

# 基于时间感知 Transformer 的智能网联 汽车交通流预测系统

李凤强<sup>1,2</sup>

(1. 兰州理工大学 计算机与通信学院, 兰州 730050;  
(2. 青海警官职业学院 现代教育技术中心, 西宁 810000)

**摘要:** 由于交通数据具有高度非线性和时空耦合特性, 传统时序模型难以有效捕捉长距离依赖关系, 导致预测精度受限; 同时, 多源异构数据的时空对齐误差会进一步降低预测可靠性, 尤其在复杂交通场景(如拥堵、突发事故)下, 误差累积效应加剧, 导致汽车交通流预测偏差较大; 基于此, 提出基于时间感知 Transformer 的智能网联汽车交通流预测系统设计方法; 在硬件层面, 通过优化多源数据采集设备(高精度 GNSS/INS、多线激光雷达)确保原始数据质量, 部署 5G 边缘计算节点实现低延迟预处理, 有效缓解时空耦合特性带来的传输延迟问题; 在软件层面: 采用时空对齐模块(高斯滤波+坐标转换)消除多源数据时空偏差, 解决误差累积问题; 其次设计改进的时间感知 Transformer 模型, 通过时间嵌入层捕捉周期规律, 结合局部-全局混合注意力机制建模长距离依赖关系, 并引入膨胀因果卷积增强非线性特征提取能力; 动态适应交通流的周期性及突变特征, 提升预测精度; 通过硬件与软件的协同运作, 实现了交通流的精准预测; 消融实验结果显示: 时间感知 Transformer 模型应用后交通流预测误差最小值达到了 0.1%, 充分证实了改进模型的有效性; 对比实验结果显示: 设计系统应用后交通流数据时间戳同步误差最大值仅有 0.08%, 空间坐标偏移量最大值仅有 0.16 mm, 交通流预测结果与实际结果趋于一致。

**关键词:** 智能网联汽车; 时间感知 Transformer 模型; 多源数据时空对齐; 消融实验; 交通流预测

## Traffic Flow Prediction System for IVCs Based on Time-Aware Transformer

LI Fengqiang<sup>1,2</sup>

(1. School of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China;  
2. Center of Modern Education Technology, Qinghai vocational college of police officers, Xining 810000, China)

**Abstract:** Due to the strongly nonlinear and spatiotemporally coupled characteristics of traffic data, it is difficult for a traditional time-series model to effectively capture its long-distance dependencies, resulting in a limited prediction accuracy. Meanwhile, the spatiotemporal alignment errors of multi-source heterogeneous data will further reduce the prediction reliability. Especially in complex traffic scenarios (such as congestion and sudden accidents), the error-accumulation effect is exacerbated, leading to a large deviation in the prediction of automobile traffic flow. Based on this, a method for an intelligent connected vehicle (ICV) traffic flow prediction system based on a time-aware Transformer is proposed. In terms of hardware, multi-source data acquisition devices (high-precision GNSS/INS and multi-line lidar) are optimized to ensure the quality of original data, and 5G edge-computing nodes are deployed to achieve low-latency preprocessing, effectively alleviating the transmission delays caused by spatiotemporal coupling. In terms of software, a spatiotemporal alignment module (Gaussian filtering and coordinate transformation) is adopted to eliminate the spatiotemporal biases of multi-source data and solve the error-accumulation. Secondly, an improved time aware Transformer model is designed. Through the time embedding layer, its periodic pattern is captured. The local-global hybrid attention mechanism is combined to model the long-distance dependencies, and a dilated causal convolution is introduced to extract the nonlinear feature, dynamically adapting to the periodic and abrupt characteristics of traffic flow, thus improving its prediction accuracy. Through the collaborative operation of hardware and software, the accurate prediction of traffic flow is achieved. The results of ablation experiment show that after the application of the time-aware Transformer model, the minimum value of the traffic flow prediction error re-

收稿日期: 2025-05-16; 修回日期: 2025-07-23。

作者简介: 李凤强(1984-), 男, 硕士, 讲师。

引用格式: 李凤强. 基于时间感知 Transformer 的智能网联汽车交通流预测系统[J]. 计算机测量与控制, 2026, 34(5): 33-43, 51.

ches 0.1%, fully confirming the effectiveness of the improved model. Comparative experimental results show that after the application of the designed system, the maximum timestamp synchronization error of the traffic flow data is only 0.08%, and the maximum spatial coordinate offset is only 0.16 mm, which shows the traffic flow prediction results are consistent with the actual results.

**Keywords:** IVC; time-aware Transformer model; spatio-temporal alignment of multi-source data; ablation experiment; traffic flow prediction

## 0 引言

智能交通系统 (ITS, intelligent traffic system) 作为现代城市交通管理的重要组成部分, 其核心目标在于解决交通拥堵问题并提升道路利用率。在 ITS 中, 交通流预测扮演着至关重要的角色<sup>[1]</sup>。同时, 智能网联汽车 (ICV, intelligent connected vehicle) 的兴起为交通流预测带来了新的机遇与挑战。

具体而言, 机遇方面: 其一, ICV 通过车载传感器、通信模块与路侧单元 (RSU, road side unit) 的实时交互, 能够精准采集车道交通流的速度、流量等参数, 相比传统的交通数据采集方式, 其采集的数据更为丰富和准确, 为交通流预测提供了更优质的输入<sup>[2]</sup>。例如, 在一些复杂的交叉路口, 智能网联汽车可以实时反馈车辆的行驶轨迹、速度变化等信息, 这些信息有助于更精确地刻画交通流的运行状态。其二, ICV 与交通基础设施的深度融合, 使得交通管理系统能够实时感知交通状态变化, 并基于预测结果动态调整信号灯配时、优化路线规划。比如, 当交通管理系统通过智能网联汽车的数据预测到某路段即将出现拥堵时, 可以提前调整信号灯配时, 引导车辆分流, 从而有效缓解交通拥堵、提升道路利用率。然而, 挑战也不容忽视: 一方面, 智能网联汽车产生的数据规模庞大且具有多源异构性, 包括来自不同类型传感器的数据以及与路侧单元交互的数据等, 这些数据在时间和空间上的对齐存在较大难度, 多源异构数据的时空对齐误差会进一步降低预测可靠性。例如, 不同传感器的采样频率不同, 可能导致时间上的数据不同步, 而传感器的安装位置和角度差异又可能造成空间坐标的偏差。另一方面, 在复杂交通场景 (如拥堵、突发事件) 下, 智能网联汽车的行驶状态会发生剧烈变化, 产生的数据具有更强的非线性和不确定性, 使得传统预测系统更难以有效捕捉复杂的时空依赖关系, 导致预测精度受限。同时, 随着城市中智能网联汽车数量的增加, 部分区域或时段的数据可能非常稀疏或难以获取, 这也增加了预测系统训练和验证的难度, 从而降低了预测模型的泛化能力。

