http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0557

基于多模态时空特征融合的终端区交通拥堵精细化预测

李善梅*，宋思霓，王红勇，王端阳，赵末
(中国民航大学 空中交通管理学院，天津 300300)

摘 要：为提升对终端区未来交通态势把握的准确性和精细化，提出一套基于多模态时空特征融合的交通拥堵预测方法。从航空器滞留和管制负荷角度，采用交通流聚类技术，提出一种考虑交通流异质性的交通拥堵指数计算方法；将终端区空域进行四维时空区块划分，以时空区块为节点，构建动态邻接网络和交通流网络，表征终端区多模态的动态空间相关特征；提出一种基于三维卷积神经网络(3DCNN)+图卷积网络(GCN)+门控循环单元(GRU)的终端区交通拥堵预测模型。采用北京终端区航迹数据进行模型验证，结果表明：所提模型优于经典基线模型，与45 min和60 min时间尺度相比，30 min预测效果最好，相较于历史平均(HA)模型、指数加权平均(EMA)模型、支持向量机回归(SVR)模型，均方根误差(RMSE)和平均绝对误差(MAE)分别下降了21%和57%、38%和72%、19%和51%；相较于只学习邻接空间特征、只学习交通流空间特征、改用长短时记忆(LSTM)学习时间特征，所提模型的RMSE和MAE分别下降了36%和40%、6%和8%、2%和2%。预测结果表明：航迹越复杂的区域，其预测误差越大，且随空域高度的上升，预测误差呈现出先增大后减小的变化规律。

关 键 词：航空运输；拥堵预测；深度学习；交通流网络；四维航迹
中图分类号：V355
文献标志码：A **文章编号**：1001-5965(2026)11-3852-12

近年来，随着中国民航业高速发展，航班量的快速增长加速了空中交通供需矛盾，导致空中交通拥堵现象愈演愈烈。终端区空域因其结构复杂、航班运行状态多样、飞行冲突多发、飞行受限多元、管制员工作负荷加大，成为空中交通拥堵最严重的空域，严重威胁交通运行安全与效率。因此，终端区交通拥堵状态的准确预测，有助于提高空中交通管理人员的态势感知能力，以便及时采取管控措施。

空中交通拥堵度量是拥堵预测的前提。目前，国内外关于拥堵度量方法的研究尚没有统一标准，主要分别从空中交通流的流动特性和航班群的复杂特性2个方面展开研究。交通流动特性方面，主要采用流量、速度、密度3个参数，对交通拥堵进行度量。比较有代表性的有：殷建棠等[1]将航段单位长度飞机平均飞行时间作为航段拥堵评估指标；李桂毅等[2]建立当量交通量、接近度、饱和度和交通密度4个扇区拥挤特征指标；Williams等[3]采用航班正常率、容流比和航班延误等指标度量交通拥堵。航班群复杂特性方面，主要采用飞行冲突数量、航班接近率等航空器相对位置的复杂特征对交通拥堵进行度量。比较有代表性的有：李善梅等[4]从复杂性的角度，构建了滞留度指标、汇聚度指标和当量交通量指标，进而度量交叉航路的交通拥堵态势；Tan等[5]以飞机为节点构建飞机网络，采用节

收稿日期：2024-07-21；录用日期：2024-08-23；网络出版时间：2024-09-05 10:38
网络出版地址：link.cnki.net/urlid/11.2625.V.20240904.1558.001
基金项目：国家自然科学基金(52672428,52202404)；天津市自然科学基金(24JCYBJC01170)；中国民航大学研究生科研创新项目(2025YJSKC03001)
*通信作者. E-mail：sm-li@cauc.edu.cn

引用格式：李善梅，宋思霓，王红勇，等. 基于多模态时空特征融合的终端区交通拥堵精细化预测[J]. 北京航空航天大学学报，2026，52(11)：3852-3863. Li S M，Song S N，Wang H Y，et al. Refined prediction of terminal area traffic congestion based on multimodal spatio-temporal feature fusion[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：3852-3863 (in Chinese).

