

DOI:10.16544/j.cnki.cn43-1494/u.20250712001

文章编号:1674-599X(2026)02-0079-09

引用格式:贾文文,吴栋,范占永.基于图多头注意力与 t 分布GARCH耦合的交通流概率预测模型[J].交通科学与工程,2026,42(2):79-87.

Citation: JIA Wenwen, WU Dong, FAN Zhanyong. Traffic flow probability prediction model based on coupling of graph multi-head attention and t -distributed GARCH[J]. Journal of Transport Science and Engineering, 2026, 42(2): 79-87.

基于图多头注意力与 t 分布GARCH耦合的交通流概率预测模型

贾文文,吴栋,范占永

(圆测信息科技股份有限公司,江苏 苏州 215027)

摘要:【目的】交通流时间序列具有复杂的非线性、显著的时空依赖性与较强的不确定性等特征,通过构建融合图多头注意力网络(GMAN)与 t 分布广义自回归条件异方差(GARCH- t)模型的概率预测模型,为智能交通管理提供兼具高精度长期均值预测能力与可靠区间估计效果的决策支持工具。【方法】将GMAN与GARCH- t 模型深度耦合,提出GMAN-GARCH- t 模型。首先,通过多头时空注意力机制动态捕捉路网节点间的非线性时空关联,精准提取交通流演化的核心特征;然后,采用GARCH- t 模型精确量化预测残差的异方差性;最后,构建“点预测-区间估计”协同优化的双层输出结构。在苏州市105个路段的实测数据上,对所提模型1至12步预测进行了验证。【结果】在均值预测中,12步预测的平均绝对误差为17.22辆/5 min;在区间估计中,95%置信区间的覆盖率达94.6%,且区间宽度可自适应交通状态变化。【结论】GMAN-GARCH- t 模型通过融合时空注意力机制与厚尾波动率建模方法,实现了交通流概率预测精度与可解释性的同步提升,可为动态交通管控提供可靠的量化决策依据。

关键词:交通流时间序列;图多头注意力;厚尾波动率;概率预测;时空关联

中图分类号:U491 文献标志码:A

Traffic flow probability prediction model based on coupling of graph multi-head attention and t -distributed GARCH

JIA Wenwen, WU Dong, FAN Zhanyong

(Yuance Information Technology Co., Ltd., Suzhou 215027, China)

Abstract: [Purposes] Traffic flow time series possess complex nonlinearity, significant spatio-temporal dependence, and strong uncertainty. Long-term prediction is more valuable in practical traffic management applications. This study aims to construct a probabilistic prediction model that integrates a graph multi-head attention network (GMAN) with a t -distributed generalized autoregressive conditional heteroscedasticity (GARCH- t) model. This provides decision support tools for intelligent traffic management that combine high-precision long-term mean prediction with reliable interval estimation. [Methods] A deep coupling model integrating GMAN and GARCH- t (the GMAN-GARCH- t model) was proposed. First, a multi-head spatio-temporal attention mechanism was applied to dynamically capture the nonlinear spatio-temporal correlations among road network nodes, accurately extracting the core features of traffic flow evolution. Second, the GARCH- t model was adopted to accurately quantify and predict the heteroscedasticity of the residuals. Finally, a dual-layer

收稿日期:2025-07-12

基金项目:国家重点研发计划“综合交通运输与智能交通”重点专项(2020YFB1600700)

通信作者:贾文文(1989—),女,工程师,主要从事交通智能化方面的研究工作。E-mail:mejwdd@163.com

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

output structure enabling collaborative optimization of "point prediction-interval estimation" was constructed. The model was validated on measured data from 105 road sections in Suzhou City for predictions spanning 1 to 12 time steps. [Findings] In the mean prediction, the mean absolute error (MAE) of the 12-step prediction reaches 17.22 vehicles/5 min. In interval estimation, the coverage rate of the 95% confidence interval reaches 94.6%, and the interval width can adapt to changes in traffic conditions. [Conclusions] Through the organic integration of spatio-temporal attention mechanism and thick-tail volatility modeling, the GMAN-GARCH- t coupling model simultaneously improves the accuracy and interpretability of traffic flow probability prediction, providing a reliable quantitative decision-making basis for dynamic traffic control.

Key words: traffic flow time series; graph multi-head attention; thick-tail volatility; probability prediction; spatio-temporal correlation

随着智慧城市建设与交通强国战略的深入推进,交通系统已成为城市数字孪生的核心载体,对其运行状态的精准刻画与科学预测已成为提升城市交通治理效能的关键^[1]。交通流预测不仅能直接助力交通拥堵缓解与通行效率提升,更在宏观路径规划、重大活动交通保障、基础设施智能养护等决策场景中发挥着重要的战略支撑作用。

交通流预测的主要研究方法包括传统非线性回归^[2]、自回归滑动平均^[3]、 k 近邻^[4]、卡尔曼滤波^[5-7]、支持向量机^[8]和贝叶斯网络^[9]等,这类方法虽具备较强的理论可解释性,但因依赖平稳性、线性关系等强假设,在处理复杂且高度非线性的交通数据时表现欠佳。