尽管交通流预测在 ITS 中占据核心地位, 但其实现过程却面临着诸多挑战。首先, 交通流量数据具有复杂的时空特征, 呈现出高度的非线性和不确定性。传统预测系统难以有效捕捉复杂的时空依赖关系, 导致预测精

度受限。其次, 随着城市规模的扩大和交通模式的多样化, 交通流量数据的分布变得不均衡, 部分区域或时段的数据可能非常稀疏或难以获取, 增加了预测系统训练和验证的难度, 从而降低了预测模型的泛化能力。其中, 夏晶晶等人<sup>[3]</sup>提出了结合改进蝴蝶算法与相空间重构的短时交通流预测模型。通过量子自适应种群初始化等方法改进蝴蝶算法, 优化核极限学习机超参, 利用混沌理论确定样本时序参数, 重构样本, 建立预测模型。相空间重构依赖固定时间延迟参数, 难以动态适应交通流中变化的周期特性, 可能导致设计系统预测精度不佳; 智慧等人<sup>[4]</sup>提出了基于区块链和联邦学习融合的交通流预测方法 (TFPM-BFL, traffic flow prediction method based on blockchain and federated learning)。利用加入注意机制的 LSTM 模型进行本地预测, 设计基于信誉评定的激励机制, 采用基于信誉值和压缩率的模型聚合方法。注意力权重分配依赖历史窗口, 在拥堵扩散等动态场景中难以准确捕捉突变特征, 从而影响设计系统的应用效果; 张俊溪等人<sup>[5]</sup>针对复杂路网短时交通流预测问题, 提出了基于改进长短时记忆神经网络 (ILSTM, improved long short-term memory) 的预测模型。通过遗传算法优化 LSTM 初始参数, 并重构损失函数以考虑相关路段对目标路段的影响。固定结构的 LSTM 难以适应交通状态的突变, 无法保障交通流预测的精度; 徐先峰等人<sup>[6]</sup>为了充分挖掘并利用交通流的时空特性, 提出由自相关函数、互相关函数和 K 最邻近 (KNN, k nearest neighbors) 算法组成的两级筛选机制, 以及图卷积网络-门控循环单元 (GCN-GRU, graph convolutional network-gated recurrent unit) 组合预测模型。KNN 筛选机制依赖欧式距离度量, 难以有效识别复杂路网中的非线性时空依赖, 从而影响设计系统的稳定性和预测精度; 张雄涛等人<sup>[7]</sup>针对交通流预测模型未考虑道路上下文相关性和空间依赖关系动态性的问题, 提出了基于混合图卷积的多通道时空交通流预测模型 (MHGCN, multi-channel spatial-temporal traffic flow prediction based on hybrid static-dynamic graph convolution)。该模型采用三明治结构提取时空特征, 即两侧时间模块, 中间多通道空间模块。多通道机制无法校正不同传感器的时空偏差, 导致预测存在偏差。

为解决交通流预测面临的交通流量数据时空特征复

杂难捕捉、数据分布不均衡影响模型泛化等技术难点，提出基于时间感知 Transformer 的智能网联汽车交通流预测系统设计方法。硬件上优化多源数据采集设备与部署 5G 边缘计算节点，软件上通过时空对齐模块消除多源异构数据时空偏差，改进时间感知 Transformer 模型（引入时间嵌入层捕捉周期规律、结合局部-全局混合注意力机制建模长距离依赖、运用膨胀因果卷积增强非线性特征提取），实现交通流精准预测，消融与对比实验证实该方法有效提升预测精度与效率，具有较高理论水平和实用价值。

## 1 系统硬件设计

### 1.1 多模态数据采集体系

在智能交通领域，为实现精准的交通预测，构建可靠且高精度的数据采集系统至关重要。该系统搭建的核心目的在于攻克时空数据异构性问题，为后续的交通流预测提供高可靠性的数据基础，具体实现以下功能。

1) 高精度交通信息感知：精确采集车辆运动状态、道路状况等多维度信息，为交通流模型提供丰富且准确的数据输入。

2) 实时动态监测：对交通环境进行实时监测，及时捕捉交通状态的变化，以满足交通管理与优化的实时性需求。

3) 异构数据融合：将不同来源、不同类型的交通数据进行融合，解决传统采集系统中数据精度不足、可靠性差等问题。

本系统的车载设备主要由高精度时空基准系统、多光谱视觉感知系统以及激光雷达运动补偿系统构成。

#### 1.1.1 高精度时空基准系统

采用 GNSS/INS 深度融合定位架构，具体实现包含：

1) 双频接收模块：配置 u-blox F9P 双频 GNSS 接收机（L1：1575.42 MHz/L2：1227.60 MHz），支持同时接收 GPS、GLONASS、Galileo 多系统信号，通过载波相位差分（RTK）实现厘米级定位；

2) 惯性补偿单元：集成六轴 MEMS IMU（STIM-300，零偏稳定性 0.3°/h），采用自适应卡尔曼滤波算法实现动态补偿，在 GNSS 信号丢失时仍能维持 3 s 内定位误差 < 5 cm；

3) 精密时钟系统：通过 IEEE 1588v2 协议实现网络时间同步，配合 Microchip TCXO 恒温晶振（频率稳定度 ±0.1 ppm），在 200 Hz 采样率下时间同步误差 < 1 μs。

#### 1.1.2 多光谱视觉感知系统

针对复杂光照条件设计如下。

1) 光学成像模块：采用 Sony IMX490 背照式传感器（3 840 × 2 160 @ 60 fps），集成四波段可调谐滤波器（700/850/940/1 100 nm ± 5 nm），波段切换时间 < 2 ms；

2) 动态曝光控制：基于遗传算法优化的自适应曝光策略，在  $10^{-3} \sim 10^5$  lx 照度范围内实现 120 dB 动态范围，信噪比（SNR）满足：

$$SNR = 10 \log_{10} \left( \frac{S_{\text{signal}}}{S_{\text{noise}}} \right) \geq 40 \text{ dB} \quad (1)$$

#### 1.1.3 激光雷达运动补偿系统

采用 Innovusion Falcon 256 线激光雷达，关键改进如下。

1) 扫描机构：基于机电系统（MEMS, micro-electro-mechanical systems）微镜的谐振式扫描（ $f=1.2$  kHz），实现  $120^\circ$ （H）×  $25^\circ$ （V）视场覆盖，角分辨率  $0.05^\circ \times 0.05^\circ$ ；

2) 实时补偿算法：通过惯性测量单元（IMU, inertial measurement unit）输出的角速度  $v_0$  和加速度  $a$ ，计算运动畸变补偿量  $\Delta P$ ：

$$\Delta P = \int_{t_0}^{t_1} (v_0 + \int a dt) dt + \mathbf{R}(\theta) \cdot r \quad (2)$$