点数、边数、平均节点度、环路数、平均聚类系数、平均路径长度、平均节点强度等 7 个网络复杂度指标作为扇区拥塞的度量指标。

上述研究主要从空中交通拥堵特征出发, 构建拥堵度量指标。与地面交通不同, 航空器的运行主要是在管制员的指挥下完成, 拥堵状态下往往伴随管制员工作负荷的增加。因此, 空中交通拥堵度量不仅应能体现空中交通流的流动和复杂特征, 还应能在一定程度上反映管制负荷的高低, 这样度量出来的结果更易被管制员接受并采纳。

空中交通拥堵预测方面, 主要有模型驱动和数据驱动方法。模型驱动方法主要通过构建数学预测模型。Lin 等[6] 引入概率统计模型对整个飞行过程中的随机因子进行建模, 进而实现对飞行轨迹的预测。张军峰等[7] 采用航空器意图模型、航空器动力与运动学模型相结合的方法, 实现了航空器四维航迹预测模型。Saraf 等[8] 提出一种自适应欧拉模型, 用于预测扇区流量。上述研究大多基于理想化的假设条件, 尽管模型较为明确, 但对于空中交通系统这样一个高维非线性问题来说, 其建模复杂性相对较大、处理能力有限, 导致预测精度不高。数据驱动方法是以真实的航班运行数据为基础, 利用数据科学与机器学习等理论和方法, 通过样本数据的训练、学习、迭代、进化, 挖掘交通参数演化的内在规律, 进而对未来交通态势进行预测。毛利民等[9] 建立了基于随机森林的终端区小时起降容量预测模型。李桂毅等[10] 等基于集成学习算法构建了一种航路交通拥挤识别模型, 实现高精度路网航段拥挤识别。Khanmohammadi 等[11] 提出双模型预测人工神经网络(dual-model prediction artificial neural network, DMP-ANN), 用于预测机场航班延误。Cai 等[12] 提出一种基于时间注意力感知的二部图卷积网络(temporal attention aware dual-graph convolution network, TAaDGCN)模型, 用于预测空中交通流量。焦卫东等[13] 提出一种基于融合多尺度卷积网络和时空双重注意力的时间卷积网络模型, 实现高精度航迹预测。Wang 等[14] 提出基于注意力机制的一维卷积神经网络(one-dimensional convolutional neural network, 1DCNN)-长短时记忆(long short-term memory, LSTM)短期交通流预测模型。刘晓琳等[15] 提出一种基于注意力机制的自适应图卷积门控循环单元 (attention-based adaptive graph convolution-gated recurrent unit, AAGC-GRU) 的航班延误预测模型。现有基于深度学习的空中交通预测取得了较为不错的预测效果, 但大多将三维空域抽象为二维进行研究, 缺乏从四维时空角度对空中交通态势演化规律进行研究, 以及将深度学习技术应用于终端区四维时空拥堵预测问题。

综上所述, 现有终端区交通拥堵度量及预测研究存在如下不足:

1) 现有研究多是从交通流滞留和航班群复杂角度构建平均意义下的拥堵指标, 不能充分反映管制负荷的大小, 导致度量结果与管制员的拥堵感知存在偏差, 较难被其接受。

2) 现有研究主要针对扇区交通拥堵进行预测, 缺乏从四维时空角度对扇区内部拥堵态势的精细化预测, 而这正是未来基于航迹运行(trajectory-based operations, TBO)空管模式有效运行的基础和关键。

3) 终端区交通运行具有较强的时空相关性。现有研究多从交通流拥堵参数时间序列中对交通状态演化的时间特征进行挖掘, 而终端区交通拥堵具有较强的空间相关特征, 且不同模态网络下呈现出不同的空间特征。

针对上述不足, 本文以终端区交通为研究对象, 首先, 提出一种同时考虑交通流动特性和管制负荷的拥堵指数计算方法; 然后, 精细划分终端区时空区块, 计算各区块拥堵指数, 并分析交通拥堵的时空分布特征; 在此基础上, 构建一种基于三维卷积神经网络(three-dimensional convolutional neural network, 3DCCN)、图卷积网络(graph convolutional networks, GCN)和门控循环单元(gated recurrent unit, GRU)相结合的终端区交通拥堵精细化预测模型, 该模型不仅能学习终端区拥堵时间相关性, 还能同时学习邻接网络和交通流网络的空间相关性; 最后, 采用北京终端区的实际航迹数据, 对本文模型的有效性进行验证。与现有空中交通拥堵度量及其预测方法相比, 本文工作有助于提升空管人员对终端区交通拥堵程度掌握的精细化、科学性和准确性, 以便采取更有效的拥堵管理措施, 也为未来 TBO 空管模式的实现提供理论基础。