近年来,已有学者将交通流预测问题转化为图建模问题^[10-11],综合考量交通流非线性的时间演变特征与动态的空间关联特征;在此基础上,各类卷积神经网络相关方法被应用于短期交通流预测研究,如图神经网络^[12]、图注意力网络^[13]、长短期记忆网络^[14]等。相较于传统方法,这类方法在短期确定性交通流预测的精度上实现了显著提升。然而,这类方法仅能给出点估计结果,无法解决长期预测中误差累积传播与不确定性量化等问题^[15-16]。尽管EFRON^[17]提出的概率预测方法试图通过构造预测区间表征不确定性,却存在诸多缺陷:预测区间宽度与实际交通状态脱节、平峰时段区间设定过度保守、高峰时段区间设定覆盖不足、残差波动未与交通影响要素建立关联、预测区间缺乏物理层面的可解释性等。上述不足导致现有不确定性量化方法难以适配高可靠性要求的交通管控场景,因此,我们不仅需要得到精准的交通流点预测结果,更需要得到可靠的不确定性量化结果。

针对上述问题,本文提出一种基于图多头注意力网络(GMAN)^[18]与 t 分布广义自回归条件异方差(GARCH- t)模型^[19]的预测模型(GMAN-GARCH- t),以实现时空动态建模与残差不确定性量化的融合。该模型通过联合优化时空特征提取与波动率建模过程,实现长期交通流的概率预测,并将预测区间作为核心输出形式开展模型评估与实际应用。预测结果表明,该模型可依托预测区间的可信度评估,实现交通管控资源的前置精准配置,有效提升交通规划的科学与应急响应时效性,为交通管理部门提供兼具可靠性与物理可解释性的决策支撑工具。

1 GMAN-GARCH 区间预测模型

1.1 模型总体结构

GMAN-GARCH模型由时空嵌入、时空注意力层^[20]、编码器-解码器(ED)^[21]及GARCH波动率模块构成。ED是深度学习领域经典的模型框架,针对交通流未来长期多步预测任务,该框架通过编码器将长时序交通流编码为特征向量,在模型训练阶段依托交通流周期数据训练编码器,并通过解码器对该特征向量进行解码预测,可有效解决单一图多头注意力神经网络在长期预测中存在的误差累积传播问题,进而提升预测精度。

模型整体架构如图1所示。第一步将原始交通流数据输入GMAN模型,通过时空嵌入模块捕捉交通流在时间与空间维度的相关性。其中,空间注意力可视为一种自适应空间区域选择机制,空间维度下不同位置的交通状态相互影响,具备显著的动态特征,该机制能够自适应捕捉空间维度中各节点间

的动态关联关系;时间注意力则是一种动态时间选择机制,用于判定注意力的作用时序,该机制可对不同时间步之间的非线性相关特征自适应建模。在此基础上,模型结合时空注意力机制与ED结构,输出1~12步的交通流均值预测结果。

第二步进行波动性建模,首先计算交通流真实值与预测均值的差值得到残差序列,并对该残差序列进行t分布拟合;然后构建具备状态自适应特性的GARCH波动率模型,将拟合后的残差序列作为该模型的输入完成波动率建模。

第三步生成区间预测结果,基于交通流预测均值、模型输出的条件方差及t分布分位数,求解得到动态的交通流区间预测结果。

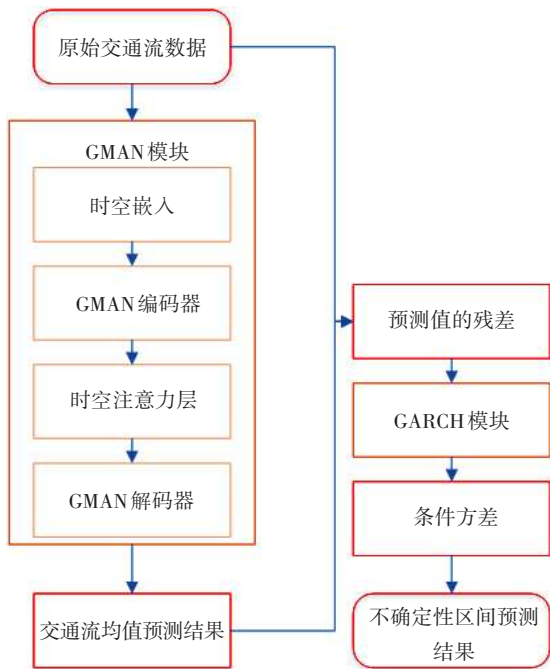


图1 GMAN-GARCH 区间预测模型总体架构

Fig. 1 General architecture of GMAN-GARCH interval prediction model

1.2 GMAN

GMAN 是一种多层图注意力网络,通过空间注意力、时间注意力与门控注意力对动态时空依赖关系协同建模。道路网络可看作加权有向图 $G = (V, E, A)$, 其中 V 为道路网络中所有节点的集合, E 为所有边的集合, A 为加权邻接矩阵, 其元素值表示不同节点间的相关程度。