其中： $\mathbf{R}(\theta)$  为当前姿态旋转矩阵， $r$  为激光点到传感器中心的距离。该算法使 250 m 测距误差从 ±5 cm 降低至 ±2 cm。

路侧单元采用多传感器融合架构，主要包括以下设备。

1) 摄像头：5 120 × 3 840 像素背照式 CMOS 摄像头集成深度学习 ISP 芯片，通过多帧 HDR 合成（14 bit 量化）实现 140 dB 动态范围，可清晰捕捉道路上的车辆、行人等目标，用于交通目标识别、流量统计等；

2) 毫米波雷达阵列：采用 77 GHz MIMO 技术<sup>[8]</sup>，通过 DBF 数字波束成形实现 ±0.1 m 测距精度，配合自适应 CFAR 检测算法使目标检出率 > 99.5%，能够精确检测车辆的距离、速度、角度等信息，实时监测交通流状态；

3) 智能地磁检测器：采用三轴磁阻传感器（10 nT 分辨率），结合粒子滤波算法实现 GNSS 拒止环境下 ±0.3 m 定位精度，填补了传统定位盲区，可用于监测车辆的存在、速度和方向等信息，尤其在卫星信号不佳的区域发挥重要作用。

通过上述技术创新，系统在典型城市市场测试中实现了：时空对齐误差：0.08 ms（时间）/1.2 cm（空间），多源数据融合置信度：98.9% ± 0.3%，运动补偿效果：急刹车工况下点云畸变率从 12.7% 降至 1.3%，为后续交通流预测提供了高可靠性的数据基础。

## 1.2 低延迟通信架构

通信是智能网联汽车交通流预测系统的核心枢纽，负责实现车辆、路侧设备与云端之间的高效数据传输与协同计算<sup>[9]</sup>。针对时空对齐误差问题，系统构建了云边端协同的通信体系，其框架图如图 1 所示。

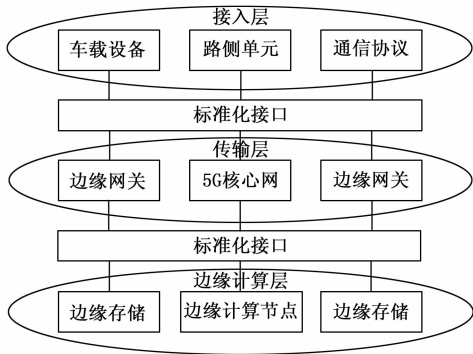


图 1 交通流预测通信体系框架图

如图 1 所示，5G 核心网是设计系统通信的基础设施，为智能网联汽车提供了高可靠、低延迟的通信能力，确保交通流数据的实时传输与处理。常规情况下，5G 核心网支持多个频段，例如 3.5 GHz、4.9 GHz、28 GHz、39 GHz 等，具有覆盖范围广、穿透能力强等优势，能满足交通流预测的需求<sup>[10]</sup>。

5G 核心网的性能指标在特定测试条件下得以保障。在数据量为不超过 10 MB，网络负载率低于 70% 的情况下，5G 核心网下行峰值速率为 10 Gbps，上行峰值速率为 5 Gbps，端到端延迟小于 1 ms。并且可以根据交通流量动态调整切片资源，可以最大限度地提升 5G 核心网的资源利用率，从而提高交通流数据的传输效率。

边缘计算节点是通信层与计算层的桥梁，负责在靠近数据源的边缘侧完成实时数据处理与轻量级模型推理，减少云端负担并降低延迟。一般情况下，边缘计算节点由计算单元、存储单元、网络接口等构成。其中，计算单元指的是 GPU 与 TPU<sup>[11]</sup>。前者型号为 NVIDIA Jetson AGX Orin，算力为 64 TOPS，并支持 INT8/FP16 精度；后者型号为 Google Edge TPU，算力为 4 TOPS，功耗仅为 2 W。存储单元选取 LPDDR5 与 NVMe SSD。前者内存为 32 GB，带宽为 102 GB/s；后者内存为 1 TB，读写速度为 7 GB/s。网络接口主要承担着与 5G 通信模块、云端连接的任务，需要支持 Sub-6 GHz 和毫米波双频段，并且配备 10 Gbps 光纤接口，方便通信设备与云端进行高速连接。

在数据预处理方面，GPU (NVIDIA Jetson AGX Orin) 和 TPU (Google Edge TPU) 有着明确的分工：

1) GPU (NVIDIA Jetson AGX Orin)：由于其具有较高的算力 (64 TOPS)，主要负责处理计算量较大、复杂度较高的任务。例如，对来自多个摄像头的高分辨率视频数据进行实时的图像特征提取和目标识别预处理，像识别道路上不同类型的车辆、行人以及交通标志等目标，由于图像数据量大且处理算法复杂，适合由 GPU 来执行。此外，对于大量的传感器数据 (如雷达、激光雷达等) 进行融合处理，将不同传感器的数据统一

到同一坐标系下，以便后续的分析 and 模型输入，这类涉及大量矩阵运算和复杂逻辑的任务也由 GPU 承担。

2) TPU (Google Edge TPU)：虽然算力相对较低 (4 TOPS)，但功耗低，适合执行一些轻量级、对实时性要求高的任务。比如对传感器数据进行简单的滤波处理，去除一些高频噪声，这类操作计算量相对较小，但需要快速响应以保证数据的及时性。另外，对于一些简单的规则判断任务，如判断车辆是否处于特定的行驶区域，或者对传感器数据进行初步的分类和筛选等，TPU 可以高效地完成，从而减轻 GPU 的负担，实现两者的协同工作。

通过接入层、传输层与边缘计算层的协同运作，完成交通流数据的实时传输与初级处理，为后续研究奠定坚实的基础。

### 1.3 高性能计算平台

面向时空模型计算需求，设计了三级加速架构。根据交通流预测需求，处理器层选用改进型 AMD EPYC 7H12，通过自适应电压调节技术提升 23% 能效比，优化缓存一致性协议降低 18% 访问延迟。加速器层配置 4 × NVIDIA A100 GPU，提供 312 TFLOPS FP16 算力支持时空图卷积并行计算 (吞吐 5.2 TB/s)。安全模块集成 AMD Secure Processor，实现 AES-256 加密加速和异常流量检测 (误报率 < 0.01%)。存储系统采用 32 GB LPDDR5 内存 (102 GB/s 带宽) 和 1TB NVMe SSD (7 GB/s 读写) 保障数据吞吐。