1　空中交通拥堵度量

1.1　空中交通拥堵定义及拥堵指数建立

目前, 空中交通拥堵的定义尚没有统一标准。本文参考前人研究成果, 将空中交通拥堵定义为: 在一定时间和空间范围内, 由于空域需求大于空域容量而造成的航空器滞留现象[16-17]。滞留现象具体表现为, 交通拥堵态势下管制员往往指挥航空器进行绕飞、盘旋等待、减速等行为, 导致航空器在空域内的飞行时间增长, 交通流在空域内的流动速度变慢, 管制员为航空器提供管制服务的时间增多、工作负荷增大等。

基于空中交通拥堵定义及拥堵态势下航空器飞行时间变长的特点, 采用飞行时间构建单架航空器的拥堵指数φ_j, 计算式为

$$\varphi_j=\begin{cases}0 & t_j<T\\ (t_j-T)/T & t_j\geqslant T\end{cases} \tag{1}$$

式中：t_j为第j架航空器的实际飞行时间；T为航空器的标准飞行时间。

本文采用第j架航空器所在交通流中所有航空器的平均飞行时间，即

$$T=\sum_{j=1}^{n}\frac{t_j}{n} \tag{2}$$

式中：n为航空器数量。

目前，地面交通拥堵度量方法较为成熟，一般只需计算交通流中所有车辆的平均速度、平均行程时间等，表征交通流拥堵程度。与地面交通不同，航空器飞行是在管制员指挥下完成的，空中交通拥堵度量不仅要能反映空中交通流动快慢，也要能反映管制员工作负荷大小。若不同时段交通流的平均拥堵指数相同，但航空器数量不同，则对于管制员来说数量多的时段更为拥堵。另外，空域中往往存在多条交通流，且各交通流所对应飞行路径长度和飞行时间不同。如图1所示，空域中存在2条交通流，交通流A和B的标准飞行时间分别为20 min和10 min，该空域总体的标准飞行时间为15 min。若2条交通流各有一架航空器，实际飞行时间分别为20 min和10 min。若不考虑交通流异质性，该空域拥堵指数为max((20−15)/15,0)+max((10−15)/15,0)=1/3，实际上，2架航空器的实际飞行时间均未超过其所属交通流的标准飞行时间，该空域并未发生交通拥堵，拥堵指数为0。另外，终端区航空器的飞行时间主要受三维飞行路径长短的影响，相同路径下不同机型的飞行时间差与不同路径引起的飞行时间差比起来要小很多，因此，这里忽略不同机型对航空器平均飞行时间的影响。因此，考虑交通流异质性，构建综合表征交通流动快慢和管制负荷的交通拥堵指数，计算式为

$$\begin{cases}\varphi=\displaystyle\sum_{i=1}^{m}\sum_{j=1}^{n_i}\varphi_{ij}\\ \varphi_{ij}=\begin{cases}0 & t_{ij}<T_i\\ (t_{ij}-T_i)/T_i & t_{ij}\geqslant T_i\end{cases}\end{cases} \tag{3}$$

式中：φ_{ij}为某时空区块内第i条交通流第j个航空器所飞航迹的拥堵指数；t_{ij}为第i条交通流第j个航空器所飞航迹的飞行时间；T_i为第i条交通流的标准飞行时间；m为交通流的条数；n_i为第i条交通流的航迹条数；φ为平均拥堵指数，其值越大说明该区块越拥堵，反之越畅通。

1.2 空中交通拥堵指数计算流程

基于式(1)～式(3)，设计空中交通拥堵指数计算流程如下。

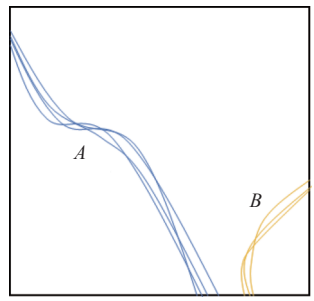

图1 不同交通流航迹

Fig. 1 Track of different traffic flows

步骤1 航迹数据预处理。受采集设备故障、恶劣天气等因素的影响，原始航迹数据中含有异常、缺失等问题。因此，首先对航迹数据进行预处理，主要包括：采用Z-score法进行异常值处理，通过线性插值将原航迹数据填充为1 s时间间隔的航迹点序列，以及对插值后航迹数据进行均匀重采样等工作，为后续计算做准备。