网络通过全连接层生成空间嵌入向量 $e_{v_i}^{(S)}$, $v_i \in V$ 和时间嵌入向量 $e_{t_j}^{(T)}$, $t_j \in \{t_1, t_2, \dots, t_{p+Q}\}$, 其中 $\{t_1, t_2, \dots, t_{p+Q}\}$ 为时间步集合, P 为历史时间步长

度, Q 为未来时间步长度。

将空间嵌入向量和时间嵌入向量融合为时空嵌入向量, 时空嵌入向量为:

$$e_{v_i, t_j} = e_{v_i}^{(S)} + e_{t_j}^{(T)} \quad (1)$$

通过时空嵌入, 将路网的结构特征与交通流的时间信息融合至时空注意力机制中。在ED结构中, 编码器与解码器均由 L 个时空注意力模块堆叠而成, 第 l 个时空注意力模块的输入为 $H^{(l-1)}$, 节点 v_i 在时间步 t_j 的隐藏状态为 $h_{v_i, t_j}^{(l-1)}$, 第 l 层的时空输出为 $H^{(l)}$, 空间、时间输出分别为 $H_S^{(l)}$ 、 $H_T^{(l)}$, 隐藏层空间、时间输出分别为 $h_{S_{v_i, t_j}}^{(l)}$ 和 $h_{T_{v_i, t_j}}^{(l)}$ 。

在时间步 t_j , 节点 v_i 的第 l 层隐藏状态为:

$$h_{S_{v_i, t_j}}^{(l)} = \sum_{v \in V} \alpha_{v_i, v} h_{v, t_j}^{(l-1)} \quad (2)$$

式中: $\alpha_{v_i, v}$ 为注意力分数, 表示节点 v 对节点 v_i 的重要程度, $\sum_{v \in V} \alpha_{v_i, v} = 1$ 。

将隐藏状态和时空嵌入拼接起来计算节点 v_i 与节点 v 之间的相关性。时间注意力与空间注意力的实现方式相近, 仅存在一处差异: 空间注意力在空间维度上捕捉节点间的依赖关系, 而时间注意力在时间维度上捕捉时间步间的依赖关系。

每个时空注意力模块还包含一个门控融合机制, 用于自适应地融合时间与空间特征。设第 l 个空间注意力与时间注意力的输出分别为 $H_S^{(l)}$ 和 $H_T^{(l)}$, 则 $H_S^{(l)}$ 和 $H_T^{(l)}$ 按如下公式融合:

$$H^{(l)} = z \odot H_S^{(l)} + (1 - z) \odot H_T^{(l)} \quad (3)$$

式中: z 为门控权重。 z 越接近 1, 模型越依赖空间注意力的输出; z 越接近 0, 模型则越依赖时间注意力的输出。

为降低长周期预测中不同时间步之间的误差传播效应, 在编码器与解码器之间引入转换注意力层, 以刻画各未来时间步与历史时间步之间的直接依赖关系。

对于节点 v_i , 其未来时间步与历史时间步的相关性 $\rho_{v_i, t}$ 通过该节点在 t_j 时刻的空间嵌入向量 e_{v_i, t_j} 和 t 时刻的空间嵌入向量 $e_{v_i, t}$ 来衡量:

$$\rho_{v_i, t} = \frac{\langle e_{v_i, t_j}, e_{v_i, t} \rangle}{\sqrt{d}} \quad (4)$$

式中: d 为向量 e_{v_i, t_j} 和 $e_{v_i, t}$ 的维度。

1.3 编码器-解码器架构

GMAN 采用ED架构。在输入编码器前, P 个历史时间步的交通流序列 $X_t = [X_1, X_2, \dots, X_p]$ 经全连

接层映射为 $H^{(0)}$;将 $H^{(0)}$ 输入由 L 个时空注意力模块堆叠而成的编码器,得到输出 $H^{(L)}$;随后通过转换注意力层,将编码特征 $H^{(L)}$ 转换为未来序列 $H^{(L+1)}$ 。解码器将 L 个时空注意力模块堆叠在 $H^{(L+1)}$ 上,得到输出 $H^{(2L+1)}$,最后经由全连接层输出 Q 个时间步的交通流预测序列:

$$\hat{X}_i = [\hat{X}_{p+1}, \hat{X}_{p+2}, \dots, \hat{X}_{p+Q}] \quad (5)$$

交通流预测残差 ε_i 为:

$$\varepsilon_i = X_i - \hat{X}_i \quad (6)$$

1.4 GARCH模型

在金融领域,GARCH模型是一类常用于波动率分析的经典模型,能够有效刻画时间序列波动性聚集的特征。与金融时间序列类似,交通流数据同样呈现出显著的波动性聚集的特征,因此将GARCH模型引入交通流分析与预测中。然而,传统GARCH模型基于残差服从正态分布的假设,而在实际场景中,交通流序列因拥堵出现异常波动的概率,远比正态分布所预测的概率高。若直接采用正态分布,会严重低估极端事件的发生风险,进而导致模型生成的预测区间过窄。

与正态分布相比, t 分布具有更厚的尾部特征,能够更好地描述极端事件。因此,本文在GARCH模型中采用 t 分布拟合预测残差。当极端事件发生时,基于 t 分布的GARCH模型可生成更宽的预测区间,从而更有效地覆盖可能出现的极端事件。上述区间拓宽机制由预测残差的条件方差与 t 分布的自由度参数共同决定。