AMD EPYC 7H12 处理器基础参数配置情况如表 1 所示。

表 1 计算设备基础参数配置表

参数名称	参数配置	单位描述
核心数	64	核
基础频率	2.6	GHz
最大加速频率	3.3	GHz
L1 缓存	4	MB
L2 缓存	32	MB
L3 缓存	256	MB
内存通道数	8	通道
内存最大容量	4	TB
内存带宽	204.8	GB/s
PCIe 通道数	128	通道
操作系统	Linux	—
硬件级安全模块	AMD Secure Processor	—

AMD EPYC 7H12 处理器虽然在高性能计算领域表现出色，但其内部电路设计仍存在一些缺陷，使其在高负载场景下可能影响其性能、能效和可靠性。通过深入分析可知：AMD EPYC 7H12 处理器内部电路在电源管理电路、时钟分布网络、缓存一致性协议、信号完



波窗口，窗口内包含一定数量的数据点。

2) 根据高斯核函数计算窗口内每个数据点的权重，权重大小与该点到中心数据点的距离相关，距离越近权重越大。

3) 将窗口内所有数据点与其对应的权重进行加权求和，得到去噪处理后的该数据点的值。

4) 对所有原始数据点重复上述操作，完成高斯滤波。

### 2.1.2 参数选择依据

1) 滤波窗口大小：根据数据的噪声特性和数据变化的平滑程度来确定。一般来说，若数据噪声较大且变化相对缓慢，可以选择较大的滤波窗口，以增强去噪效果；若数据变化较快，则应选择较小的窗口，避免过度平滑而丢失重要信息。在本系统中，通过多次实验测试不同窗口大小下的去噪效果和特征保留情况，最终确定合适的。

2) 高斯核的标准差：控制着高斯核函数的宽度，影响着权重的分布。越大，权重分布越平缓，滤波效果越平滑；越小，权重分布越集中，对局部特征的保留越好。通过实验对比不同值下的去噪结果，综合考虑噪声去除和数据特征保留，确定了合适的。

滤波表达式为：

$$y_i = \frac{1}{Z} \sum_{j=-k}^k x_{i+j} \cdot \exp\left[-\frac{j^2}{2\sigma^2}\right] \quad (3)$$

式中， $y_i$  表示的是去噪处理后的多源数据（交通流数据）； $Z$  表示的是归一化常数； $k$  表示的是滤波窗口大小； $\sigma$  表示的是高斯核的标准差。

多源数据（交通流数据） $y_i$  通常具有不同的时间戳和空间分辨率，例如车辆轨迹、交通信号、环境数据等，需要通过时空对齐处理将其统一到一致的时空坐标系中，方便后续交通流数据的应用与分析<sup>[15-16]</sup>。其中，交通流数据  $y_i$  时间对齐处理主要包含两个阶段，分别为时间戳统一阶段与时间分辨率统一阶段，如下所示。

#### 1) 时间对齐处理：

##### (1) 时间戳统一阶段：

时间戳统一指的是将不同数据源的时间戳对齐到同一时间基准。假设  $y_i$  与  $y_j$  来自于不同数据源，其对应的时间戳序列为  $t_i$  与  $t_j$ ，对齐后的时间戳表达式为：

$$t = \zeta(t_i, t_j) \quad (4)$$

式中， $t$  表示的是对齐时间戳序列； $\zeta(\cdot)$  表示的是时间戳序列升序排列函数。

##### (2) 时间分辨率统一阶段：

时间分辨率统一指的是将不同数据源的时间分辨率统一到同一频率。假设  $y_i$  与  $y_j$  来自于不同数据源，其对应的时间分辨率为  $\Delta t_i$  与  $\Delta t_j$ 。选择最小公倍数作为统一的时间分辨率，是因为它能够在不丢失数据重要信息

的前提下，最大程度地整合不同分辨率的数据，保证数据的一致性和完整性。统一后的时间分辨率表达式为：

$$\Delta t = \gamma(\Delta t_i, \Delta t_j) \quad (5)$$

式中， $\Delta t$  表示的是统一后的时间分辨率； $\gamma(\cdot)$  表示的是最小公倍数查找函数。

交通流数据  $y_i$  空间对齐处理主要包含两个阶段，分别为坐标系转换阶段与空间分辨率统一阶段，如下所示：

#### 2) 空间对齐处理：

##### (1) 坐标系转换阶段：

坐标系转换指的是将不同数据源的空间坐标统一到同一坐标系<sup>[17]</sup>。假设数据源  $y_i$  的坐标为  $(X_i, Y_i)$ ，数据源  $y_j$  的坐标为  $(X_j, Y_j)$ ，根据两个数据源的实际情况，通过测量、校准等方式确定数据源  $y_i$  坐标与数据源  $y_j$  坐标之间的转换矩阵。使用转换矩阵对数据源  $y_i$  的坐标进行转换，得到数据源  $y_i$  坐标统一后结果表达式为：

$$(X, Y) = A_{ij} \cdot (X_i, Y_i) \quad (6)$$

式中， $(X, Y)$  表示的是数据源  $y_i$  坐标统一后结果； $A_{ij}$  表示的是数据源  $y_i$  坐标与数据源  $y_j$  坐标之间的转换矩阵。转换矩阵  $A_{ij}$  的确定需要依据具体的传感器安装位置、方向以及实际的地理环境等因素，通过精确的测量和校准来获取，以确保坐标系转换的准确性。

##### (2) 空间分辨率统一阶段：

空间分辨率统一指的是将不同数据源的空间分辨率统一到同一尺度。假设  $y_i$  与  $y_j$  来自于不同数据源，其对应的空间分辨率为  $\Delta s_i$  与  $\Delta s_j$ ，使用最大公约数查找函数计算  $\Delta s_i$  与  $\Delta s_j$  的最大公约数，得到统一后空间分辨率  $\Delta s$ 。对于空间分辨率较低的数据，通过插值等方法将其分辨率提升到  $\Delta s$ ；对于空间分辨率较高的数据，进行降采样处理，使其分辨率也为  $\Delta s$ 。选择最大公约数作为统一的空间分辨率，是因为它能够在保留数据主要特征的基础上，合理地整合不同分辨率的数据，避免数据过度细化或粗糙化。统一后空间分辨率表达式为：

$$\Delta s = \lambda(\Delta s_i, \Delta s_j) \quad (7)$$

式中， $\Delta s$  表示的是统一后的空间分辨率； $\lambda(\cdot)$  表示的是最大公约数查找函数。

将上述时间对齐处理与空间对齐处理后的交通流数据进行融合处理，从而获得时空对齐的交通流数据：

$$\hat{y}_i = \omega_1 * y_i[t, \Delta t] + \omega_2 * y_i[(X, Y), \Delta s] \quad (8)$$

式中， $\hat{y}_i$  表示的是时空对齐处理后的交通流数据； $y_i[t, \Delta t]$  与  $y_i[(X, Y), \Delta s]$  表示的是时间对齐与空间对齐处理后的交通流数据； $\omega_1$  与  $\omega_2$  表示的是  $y_i[t, \Delta t]$  与  $y_i[(X, Y), \Delta s]$  的融合系数。