步骤2 交通流识别。为考虑交通流异质性，需要识别交通流。由于K-means聚类方法具有计算快速简单、对高维数据处理能力较强、参数设置简单等特点，使用基于欧氏距离的K-means聚类方法对重采样后的航迹进行聚类操作。

步骤3 目标空域区块划分。为精细化挖掘空中交通拥堵的时空演化特性，采用时空分解方法将目标空域划分成大小相等的四维时空区块。先将目标空域沿经度、纬度、高度方向划分为大小相同的三维网格，实现对目标空域的空间分解，进一步，将各网格的航迹数据按时间进行划分，获取四维时空区块划分结果。

步骤4 标准飞行时间计算。计算各时空区块中各航空器实际飞行时间及各条交通流的标准飞行时间T_i。

步骤5 航空器拥堵指数计算。基于式(1)计算各时空区块中各航空器拥堵指数φ_{ij}。

步骤6 时空区块拥堵指数计算。由φ_{ij}及式(3)计算各时空区块拥堵指数φ。

2 空中交通拥堵的时空特性分析

2.1 数据描述与拥堵指数计算

采用2023年7—9月北京终端区进场航迹数据对本文模型进行验证，包括首都机场、大兴机场及天津机场的实际进场飞行航迹各采样点的经度、纬度、速度、高度、时间等数据，共涉及99 346架航空器，约有183 472 682个航迹点。

首先，根据1.3节交通拥堵指数计算流程，对初

始航迹数据进行预处理工作, 共删除 237 个异常航迹点数据, 采用 1 s 时间间隔对航迹进行线性插值填充, 并对填充后的各条航迹进行均匀重采样操作, 使各条航迹的航迹点数均为 50 个, 便于后续航迹间相似度的计算。基于预处理后的航迹数据, 计算两两航迹之间的欧氏距离, 并采用 K-means 方法对航迹进行聚类, 从而识别终端区交通流, 识别结果如图 2 所示。