2 案例应用与分析

2.1 数据说明

本文选取苏州市2022年10月1日至2022年11月24日105个路段的电警数据作为样本,验证GMAN-GARCH混合模型的预测精度。首先将原始数据按5 min时间粒度进行聚合,再划分训练集、验证集与测试集。模型选取10月1日至11月9日共40 d的交通流量数据构建训练集,该时段覆盖工作日、周末及节假日等多种交通模式,可使模型学习到更全面的交通流动态特征,进而提升模型的泛化能力;模型选取11月10日至11月19日共10 d的交通流量数据构建验证集;模型选取11月20日至11月24日共5 d的交通流量数据构建测试集。

2.2 试验设置

GMAN模型采用均方误差(MSE)作为损失函数,优化器选用自适应矩估计(Adam)优化器,初始学习率设为0.001,训练批次设为16;为保证试验结果的可靠性,使用5个不同的随机种子重复训练,并计算多次运行结果的平均值。

GARCH模型以最大似然函数作为损失函数;整体预测过程采用滑动时间窗的方式开展多步滚动预测,滑动窗口的步长设为1。

2.3 评价指标

为检验预测模型的精度,本文采用平均绝对误差(MAE)和均方根误差(RMSE)评价预测效果,采用无效覆盖率(ICR)和宽度流量比(CV)评价区间预测效果。

2.4 分布拟合分析

区间预测的常用方法主要包括非参数自助重抽样(Bootstrap)与基于正态分布假设的GARCH模型方法。然而在交通流预测中,预测残差通常不满足传统建模所假设的正态分布。为准确刻画其分布特征,本文首先对预测残差的分布形态进行分析,预测残差Q-Q图如图2所示。




图2 Q-Q图

Fig. 2 Q-Q plot

由图2可知,特定时间步长下预测残差的Q-Q图曲线呈“S”形而非直线,这表明残差显著偏离正态分布。与正态分布相比,该残差Q-Q图两端的样本点分别向上与向下弯曲,这表明残差序列存在比正态分布更多的极大正值与极小负值,即呈现出厚

尾特征。计算特定时间步长下残差分布的峰度,结果均大于0(正态分布峰度为0),这表明该残差分布较正态分布更为陡峭。因此,该残差序列呈现出明显的尖峰厚尾特征。

为量化评估不同分布对残差的拟合效果,本文基于残差平方和(SSE)与贝叶斯信息准则(BIC),对比了正态分布、*t*分布和拉普拉斯分布的拟合优度,结果如图3所示。




图3 各分布拟合结果

Fig. 3 Fitting results of various distributions

由图3可知,无论是单步还是多步预测的残差,*t*分布的拟合效果均最好,明显优于正态分布和拉普拉斯分布的拟合效果。因此,本文采用*t*分布对预测残差进行拟合。

2.5 均值预测结果分析

本文对105个路段的交通流量序列进行了全面评估,对每个序列分别计算性能指标并取平均值作为算法的整体性能。依据式(1)~(5)可得到GMAN模型在多个特定时间步长下的均值预测结果,具体

如图4所示。

由图4可知,无论是短时(5~<15 min)还是长时(15~60 min)预测,GMAN模型的预测结果与实际数据均高度吻合。

依据MAE和RMSE的计算公式,可得到GMAN模型均值预测结果的各项评价指标。自回归积分移动平均(ARIMA)模型、时空图卷积网络(STGCN)模型及GMAN模型的预测性能见表1、表2。

表1 12个时间步长内的预测性能

Table 1 Prediction performance over 12 time steps

模型	MAE/[辆·(5 min) ⁻¹]	RMSE/[辆·(5 min) ⁻¹]
ARIMA	21.16	27.78
STGCN	15.07	27.22
GMAN	14.85	23.10

由表1可知,GMAN模型在12个时间步长内的预测性能指标(MAE、RMSE)均比ARIMA和STGCN模型的优。

表2 多个特定时间步长下的预测性能

Table 2 Prediction performance under multiple specific time steps

模型	时间步长	MAE/[辆·(5 min) ⁻¹]	RMSE/[辆·(5 min) ⁻¹]
ARIMA	1	15.87	20.56
	3	18.07	23.67
	6	20.56	27.17
	12	26.09	34.28
STGCN	1	13.46	24.28
	3	13.98	25.18
	6	14.72	26.56
	12	17.26	31.08
GMAN	1	14.42	22.33
	3	13.93	21.53
	6	14.09	21.86
	12	17.22	27.11

由表2可知,GMAN模型在各时间步长下的MAE和RMSE大多比ARIMA和STGCN模型的小,这表明GMAN模型在多数不同预测步长上能实现更准确的预测。同时,GMAN模型的MAE、RMSE随预测步长的波动较小,这表明该模型能较好地解决误差累积问题,具有良好的稳定性与预测精度。因此,GMAN模型可以更准确地实现交通流多步预测。