上述过程完成了交通流数据的时空对齐处理，有效解决了长期预测中的误差累积问题，为后续交通流预测提供了高质量的时空一致性数据基础。

## 2.2 时间感知 Transformer 模型设计模块

尽管时空对齐处理显著降低了多源数据的时空偏差，但处理后的数据仍面临交通流周期性规律与突发性事件难以建模、长序列依赖关系捕捉不足的问题。为此，提出改进的时间感知 Transformer 模型，通过时间嵌入层捕捉周期特征，结合局部-全局混合注意力机制建模多尺度时空依赖，并引入膨胀因果卷积增强非线性特征提取能力，有效提升了交通流预测的精度和鲁棒性。

Transformer 模型凭借其强大的并行计算能力和对长程依赖关系的捕捉能力，取得了显著的成功。然而，在将其应用于交通流预测任务时，面临着较大的挑战，例如时空相关性捕捉不足、训练效率低下等。因此，对原始 Transformer 模型进行改进与优化（时间感知 Transformer 模型），具体如表 2 所示。

表 2 Transformer 模型改进内容表

模块	改进内容	作用
时间嵌入层	融合时间特征	增强时间感知功能
注意力机制	局部窗口+全局周期注意力	捕捉短期波动与长期规律
编码器	改进注意力+TCN	联合建模长程与局部依赖
多模态融合	动态门控权重	自适应融合多源数据
解码器	通过自回归预测交通流	提供预测可靠性量化

由表 2 内容可知：时间感知 Transformer 模型是一种专为交通流预测设计的时序建模架构，通过融合时间嵌入、改进的注意力机制和多模态数据，实现对交通流的高精度预测。改进模型分为编码器和解码器两部分，核心改进包括时间嵌入层、局部-全局注意力机制和多模态融合模块。

### 2.2.1 时间嵌入层设计

时间嵌入层主要是将时间戳转化为高维向量，以捕捉交通流的周期性规律<sup>[18]</sup>。将小时、周几与节假日（时间戳）进行特征编码处理，均映射为  $d$  维向量，记为  $E_H$ 、 $E_D$  与  $E_J$ ，并对三者进行融合处理，获得最终的时间嵌入向量，表达式为：

$$E_t = \alpha_1 E_H + \alpha_2 E_D + \alpha_3 E_J \quad (9)$$

式中， $E_t$  表示的是时间嵌入向量； $\alpha_1$ 、 $\alpha_2$  与  $\alpha_3$  表示的是小时特征编码  $E_H$ 、周几特征编码  $E_D$  与节假日特征编码  $E_J$  的融合系数，取值范围为  $0 \sim 1$ ，并满足条件： $\alpha_1 + \alpha_2 + \alpha_3 = 1$ 。

时间嵌入层添加在 Transformer 模型的输入层<sup>[19]</sup>，将时间嵌入向量  $E_t$  与交通流数据  $\hat{y}_t$  进行拼接，增强改进模型对周期性规律的时间感知能力。

### 2.2.2 局部-全局混合注意力机制

注意力机制是编码器的核心部分，其改进主要是通

过局部时间窗口注意力和全局周期注意力，分别捕捉交通流数据的短期依赖和长期周期规律，从而提升 Transformer 模型交通流预测的精度<sup>[20]</sup>。其中，局部时间窗口注意力主要是捕捉交通流数据的短期波动，其将输入数据划分为长度为  $l$  的局部窗口，对每个窗口内的数据序列计算自注意力，表达式为：

$$B_l = \text{Softmax} \left[ \frac{QK^T}{\sqrt{d_k}} \right] V \quad (10)$$

式中， $B_l$  表示的是局部时间窗口注意力； $\text{Softmax}[\cdot]$  表示的是激活函数； $Q$ 、 $K$  与  $V$  表示的是局部时间窗口的查询矩阵、键矩阵及其值矩阵； $d_k$  表示的是键维度。

全局周期注意力主要是捕捉交通流数据的长期规律，其将输入数据按周期（例如每日、每周）进行分段处理，计算跨周期的注意力，表达式为：

$$B_s = \text{Softmax} \left[ \frac{Q_g K_g^T}{\sqrt{d_k}} + M \right] V_g \quad (11)$$

式中， $B_s$  表示的是全局周期注意力； $Q_g$ 、 $K_g$  与  $V_g$  表示的是全局周期的查询矩阵、键矩阵及其值矩阵； $M$  表示的是掩码矩阵，主要作用是限制非周期位置的注意力权重。

通过门控机制对局部时间窗口注意力  $B_l$  与全局周期注意力  $B_s$  进行融合处理，表达式为：

$$\begin{cases} B_{\text{fused}} = \chi \cdot B_l + (1 - \chi) \cdot B_s \\ \chi = \sigma\{W_\chi \times [B_l; B_s]\} \end{cases} \quad (12)$$

式中， $B_{\text{fused}}$  表示的是注意力融合结果； $\chi$  表示的是注意力融合系数； $\sigma[\cdot]$  表示的是 Sigmoid 函数； $W_\chi$  表示的是可学习参数。

关于局部窗口大小  $l$  的选取，进行了多组对比实验。在实验中，尝试了不同的窗口大小，从较小的数值如  $l=5$  到较大的数值如  $l=20$ 。当窗口大小较小时，模型对于交通流数据中短期的高频波动特征捕捉较为灵敏，但对于一些稍长周期的特征可能捕捉不足；而当窗口大小较大时，虽然能够捕捉到一定的长周期特征，但在处理高频的短期波动时表现不佳。通过对不同窗口大小下模型在测试集上的交通流预测误差进行统计分析，发现当  $l=10$  时，模型在平衡短期波动和长周期特征捕捉方面取得了较好的效果，能够使得交通流预测误差相对较小。

### 2.2.3 膨胀因果卷积模块

为增强非线性特征提取能力，设计多尺度卷积网络：

1) 膨胀因子配置：采用指数增长策略  $[1, 2, 4, 8, 16, 32]$ 。交通流数据在不同时间尺度上存在着不同的特征，小的膨胀因子可以捕捉到交通流数据中较为精细的局部特征，例如短时间内的车辆流量变化；而大的膨胀因子则可以捕捉到更宏观的、长周期的特征，比如

一天内不同时间段的交通拥堵规律。通过采用指数增长的膨胀因子序列,能够以较少的参数覆盖更广泛的时间尺度范围。为了验证这一策略的有效性,进行了对比实验,尝试了均匀增长的膨胀因子序列以及随机选取的膨胀因子组合等其他配置方式。实验结果表明,在交通流预测任务中,指数增长策略在捕捉交通流的多尺度特征方面表现最优,能够有效提升模型的非线性特征提取能力,从而降低交通流预测误差。