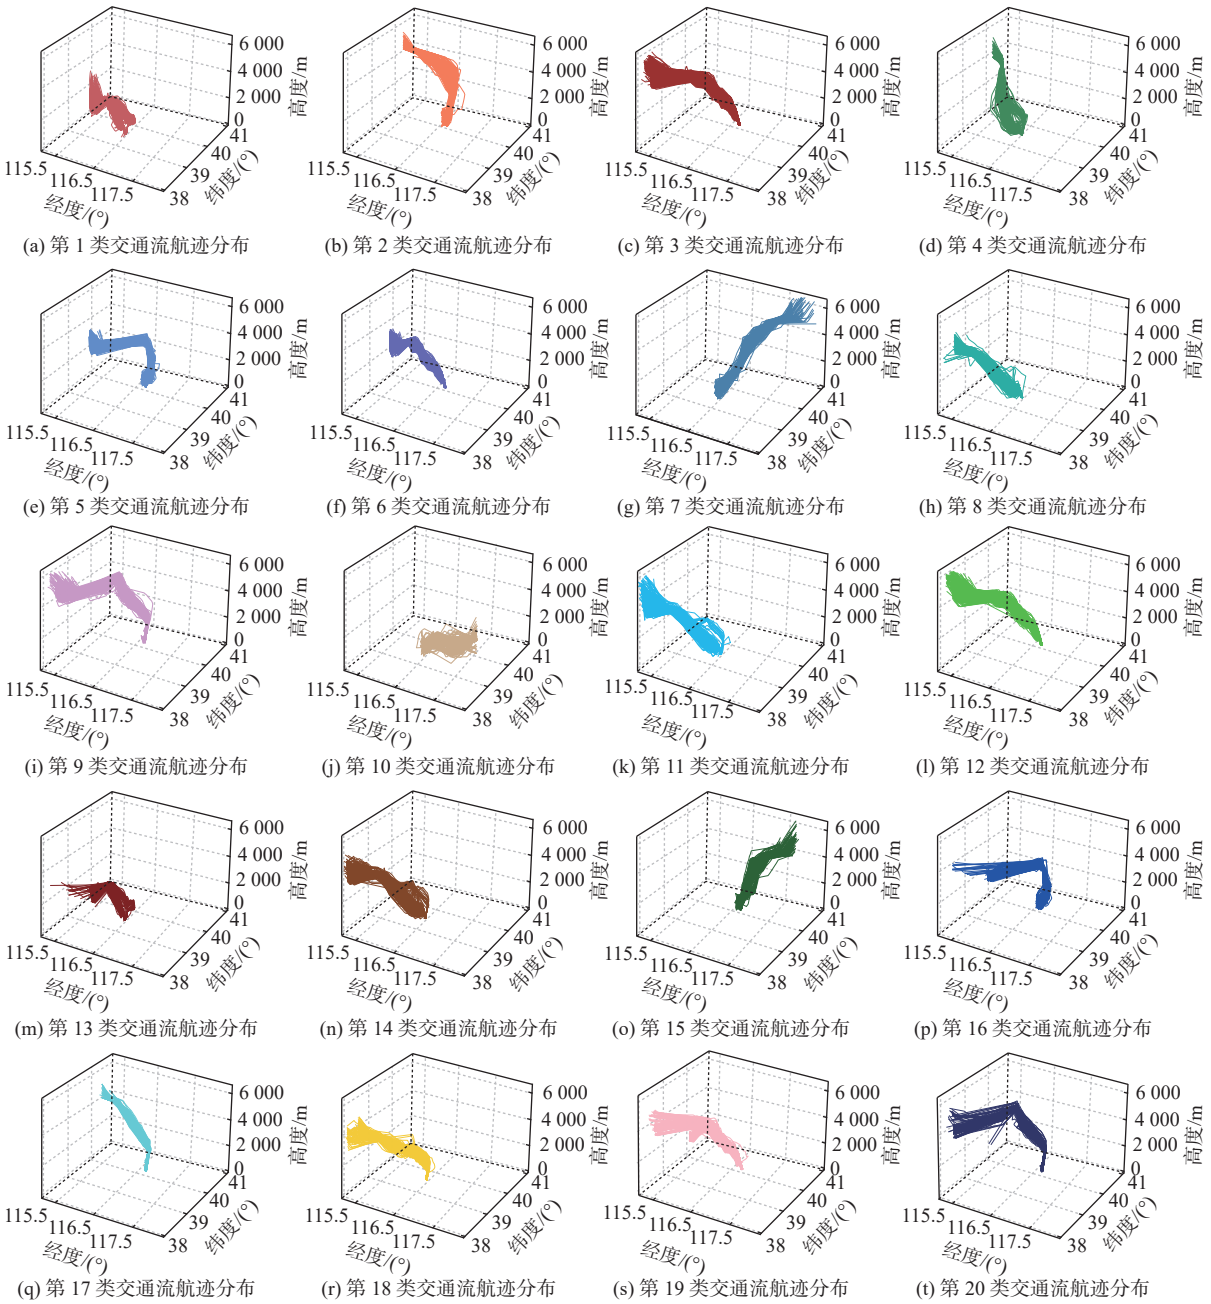

(a) 第 1 类交通流航迹分布　(b) 第 2 类交通流航迹分布　(c) 第 3 类交通流航迹分布　(d) 第 4 类交通流航迹分布

(e) 第 5 类交通流航迹分布　(f) 第 6 类交通流航迹分布　(g) 第 7 类交通流航迹分布　(h) 第 8 类交通流航迹分布

(i) 第 9 类交通流航迹分布　(j) 第 10 类交通流航迹分布　(k) 第 11 类交通流航迹分布　(l) 第 12 类交通流航迹分布

(m) 第 13 类交通流航迹分布　(n) 第 14 类交通流航迹分布　(o) 第 15 类交通流航迹分布　(p) 第 16 类交通流航迹分布

(q) 第 17 类交通流航迹分布　(r) 第 18 类交通流航迹分布　(s) 第 19 类交通流航迹分布　(t) 第 20 类交通流航迹分布

图 2　交通流识别结果

Fig. 2　Traffic flow recognition results

然后, 将北京终端区空域进行区块划分。由于北京终端区平面结构为不规则多边形, 为便于计算, 本文选取经度范围为东经 [115.2°, 118.2°], 纬度范围为北纬 [38°, 41°], 高度范围为 [0 m, 6 000 m] 的空间范围作为研究对象, 从而将北京终端区包含在内。为实现北京终端区的精细化拥堵预测, 将终端区进行三维区块划分。鉴于过小区块的交通态势信息会增大管制员对终端区运行态势掌控的复杂性, 且过大区块的交通态势信息对管制指挥意义不大, 因此, 通过咨询北京终端区一线管制员, 最终分别沿经度、纬度、高度 3 个方向, 将研究区域均匀划分为 4×4×4 个区块, 并对其进行编号, 如图 3 所示。在此基础上, 分别以 30 min、45 min、60 min 不同时间尺度对各时空区块进行时间划分, 从而将航迹数据划分到各时空区块上。

最后, 基于各时空区块的航迹数据, 按步骤 4～

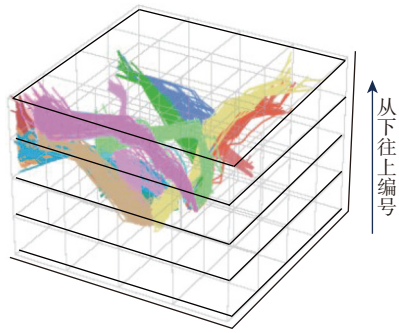

(a) 空间网格划分

33	34	35	36	49	50	51	52
37	38	39	40	53	54	55	56
41	42	43	44	57	58	59	60
45	46	47	48	61	62	63	64
1	2	3	4	17	18	19	20
5	6	7	8	21	22	23	24
9	10	11	12	25	26	27	28