2.6 区间预测结果分析

在95%置信区间下,依据图3的拟合结果,可得到基于GMAN-GARCH-*t*模型的交通流区间预测结果。GMAN-GARCH-*t*模型与各对照模型在多个特定时间步长下的拟合效果如图5所示。

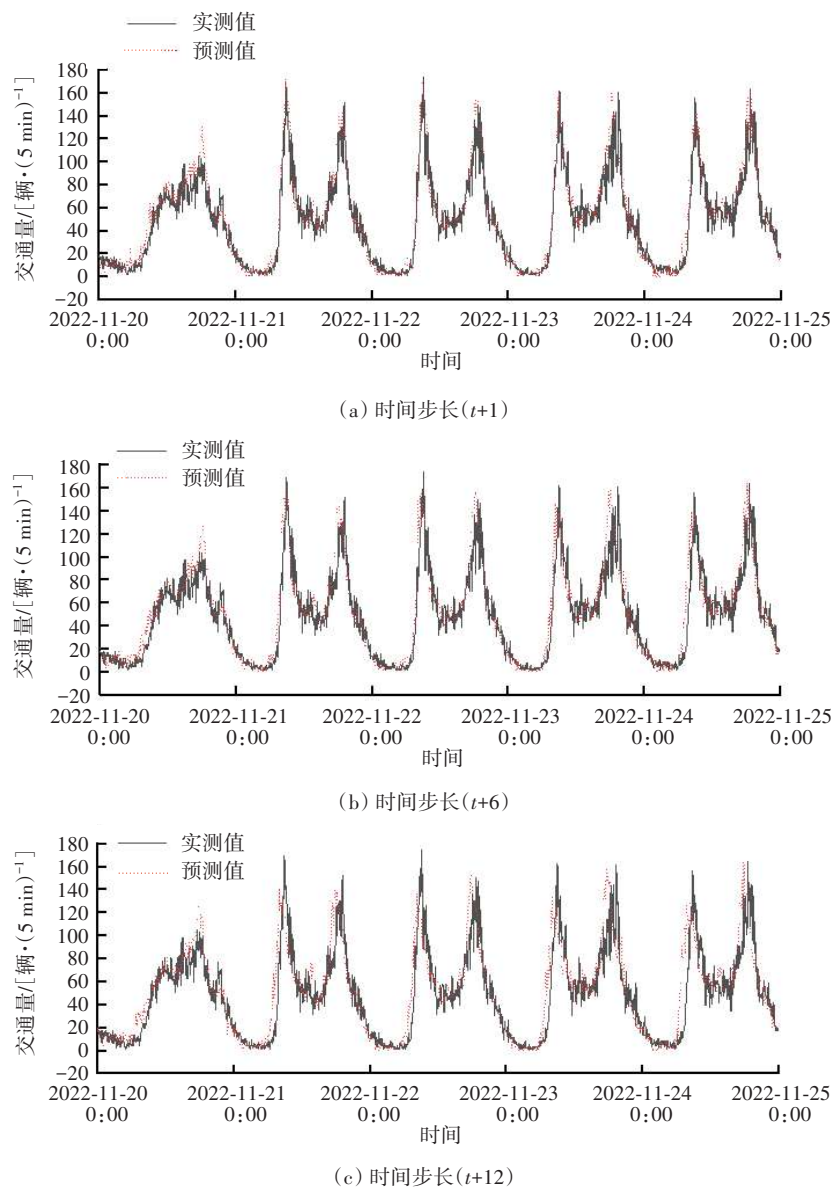


图4 交通流均值预测结果

Fig. 4 Mean prediction results of traffic flow

由图5可知,区间预测结果并未随步长增加而显著发散。GMAN-Bootstrap模型预测结果的区间宽度较为僵化(平峰时段区间过宽、高峰时段区间过窄),无法有效反映交通流的真实波动。GMAN-GARCH模型预测结果的区间宽度整体上偏窄,在交通流高峰时段的区间覆盖效果较差。而GMAN-GARCH- t 模型预测的区间宽度可动态匹配交通流量波动,尤其在交通流高峰时段,相较于GMAN-GARCH与GMAN-Bootstrap模型,其区间覆盖性更好,能更合理地度量交通流的波动范围。

对GMAN-GARCH- t 模型及各对照模型在多个特定时间步长下的交通流区间预测结果进行评价,结果如图6所示。

由图6可知,在预测步长1~12范围内,GMAN-GARCH模型的区间预测无效覆盖率显著高于5%。这表明,残差服从正态分布的假设低估了极端事件的发生概率,导致所构建的预测区间过窄,覆盖率严重不足。相比之下,GMAN-GARCH- t 与GMAN-Bootstrap模型的区间预测无效覆盖率均接近5%的理论值,预测结果更为可靠。

具体而言,在95%置信水平下,GMAN-Bootstrap模型的区间预测覆盖率为94.0%,而GMAN-GARCH- t 模型的区间预测覆盖率可达94.6%,较前者高出0.6个百分点。同时,在相同预测时间步长下,GMAN-GARCH- t 模型区间预测的宽度流量比均比GMAN-Bootstrap模型区间预测的小。在相同的置