2) 因果约束:通过左填充保持时序因果性;

3) 残差连接:每层输出  $H_i$  计算为:

$$H_i = \text{ReLU}(\mathbf{W}_\chi * H_{i-1}) + H_{i-1} \quad (13)$$

## 2.2.4 多模态融合模块

多模态融合模块添加在编码器与解码器中间,主要承担着编码器提取特征数据融合的任务,通过门控机制实现。

在确定融合权重系数时,具体过程如下。

首先,对于第  $i$  个交通流数据特征  $H_i$ ,通过线性变换  $\mathbf{W}_H H_i + \mathbf{b}_H$  (其中  $\mathbf{W}_H$  是交通流数据特征融合权重系数计算的权重矩阵,  $\mathbf{b}_H$  是偏置向量),得到一个中间向量。然后,将所有中间向量通过 Softmax 函数进行归一化处理,从而得到融合权重系数  $v_i = \text{Softmax} [\mathbf{W}_H H_i + \mathbf{b}_H]$ 。

在训练过程中,采用端到端的训练方式。模型的目标函数为预测的交通流与真实交通流之间的误差(例如均方误差),通过反向传播算法,同时更新模型中包括  $\mathbf{W}_H$  和  $\mathbf{b}_H$  在内的所有可学习参数。在反向传播过程中,误差会从解码器的输出层逐层反向传播,计算出关于  $\mathbf{W}_H$  和  $\mathbf{b}_H$  的梯度,进而更新它们的值,使得融合权重系数能够自适应地调整,以更好地融合多源数据特征。

为了保证融合后的交通流数据特征  $H_{\text{final}} = \sum_{i=1}^N v_i \cdot H_i$  能够最优地代表原始多源数据的信息,从以下几个方面进行设计和训练:

一方面,Softmax 函数的归一化特性保证了融合权重系数  $v_i$  满足非负且  $\sum_{i=1}^N v_i = 1$ ,使得融合过程是合理的加权求和。另一方面,在训练过程中,模型通过不断优化目标函数,使得融合后的特征能够最大程度地与真实交通流信息相匹配。也就是说,在误差的驱动下,模型会自动调整融合权重系数,让重要的特征获得更大的权重,从而使融合后的特征能够最优地代表原始多源数据中与交通流预测相关的信息。其表达式为:

$$\begin{cases} H_{\text{final}} = \sum_{i=1}^N v_i \cdot H_i \\ v_i = \text{Softmax}[\mathbf{W}_H H_i + \mathbf{b}_H] \end{cases} \quad (14)$$

式中,  $H_{\text{final}}$  表示的是加权融合后的交通流数据特征;  $N$

表示的是交通流数据特征的总数量;  $H_i$  与  $v_i$  表示的是第  $i$  个交通流数据特征及其融合权重系数;  $\mathbf{W}_H$  与  $\mathbf{b}_H$  表示的是交通流数据特征融合权重系数计算的权重矩阵与偏置向量。

上述过程完成了 Transformer 模型的改进与优化,获得时间感知 Transformer 模型,并对改进内容进行了详细的说明与介绍,为后续交通流预测结果获取提供更优质的模型支撑。

## 2.3 交通流预测结果获取模块

研究的智能网联汽车交通流预测系统具有显著的协同创新优势。在硬件方面,通过优化多源数据采集设备(如高精度 GNSS/INS、多线激光雷达),从源头确保了原始数据的高质量,同时部署 5G 边缘计算节点实现低延迟预处理,有效缓解了时空耦合特性带来的传输延迟问题,为后续数据处理与模型运行提供了坚实的基础。在软件层面,时空对齐模块(采用高斯滤波+坐标转换)消除了多源数据的时空偏差,解决了误差累积问题;改进的时间感知 Transformer 模型则通过时间嵌入层捕捉周期规律,结合局部-全局混合注意力机制建模长距离依赖关系,并引入膨胀因果卷积增强非线性特征提取能力,能够动态适应交通流的周期性及突变特征。硬件与软件的协同运作形成了一个有机整体,从数据采集、传输、处理到模型预测,全方位提升了交通流预测的精准性与可靠性。

针对传统预测方法在复杂时空依赖关系建模和突发交通事件响应上的不足,基于 2.1 节时空对齐处理后的高精度交通流数据,结合 2.2 节改进的时间感知 Transformer 模型<sup>[21]</sup>,实现智能网联汽车交通流的精准预测,具体流程如下所示。

步骤一:将交通流数据  $\hat{y}_i$  输入至时间感知 Transformer 模型的输入层,联合时间嵌入层拼接交通流数据  $\hat{y}_i$  与时间嵌入向量  $\mathbf{E}_i$ ,表达式为:

$$z_i = \mathcal{D}(\hat{y}_i, \mathbf{E}_i) \quad (15)$$

式中,  $z_i$  表示的是嵌入时间向量后的交通流数据;  $\mathcal{D}\{\cdot\}$  表示的是数据拼接函数。

步骤二:编码器应用改进注意力机制对交通流数据  $z_i$  进行进一步的处理,表达式为:

$$\hat{z}_i = z_i \times B_{\text{fused}} \quad (16)$$

式中,  $\hat{z}_i$  表示的是改进注意力机制处理后的交通流数据。

步骤三:为增强模型对交通突变事件的非线性特征提取能力,编码器使用膨胀因果卷积提取交通流数据  $\hat{z}_i$  的特征,表达式为:

$$H_i = \text{ReLU}[\mathbf{W}_{\text{cen}} * \hat{z}_i + \mathbf{b}_{\text{cen}}] \quad (17)$$

式中,  $\text{ReLU}[\cdot]$  表示的是激活函数;  $\mathbf{W}_{\text{cen}}$  与  $\mathbf{b}_{\text{cen}}$  表示的是膨胀因果卷积操作的权重矩阵与偏置向量;  $*$  表示的是

膨胀卷积操作，膨胀因子随层数指数增长。

步骤四：应用多模态融合模块对交通流数据特征  $H_i$  进行加权融合处理——公式 (14)，获得融合交通流数据特征  $H_{\text{final}}$ 。

步骤五：解码器以融合交通流数据特征  $H_{\text{final}}$  为依据，通过自回归方式预测智能网联汽车交通流，表达式为：

$$Q_t = W_Q \tanh(W_S S_t + W_C H_{\text{final}}) + b_Q \quad (18)$$

式中， $Q_t$  表示的是当前时刻智能网联汽车的交通流预测数值； $W_Q$  与  $b_Q$  表示的是交通流预测的权重矩阵与偏置向量； $W_S$  与  $W_C$  表示的是隐状态向量与特征向量的权重系数； $S_t$  表示的是隐状态向量，由编码器的门控循环单元更新与生成。

