期交通流呈现出的高度非线性、强波动性及多变量耦合特征，本研究提出了一种基于双流递归长短期记忆网络的微观交通状态预测方法。该方法旨在解决传统断面级预测模型在施工区精细化管控中的盲区问题，通过构建微观 - 中观 - 宏观的多粒度空间感知体系，实现了对施工瓶颈路段未来 1 小时交通演变轨迹的精准推演。本研究的主要结论如下：

1) 解决了多变量量纲干扰难题：针对拥堵指数(0-10)与平均车速(0-120)量级差异显著的问题，创新性设计了双流独立预测架构。实验表明，相比于单流共享权重的标准 LSTM，双流架构有效隔离了不同变量在反向传播中的梯度干扰，使得拥堵指数的预测精度(MAE)提升了约 35%，显著增强了模型对拥堵起步阶段的感知灵敏度。

2) 保证了长时预测的物理一致性: 针对递归预测中误差累积导致的轨迹发散问题, 引入了状态交互输入机制。该机制通过在递归推理过程中交叉输入拥堵与速度的预测值, 隐式地强加了低速导致拥堵、拥堵抑制速度的物理约束。实验结果显示, 在未来 60 分钟的长时预测中, 本文模型的车速预测误差(RMSE)比基准模型降低了 27%, 有效克服了长时序预测的不稳定性。

3) 验证了多粒度空间感知的全域有效性: 基于微观、中观、宏观三层粒度的横向对比分析表明, 模型在各空间层面均表现出优异的预测性能。其中, 宏观粒度因消除了随机噪声, 车速预测 MAPE 低至 3.25%, 精准刻画了路网整体运行趋势; 而在最具挑战的 100 m 微观粒度下, 模型仍能将车速 RMSE 控制在 7.12 km/h 以内。这种宏观定势、微观纠偏的能力, 成功打破了施工区监测盲区, 为从路网调度到车道级管控提供了全方位的决策支持。

5.2. 未来展望

尽管本文提出的模型在改扩建施工区交通预测中取得了显著成效, 但仍存在一定的局限性, 未来研究可从以下几个方面进行深化:

1) 多源外部特征融合: 目前模型主要依赖历史交通状态数据。未来可进一步融合气象数据(暴雨、大雾)、施工计划数据(具体封闭车道数、施工工序)以及节假日事件等多源异构信息, 以提升模型在极端天气或特殊施工节点下的鲁棒性。

2) 时空图神经网络的应用: 本文侧重于微观路段的时序特征提取, 对路网空间拓扑的建模相对简化。未来可引入图卷积神经网络(GCN)或时空图注意力网络(ST-GAT), 显式地建模上下游路段及分合流区之间的空间扩散效应, 进一步提升网络级交通拥堵的协同预测能力。

3) 轻量化与边缘部署: 考虑到施工现场对实时性的高要求, 未来将致力于模型的轻量化压缩(如模型剪枝、量化), 探索将其部署于路侧边缘计算设备中, 实现毫秒级的实时在线推理与本地化预警。

基金项目

本课题受上海市城市数字化转型专项资金项目“城市交通体征监测与数字治理平台”项目资助(202401071)。

参考文献

- [1] Wang, J., Song, H., Fu, T., Behan, M., Jie, L., He, Y., *et al.* (2022) Crash Prediction for Freeway Work Zones in Real Time: A Comparison between Convolutional Neural Network and Binary Logistic Regression Model. *International Journal of Transportation Science and Technology*, **11**, 484-495. <https://doi.org/10.1016/j.ijtst.2021.06.002>
- [2] Cui, Z., Ke, R., Pu, Z. and Wang, Y. (2020) Stacked Bidirectional and Unidirectional LSTM Recurrent Neural Network for Forecasting Network-Wide Traffic State with Missing Values. *Transportation Research Part C: Emerging Technologies*, **118**, Article ID: 102674. <https://doi.org/10.1016/j.trc.2020.102674>
- [3] Zhang, Z., Lin, X., Li, M. and Wang, Y. (2021) A Customized Deep Learning Approach to Integrate Network-Scale Online Traffic Data Imputation and Prediction. *Transportation Research Part C: Emerging Technologies*, **132**, Article ID: 103372. <https://doi.org/10.1016/j.trc.2021.103372>
- [4] Wang, A., Ye, Y., Song, X., Zhang, S. and Yu, J.J.Q. (2023) Traffic Prediction with Missing Data: A Multi-Task Learning Approach. *IEEE Transactions on Intelligent Transportation Systems*, **24**, 4189-4202. <https://doi.org/10.1109/tits.2022.3233890>
- [5] 王亦兵, 胡然, 余宏鑫, 等. 面向高速公路非检测点位的全域交通状态预测方法[J]. 交通运输工程学报, 2025, 25(1): 274-294.
- [6] Meng, X., Fu, H., Peng, L., Liu, G., Yu, Y., Wang, Z., *et al.* (2022) D-LSTM: Short-Term Road Traffic Speed Prediction Model Based on GPS Positioning Data. *IEEE Transactions on Intelligent Transportation Systems*, **23**, 2021-2030. <https://doi.org/10.1109/tits.2020.3030546>
- [7] Luo, S., Zou, F., Zhang, C., Tian, J., Guo, F. and Liao, L. (2022) Multi-View Travel Time Prediction Based on Electronic

-
- Toll Collection Data. *Entropy*, **24**, Article 1050. <https://doi.org/10.3390/e24081050>
- [8] 郭凤斌, 潘崇柯, 张思楠, 等. 基于 ETC 门架系统的高速公路短时交通流预测模型[J]. 公路交通科技, 2025, 42(11): 38-46.
- [9] Morshedzadeh, Y., Gargoum, S. and Gargoum, A. (2024) Using Deep Neural Networks and Big Data to Predict Microscopic Travel Time in Work Zones. *Transportation Research Record: Journal of the Transportation Research Board*, **2678**, 419-434. <https://doi.org/10.1177/03611981241233282>
- [10] Mashhadi, A.H., Rashidi, A., Hamed, M. and Marković, N. (2025) Traffic Estimation in Work Zones Using a Custom Regression Model and Data Augmentation. *Computer-Aided Civil and Infrastructure Engineering*, **40**, 1422-1444. <https://doi.org/10.1111/mice.13413>
- [11] Zeng, A., Chen, M., Zhang, L. and Xu, Q. (2023) Are Transformers Effective for Time Series Forecasting? *Proceedings of the AAAI Conference on Artificial Intelligence*, **37**, 11121-11128. <https://doi.org/10.1609/aaai.v37i9.26317>
- [12] Ke, R., Li, W., Cui, Z. and Wang, Y. (2020) Two-Stream Multi-Channel Convolutional Neural Network for Multi-Lane Traffic Speed Prediction Considering Traffic Volume Impact. *Transportation Research Record: Journal of the Transportation Research Board*, **2674**, 459-470. <https://doi.org/10.1177/0361198120911052>
- [13] Han, L., Ye, H. and Zhan, D. (2024) The Capacity and Robustness Trade-Off: Revisiting the Channel Independent Strategy for Multivariate Time Series Forecasting. *IEEE Transactions on Knowledge and Data Engineering*, **36**, 7129-7142. <https://doi.org/10.1109/tkde.2024.3400008>