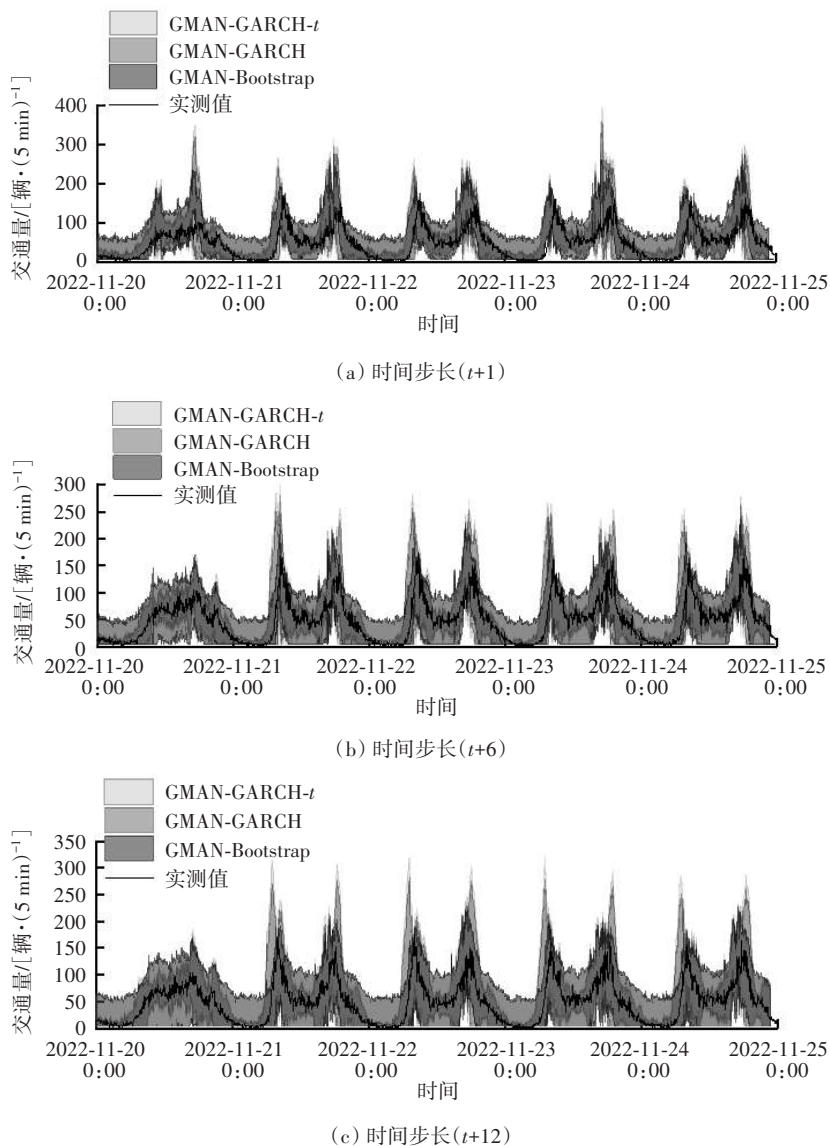


图5 交通流区间预测结果

Fig. 5 Interval prediction results of traffic flow

信水平下,预测区间越窄,则信息有效密度越高,对交通流预测不确定性的界定能力越强,越有利于辅助决策。GMAN-GARCH- t 模型通过对预测残差进行 t 分布拟合,能够更好地刻画残差的尖峰厚尾特征,从而构建出更为精准的预测区间。

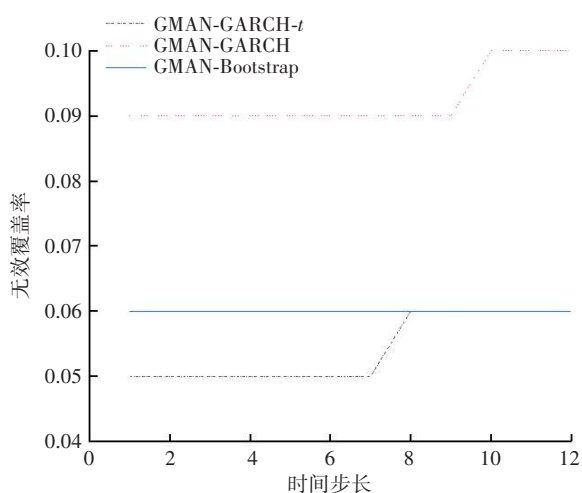
总体而言,GMAN-GARCH- t 模型区间预测的宽度流量比比GMAN-Bootstrap模型区间预测的降低了1.4%。这表明该模型借助 t 分布的厚尾特征,实现了覆盖精度与信息密度的均衡,可为动态交通管控提供更为可靠的决策依据。