综上所述，在时间感知 Transformer 模型应用基础上，实现了智能网联汽车交通流的有效预测，为智能交通系统 (ITS) 的后续发展提供一定的帮助。

### 3 设计系统应用性能测试

#### 3.1 实验场景构建

为了验证设计系统的应用性能，随机选取路段进行智能网联汽车交通流预测实验。实验场景时间范围设置为连续 7 个月，其中涵盖了工作日、周末与节假日。这一选择是基于以下考虑：智能网联汽车交通流在不同时间尺度下呈现出复杂的变化规律，连续 7 个月的时长能够较为全面地覆盖不同季节的气候条件（如夏季的高温、冬季的低温等可能对交通出行产生影响），以及不同类型日期（工作日、周末与节假日）的出行模式差异。

在空间范围上，选择城市核心区域，面积 200 km<sup>2</sup>，包含 12 个交通分区。城市核心区域作为城市的经济、商业和人口活动中心，交通状况复杂且具有代表性。这里汇聚了多种类型的道路（主干道、次干道、支路等），不同的功能分区（商业区、住宅区、办公区等），能够反映出不同出行目的（通勤、购物、办事等）下的交通流特征。12 个交通分区的划分是依据城市的地理布局、道路网络结构以及实际交通流量分布情况确定的，便于对不同区域的交通特性进行精细化分析。该区域的地理信息和交通数据主要来源于城市地理信息系统 (GIS) 以及交通部门的实时监测系统，保证了空间数据的准确性和时效性。

以下对 12 个交通分区的具体交通特征进行详细阐述。

1) 交通分区 1：位于商业区中心，平均车流量为每小时 1 500~2 000 辆，主干道占比 60%，次干道占比 30%，支路占比 10%。交通信号灯设置为早高峰期间绿信比 40%，平峰期绿信比 30%。

2) 交通分区 2：以住宅区为主，平均车流量每小

时 800~1 200 辆，主干道占比 20%，次干道占比 50%，支路占比 30%。交通信号灯设置为晚高峰期间绿信比 45%，平峰期绿信比 35%。

3) 交通分区 3：是办公区集中地，平均车流量每小时 1 300~1 700 辆，主干道占比 50%，次干道占比 40%，支路占比 10%。交通信号灯设置为工作日早高峰绿信比 42%，平峰期绿信比 32%。

4) 交通分区 4：为混合功能区，平均车流量每小时 1 000~1 400 辆，主干道占比 35%，次干道占比 45%，支路占比 20%。交通信号灯设置为周末绿信比 38%，平峰期绿信比 33%。

5) 交通分区 5：靠近城市边缘的住宅区，平均车流量每小时 600~1 000 辆，主干道占比 15%，次干道占比 55%，支路占比 30%。交通信号灯设置为夜间绿信比 30%，平峰期绿信比 30%。

6) 交通分区 6：处于商业区与住宅区交界，平均车流量每小时 1 200~1 600 辆，主干道占比 40%，次干道占比 45%，支路占比 15%。交通信号灯设置为工作日晚高峰绿信比 43%，平峰期绿信比 33%。

7) 交通分区 7：主要为工业区，平均车流量每小时 700~1 100 辆，主干道占比 25%，次干道占比 50%，支路占比 25%。交通信号灯设置为早高峰期间绿信比 38%，平峰期绿信比 30%。

8) 交通分区 8：位于城市核心的商业区，平均车流量每小时 1 800~2 200 辆，主干道占比 70%，次干道占比 20%，支路占比 10%。交通信号灯设置为周末全天绿信比 40%，平峰期绿信比 35%。

9) 交通分区 9：是新开发的住宅区，平均车流量每小时 500~900 辆，主干道占比 10%，次干道占比 60%，支路占比 30%。交通信号灯设置为节假日绿信比 35%，平峰期绿信比 30%。

10) 交通分区 10：靠近高校的混合功能区，平均车流量每小时 1 100~1 500 辆，主干道占比 30%，次干道占比 50%，支路占比 20%。交通信号灯设置为工作日白天绿信比 37%，平峰期绿信比 32%。

11) 交通分区 11：处于办公区与工业区交界，平均车流量每小时 900~1 300 辆，主干道占比 35%，次干道占比 45%，支路占比 20%。交通信号灯设置为夜间高峰绿信比 32%，平峰期绿信比 30%。

12) 交通分区 12：以休闲娱乐区为主，平均车流量每小时 1 400~1 800 辆，主干道占比 45%，次干道占比 40%，支路占比 15%。交通信号灯设置为节假日晚高峰绿信比 42%，平峰期绿信比 35%。

具体的交通流预测包括短期（未来 1~3 小时）和长期（未来 1~7 月）的车流量预测，涵盖了小汽车、公交车、货车等不同类型车辆的交通流数据。

为确保实验场景硬件符合 1.1 节多模态数据采集体系的要求,在车载设备上,实验路段内的智能网联汽车配备了集 RTK 差分定位与惯性导航技术于一体的 GNSS/INS 融合定位模块,通过双频 GNSS 接收机接收差分信号并结合 IMU 实现动态补偿,保障水平定位与航向角精度,同时采用 IEEE 1588v2 精密时间协议及 TCXO 恒温晶振实现  $\mu\text{s}$  级时间同步;还安装了具备多光谱成像、毫秒级波段切换和自适应曝光等功能的摄像头系统,以及拥有大视场覆盖和基于 IMU 运动补偿算法的 256 线固态激光雷达。在路侧单元方面,实验场景部署了集成深度学习 ISP 芯片、具备高动态范围的背照式 CMOS 摄像头,采用 77 GHz MIMO 技术且测距精度高、目标检出率高的毫米波雷达阵列,以及基于三轴磁阻传感器和粒子滤波算法实现高精度定位的智能地磁探测器。如此配置,保证了实验场景硬件在时空数据采集等方面满足要求,为验证设计系统应用性能提供可靠数据采集基础。

### 3.2 消融实验

设计系统时间感知 Transformer 模型是在 Transformer 模型基础上改进而得,为了验证其有效性,设计消融实验。参与消融实验的模型如下所示。

1) 模型 1: 传统 Transformer 模型,由输入层、编码器与解码器构成;

2) 模型 2: 改进 Transformer 模型,在输入层中添加时间嵌入层,其余模块未改进;

3) 模型 3: 改进 Transformer 模型,改进编码器中的注意力机制(局部窗口+全局周期注意力),其余模块未改进;

4) 模型 4: 改进 Transformer 模型,在编码器与解码器中间添加多模态融合模块,其余模块未改进;