13	14	15	16	29	30	31	32

(b) 空间网格编号

图 3 空间网格划分及编号

Fig. 3 Spatial grid partitioning and numbering

步骤 6 所述方法，计算各时空区块的拥堵指数。

2.2 空中交通拥堵的时空分布

基于 30 min 时间尺度拥堵指数计算结果，统计各时空区块的平均拥堵指数、平均飞行时长和平均交通量，限于篇幅限制，表 1 给出部分区块计算结果。经统计发现，27 个时空区块处于拥堵指数在 0～1×10^{-17} 之间的畅通状态，其中，24 个区块的平均交通量在 1～2 架之间，3 个区块的平均交通量在 2～2.2 架之间，平均飞行时间为 566.9 s；21 个时空区块处于平均拥堵指数在 1×10^{-17}～6×10^{-17} 之间的稳定状态，其中，18 个区块的平均交通量在 2～5 架之间，3 个区块的平均交通量在 1.6～1.9 架之间，平均飞行时间为 592.4 s；16 个时空区块处于平均拥堵指数在 6×10^{-17}～3×10^{-16} 之间的拥堵状态，平均交通量均在 5～16 架之间，平均飞行时间为 683.2 s。可见，时空区块的平均交通量越大，平均飞行时间越长，平均拥堵指数越高，交通拥堵越严重。

表 1 交通拥堵计算结果

Table 1 Calculation results of traffic congestion

时空区块	平均拥堵指数	平均飞行时长/s	平均交通量/架
1	0	819.8	1.0
2	0	469.4	1.1
3	1.07×10^{-17}	468.2	1.9
⋮	⋮	⋮	⋮
60	3.03×10^{-18}	681.3	1.4
61	3.14×10^{-18}	651.4	1.7
62	3.33×10^{-18}	612.0	1.7
63	7.4×10^{-18}	712.3	2.0

2.3 空中交通拥堵的时间相关性

2.3.1 周期性

各区块交通拥堵指数的日变化具有一定的相似性。以时空区块 6 为例，选取 2023 年 7 月前 3 周该区块的拥堵指数数据，并绘制拥堵指数时变图，如图 4 所示。可以看出，时空区块 6 拥堵指数的日变化呈现出较为明显的宏观周期性，拥堵高峰期一般处于每天 8:00—24:00 的时段，拥堵低峰期一般处于夜间 24:00—8:00，同时，相邻周之间也存在着潜在的相似关系。上述周期性主要是由航班计划具有较强稳定性造成的。