3 讨论

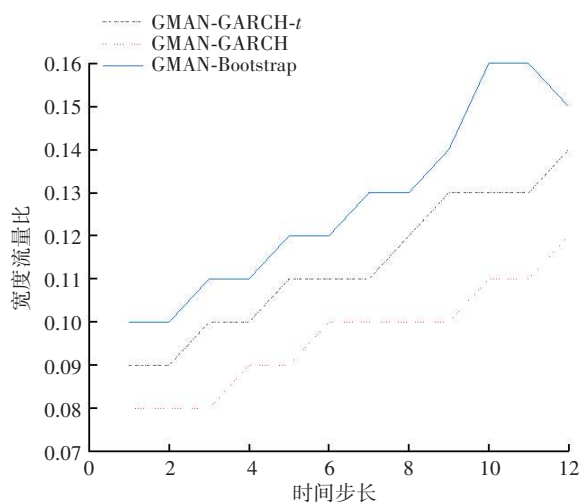
本文提出的GMAN-GARCH- t 模型能够实现长

期稳定的多步点预测,并可精准量化预测的不确定性,输出可靠的预测区间。基于苏州电警数据开展的试验结果表明,该模型的区间预测覆盖率可达94.6%,且整体上区间预测的宽度流量比维持在较低水平。与GMAN-GARCH、GMAN-Bootstrap等模型相比,本文所提模型在覆盖精度与信息密度的综合权衡上表现更优。

该模型框架可为交通管控提供决策支持。在信号控制方面,信号控制系统可依据预测区间宽度动态调整控制策略,指导信号配时优化:区间过宽,表明当前交通流波动性较强,可结合区间预测上限值,采用韦伯斯特配时法计算信号配时方案,形成保守控制策略,或提示管理人员进行人工干预,提升系统鲁棒性。在导航路径推荐方面,借助稳定的



(a) 无效覆盖率



(b) 宽度流量比

图6 区间预测评价

Fig. 6 Interval prediction evaluation

多步点预测与不确定性量化结果,可全面感知未来5 min至1 h的交通态势,实施分流引导,提升交通系统的弹性与可靠性,并为用户提供多种行程时间参考。

4 结论

1) 本文提出的GMAN-GARCH- t 混合模型,借助时空信息融合学习机制,能够自适应刻画动态空间相关性与非线性时间相关性。该模型具备良好的稳定性与预测精度,可较好解决传统交通流预测模型存在的误差累积问题。

2) 基于 t 分布拟合的GARCH模型能够借助 t 分布的厚尾特征有效捕捉交通流极端波动,可更精准量化交通流的不确定性。

3) GMAN-GARCH- t 模型为城市道路交通流概

率预测提供了新思路,其动态区间预测结果可有效支撑拥堵预警与管控资源的优化配置。

本文的研究仍存在若干待解决的问题与值得深入拓展的研究方向。例如在交通流不确定性来源分解方面,本文仅将其作为整体进行量化分析,忽略了数据噪声与交通流自身的内在随机性。后续将引入贝叶斯深度学习框架,对不确定性来源进行有效分解,从而为交通管理决策提供更具针对性的支撑信息。

参考文献(References):

- [1] 贾文文. 短时交通流预测中的分布特征分析和建模[D]. 南京: 东南大学, 2017.
JIA Wenwen. Analysis and modeling of distribution characteristics in short-term traffic flow forecasting[D]. Nanjing: Southeast University, 2017.
- [2] HÖGBERG P. Estimation of parameters in models for traffic prediction: a non-linear regression approach[J]. Transportation Research, 1976, 10(4): 263-265. DOI: 10.1016/0041-1647(76)90059-9.
- [3] 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. DOI: 10.1061/(asce) 0733-947x (2003) 129: 6(664).
- [4] ZHANG L, LIU Q C, YANG W C, et al. An improved K-nearest neighbor model for short-term traffic flow prediction[J]. Procedia-Social and Behavioral Sciences, 2013, 96: 653-662. DOI: 10.1016/j.sbspro.2013.08.076.
- [5] OKUTANI I, STEPHANEDES Y J. Dynamic prediction of traffic volume through Kalman filtering theory [J]. Transportation Research (Part B: Methodological), 1984, 18(1): 1-11. DOI: 10.1016/0191-2615(84)90002-X.
- [6] 杭明升, 杨晓光, 彭国雄. 基于卡尔曼滤波的高速道路行程时间动态预测[J]. 同济大学学报(自然科学版), 2002, 30(9): 1068-1072. DOI: 10.3321/j.issn: 0253-374X.2002.09.008.
HANG Mingsheng, YANG Xiaoguang, PENG Guoxiong. Study of predicted travel time in urban expressway based on Kalman filter[J]. Journal of Tongji University (Natural Science), 2002, 30(9): 1068-1072. DOI: 10.3321/j.issn: 0253-374X.2002.09.008.
- [7] YE Z R, ZHANG Y L, MIDDLETON D R. Unscented Kalman filter method for speed estimation using single loop detector data[J]. Transportation Research Record: Journal of the Transportation Research Board, 2006, 1968(1): 117-125. DOI: 10.1177/0361198106196800114.
- [8] 何祖杰, 吴新焯, 刘中华. 基于改进灰狼算法优化支