5) 模型 5: 时间感知 Transformer 模型(即设计系统应用模型),添加时间嵌入层,改进注意力机制,并增添多模态融合模块。

应用模型 1~5 进行交通流预测实验,计算交通流预测误差,如图 3 所示。




图 3 交通流预测误差示意图

如图 3 所示,模型 1 交通流预测误差最大,主要是因为传统 Transformer 模型存在着时空相关性捕捉不足、训练效率低下等缺陷,无法在交通流预测任务中发挥出较好的性能,致使交通流预测误差较大;模型 2~模型 4 在传统 Transformer 模型基础上进行了部分改进。相较于模型 1 来看,模型 2~模型 4 交通流预测误差得到了一定的降低,说明模型改进部分起到了有力影响,有效地提升了交通流预测精度;模型 5(设计系统应用模型)交通流预测误差最小,最小值达到了 0.1%,主要是因为其在传统 Transformer 模型基础上进行了大幅度的改进与优化,从而有效地提高了交通流预测精度,充分证实了时间感知 Transformer 模型的有效性。

### 3.3 对比实验

选取融合核极限学习机与 PSR 的交通流预测系统、一种基于区块链和联邦学习融合的交通流预测系统作为对比系统 1 与对比系统 2,联合设计系统共同进行交通流预测实验,通过交通流数据时间戳同步误差,交通流数据空间坐标偏移量与交通流预测结果来显示应用系统的性能优劣。

其中,交通流数据时间戳同步误差与空间坐标偏移量主要是反映多源数据时空对齐处理性能的好坏,具体如图 4~5 所示。




图 4 交通流数据时间戳同步误差示意图




图 5 交通流数据空间坐标偏移量示意图

相较于对比系统 1 与对比系统 2 来看,设计系统应用后交通流数据时间戳同步误差与空间坐标偏移量较小,时间戳同步误差最大值仅有 0.08%,空间坐标偏移量最大值仅有 0.16 mm。这主要是因为设计系统应用

高斯滤波算法对交通流数据进行了去噪处理，有效地提高了交通流数据的整体质量，并通过时间戳统一阶段、时间分辨率统一阶段、坐标系转换阶段与空间分辨率统一阶段完成了多源数据的时空对齐处理，将其分辨率考虑在内，从而有效地提升了时空对齐处理精度，进而降低了设计系统交通流数据对应的时间戳同步误差与空间坐标偏移量。

设计系统、对比系统 1 与对比系统 2 应用后交通流预测结果如图 6 所示。




图 6 交通流预测结果示意图

设计系统应用后交通流预测结果与实际结果趋于一致，而对比系统 1 与对比系统 2 应用后交通流预测结果与实际结果存在着较大的偏差。这主要是因为设计系统应用了时间感知 Transformer 模型，其通过引入时间嵌入层，有效捕捉了交通流数据中隐含的时间依赖性，这对于交通流这种具有显著日周期性、周周期性乃至年周期性特征的数据尤为重要。时间特征编码机制不仅帮助 Transformer 模型理解了时间点的绝对位置，还使其能够感知到不同时间点之间的相对关系，从而更准确地预测交通流量的变化趋势。与此同时，注意力机制的改进在处理每个时间步的数据时，能够动态地关注数据中所有其他时间步的信息，而不仅仅是相邻的时间步。此种全局依赖建模能力，使得设计系统能够捕捉到远距离的时间相关性，从而为交通流预测提供更有利的帮助。此外，多模态融合模块的添加对交通流数据特征进行了进一步的处理，能够有效降低改进模型的运算体量，从而提升改进模型的整体效率。综上所述，在时间感知 Transformer 模型的改进应用基础上，有效提升了模型在交通流预测任务中的适用性，从而大幅度地缩短了交通流预测结果与实际结果之间的差距。

#### 4 结束语

文章提出的基于时间感知 Transformer 的智能网联汽车交通流预测系统，通过硬件与软件的协同创新，有效解决了传统方法在复杂交通场景下的预测瓶颈。在硬件层面，通过高精度 GNSS/INS 与多线激光雷达的数据采集优化，结合 5G 边缘计算节点的部署，显著降低了数据传输延迟；在软件层面，时空对齐模块

的应用使多源数据时空偏差控制在 0.08% 的时间同步误差和 0.16 mm 的空间偏移范围内，而改进的时间感知 Transformer 模型通过融合周期特征嵌入、混合注意力机制和膨胀因果卷积，将预测误差降至 0.1%。实验结果表明，该系统不仅能够精准捕捉交通流的周期性规律和突发特征，而且在拥堵和事故等复杂场景下表现出优异的鲁棒性，为智能网联汽车的实时决策提供了可靠的技术支撑，具有重要的理论价值和工程应用前景。

#### 参考文献：

- [1] MEESE C, CHEN H, LI W, et al. Adaptive traffic prediction at the ITS edge with online models and Blockchain-Based federated learning [J]. IEEE Transactions on Intelligent Transportation Systems, 2024 (9): 25.
- [2] 陈以, 齐兴宇, 胡水源, 等. 基于 VMD 多阶段优化的短时交通流预测研究 [J]. 计算机仿真, 2025, 42 (1): 126-132.
- [3] 夏晶晶, 陈振. 融合核极限学习机与 PSR 的混沌交通流预测 [J]. 计算机工程与设计, 2024, 45 (6): 1880-1887.
- [4] 智慧, 段苗苗, 杨利霞, 等. 一种基于区块链和联邦学习融合的交通流预测方法 [J]. 电子与信息学报, 2024, 46 (9): 3777-3787.
- [5] 张俊溪, 曲仕茹, 张志腾, 等. 时空相关的道路网络短时交通流预测模型 [J]. 北京交通大学学报, 2024, 48 (3): 74-82.
- [6] 徐先峰, 杨凡, 刘状壮, 等. 基于两级筛选机制及深度学习组合模型实现短时交通流预测 [J]. 控制与决策, 2023, 38 (1): 84-92.
- [7] 张雄涛, 郑景玉, 申情, 等. 基于混合图卷积的多通道时空交通流预测模型 [J]. 电信科学, 2023, 39 (9): 97-110.
- [8] 赵子琪, 杨斌, 张远广. 基于图自编码器和 GRU 网络的分层交通流预测模型 [J]. 计算机科学, 2024, 51 (s1): 680-685.
- [9] PATIL S V, HASHIMOTO K, KISHIDA M. A robust traffic flow control using connected vehicle technology: signal Spatio-Temporal Logic-Based approach [J]. IEEE Transactions on Intelligent Transportation Systems, 2024 (12): 25.
- [10] 余亚男, 贾勇, 杜玲丽, 等. 基于时空 Transformer 的毫米波雷达三维人体姿态重构 [J]. 信号处理, 2024, 40 (10): 1910-1920.
- [11] 石泽男, 陈海鹏, 张冬, 等. 预训练驱动的多模态边界感知视觉 Transformer [J]. 软件学报, 2023, 34 (5): 2051-2067.

(下转第 51 页)