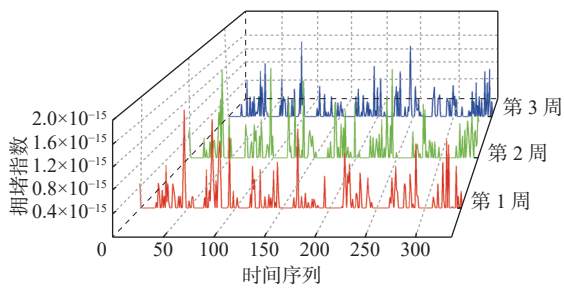

图 4 连续 3 周的拥堵指数变化趋势(时间尺度为 30 min)

Fig. 4 Congestion index has changed for three consecutive weeks (time scale is 30 min)

2.3.2 非线性

尽管有较为固定的航班计划约束空中交通行为，但由于空中交通系统是一个“人-机-环”构成的复杂开放系统，受人为因素、恶劣天气、设备故障等不确定因素的影响，使空中交通系统具有一定的非线性特征。空中交通拥堵指数表现出微观非线性的时变特征，给交通拥堵的准确预测带来较大挑战。

三阶自相关统计量 R 能够较好地检验出时间序列中的非线性特性，计算如下：

$$R(\tau_1,\tau_2)=\frac{\sum_{k=\max(\tau_1,\tau_2)+1}^{l}\left(x_k x_{k-\tau_1} x_{k-\tau_2}\right)^3}{l-\max(\tau_1,\tau_2)} \tag{4}$$

式中：τ_1、τ_2为时间延迟，一般取$\tau_2=2\tau_1$；x_k为时间序列第k个数值；l为时间序列长度。

进一步采用 Sigma 检验法对原数据和打乱原始序列元素顺序得到替代数据的检验统计量进行对比分析。假设原数据的三阶自相关统计量为T_0，其替代数据的三阶自相关统计量均值为T_S、均方差为σ_S，则 Sigma 检验量S计算如式(5)所示。根据 Sigma 检验原则，在显著性水平 0.05 下，当 $S\geqslant1.96$ 时，拒绝原假设，说明原始序列具有非线性特征。

$$S=|T_0-T_S|/\sigma_S \tag{5}$$

选取拥堵多发的时空区块 6、时空区块 10、时空区块 22、时空区块 33 及时空区块 38 的拥堵指数时间序列, 基于上述方法检验非线性特性, S 值依次为 7.78、14.45、4.34、4.92 和 7.55, 5 个区块的 Sigma 检验量均大于 1.96, 说明拥堵指数时间序列具有非线性成分。

2.4　空中交通拥堵的空间相关性

为进一步分析不同区块之间的空间相关性, 计算两两区块拥堵指数的皮尔逊相关系数, 可视化如图 5 所示。可见, 对角线附近相关系数较大, 说明相邻区块之间的相关性较大, 例如, 时空区块 2 与时空区块 3、时空区块 6、时空区块 18、时空区块 21、时空区块 22 相邻, 其相关性系数均达到 0.7 以上。另外, 处于同一交通流上的时空区块之间的相关性较大, 例如, 时空区块 18 和时空区块 19、时空区块 21、时空区块 22 处于同一交通流上(见图 1), 其相关性系数虽然低于相邻区块的相关性系数, 但也均达到 0.5 以上, 相关性较大。

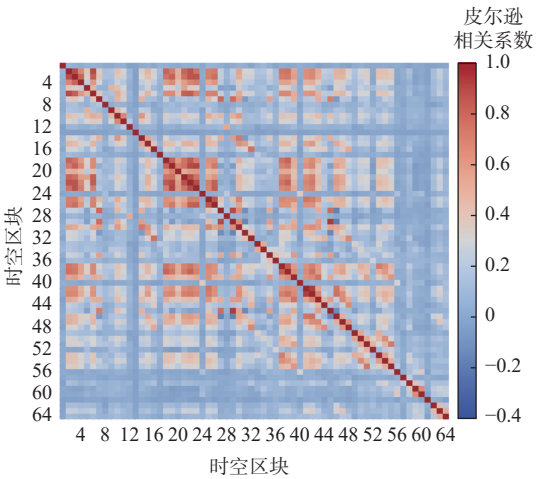

图 5　拥堵指数相关性系数

Fig. 5　Congestion index correlation coefficient plot

3　终端区交通拥堵预测模型的构建

3.1　问题描述

已知: 将终端区划分为N个时空区块, 整个终端区的拥堵指数表达为$\boldsymbol{V}=[\boldsymbol{V}_1,\boldsymbol{V}_2,\cdots,\boldsymbol{V}_l]$, l为时间序列长度, $\boldsymbol{V}_k=[\boldsymbol{V}_{k1},\boldsymbol{V}_{k2},\cdots,\boldsymbol{V}_{kN}]$表示$k$时段各时空区块的交通状态。