- 持向量机的短期交通流预测[J]. 厦门大学学报(自然科学版), 2022, 61(2): 288-297. DOI: 10.6043/j.issn.0438-0479.202104024.
- HE Zujie, WU Xinye, LIU Zhonghua. Optimized SVM model for short-term traffic flow prediction based on improved gray wolf optimizer [J]. Journal of Xiamen University (Natural Science), 2022, 61(2): 288-297. DOI: 10.6043/j.issn.0438-0479.202104024.
- [9] LIU Z B, YANG Z S, GAO P. Research on the short-term traffic flow prediction method based on BP neural networks[C]//World Automation Congress 2012. Puerto Vallarta: IEEE, 2012: 1-4.
- [10] DIAO Z L, WANG X, ZHANG D F, et al. Dynamic spatial-temporal graph convolutional neural networks for traffic forecasting [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33(1): 890-897. DOI: 10.1609/aaai.v33i01.3301890.
- [11] YU B, YIN H T, ZHU Z X. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting [C]//Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence. Stockholm: International Joint Conferences on Artificial Intelligence Organization, 2018: 3634-3640. DOI: 10.24963/ijcai.2018/505.
- [12] 张玺君, 余光杰, 崔勇, 等. 基于聚类算法和图神经网络的短时交通流预测[J]. 吉林大学学报(工学版), 2024, 54(6): 1593-1600. DOI: 10.13229/j.cnki.jdxbgxb.20220950.
- ZHANG Xijun, YU Guangjie, CUI Yong, et al. Short-term traffic flow prediction based on clustering algorithm and graph neural network[J]. Journal of Jilin University (Engineering and Technology Edition), 2024, 54(6): 1593-1600. DOI: 10.13229/j.cnki.jdxbgxb.20220950.
- [13] JIN C H, RUAN T, WU D X, et al. HetGAT: a heterogeneous graph attention network for freeway traffic speed prediction [J]. Neural Computing and Applications, 2021, 33(13): 7891-7904. DOI: 10.1007/s00521-020-05586-9.
- [14] 刘清梅, 万明, 严利鑫, 等. 基于集合经验模态分解降噪和优化LSTM的道路交通事故预测[J]. 交通信息与安全, 2023, 41(5): 12-23. DOI: 10.3963/j.jssn.1674-4861.2023.05.002.
- LIU Qingmei, WAN Ming, YAN Lixin, et al. A method for predicting traffic accidents based on an ensemble empirical mode decomposition and an optimized LSTM model[J]. Journal of Transport Information and Safety, 2023, 41(5): 12-23. DOI: 10.3963/j.jssn.1674-4861.2023.05.002.
- [15] 史昕, 胡欣倩, 赵祥模, 等. 基于神经微分方程的自适应图时空同步交通流预测方法[J]. 交通运输工程学报, 2025, 25(2): 170-188. DOI: 10.19818/j.cnki.1671-1637.2025.02.011.
- SHI Xin, HU Xinqian, ZHAO Xiangmo, et al. Adaptive graph spatio-temporal synchronization for traffic flow prediction based on NODEs [J]. Journal of Traffic and Transportation Engineering, 2025, 25(2): 170-188. DOI: 10.19818/j.cnki.1671-1637.2025.02.011.
- [16] 张韞, 张波, 王剑楠, 等. 基于动态时空特征周期性编码的公路交通流量预测模型[J]. 公路交通科技, 2025, 42(3): 21-33. DOI: 10.3969/j.issn.1002-0268.2025.03.003.
- ZHANG Yun, ZHANG Bo, WANG Jiannan, et al. Highway traffic flow prediction model based on periodic encoding with dynamic spatio-temporal features [J]. Journal of Highway and Transportation Research and Development, 2025, 42(3): 21-33. DOI: 10.3969/j.issn.1002-0268.2025.03.003.
- [17] EFRON B. Bootstrap methods: another look at the jackknife[J]. The Annals of Statistics, 1979, 7(1): 1-26.
- [18] ZHENG C P, FAN X L, WANG C, et al. GMAN: a graph multi-attention network for traffic prediction[C]//Proceedings of the AAAI Conference on Artificial Intelligence. New York: AAAI Press, 2020: 1056-1063.
- [19] 吴婷, 蒋阳升, 丁笑, 等. 城市轨道交通断面客流不确定性分析的广义自回归条件异方差改进模型[J]. 城市轨道交通研究, 2017, 20(5): 30-36. DOI: 10.16037/j.1007-869x.2017.05.007.
- WU Ting, JIANG Yangsheng, DING Xiao, et al. Improved GARCH model in urban rail transit based on uncertainty analysis of section passenger flow[J]. Urban Mass Transit, 2017, 20(5): 30-36. DOI: 10.16037/j.1007-869x.2017.05.007.
- [20] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C]//Advances in Neural Information Processing Systems. Red Hook: Curran Associates Inc., 2017, 30: 5998-6008. DOI: 10.5555/3295222.3295349.
- [21] 张锦, 皮煜, 孙程, 等. 面向交通流预测的时空编码器-解码器模型[J]. 国防科技大学学报, 2025, 47(3): 173-182. DOI: 10.11887/j.cn.202503018.
- ZHANG Jin, PI Yu, SUN Cheng, et al. Spatial-temporal encoder-decoder model for traffic flow prediction[J]. Journal of National University of Defense Technology, 2025, 47(3): 173-182. DOI: 10.11887/j.cn.202503018.

(责任编辑:熊怡;校对:石月珍)