预测: 未来时段各时空区块的拥堵指数$\boldsymbol{V}_{t+L}$, L为预测步长。

由 2.4 节可知, 各时空区块交通拥堵不仅受周围区块的影响, 而且受同一交通流上其他区块的影响。为此, 基于各时空区块交通拥堵指数和区块间流量, 分别构建不同时段的三维网格G^1和交通流网络G^2; 对G^1进行三维卷积操作, 对G^2进行图卷积操作, 重构各时空区块之间空间特征; 将卷积后的空间特征, 利用 GRU 学习区块拥堵演化的时间相关性, 实现对各时空区块未来拥堵指数的预测。该拥堵预测问题可描述为

$$f([G^1,G^2];[\boldsymbol{V}_{t-l+1},\cdots,\boldsymbol{V}_{t-1},\boldsymbol{V}_t])\xrightarrow{\text{3DCNN}(\cdot)+\text{GCN}(\cdot)+\text{GRU}(\cdot)}\boldsymbol{V}_{t+L} \tag{6}$$

3.2　基于 3DCNN-GCN-GRU 的交通拥堵预测模型构建

基于 3.1 节问题描述, 构建基于 3DCNN+GCN+GRU 的交通拥堵预测模型。该模型主要由 3DCNN 特征重构部分、GCN 特征重构部分和 GRU 预测部分组成, 模型结构如图 6 所示, 其中, h 表示历史

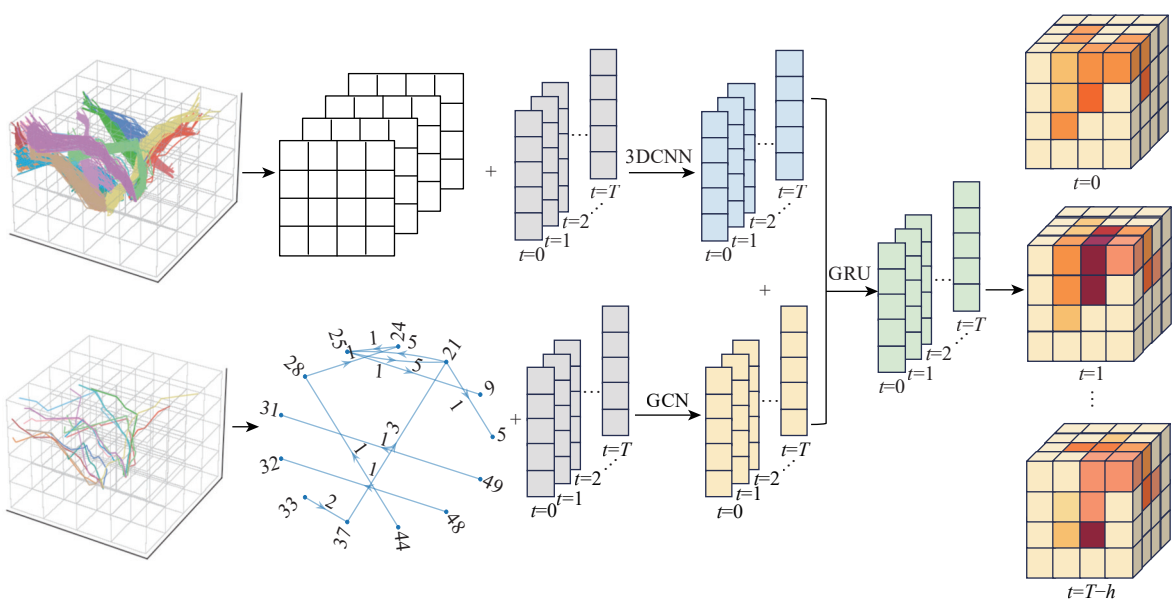

图 6　3DCNN-GCN-GRU 框架

Fig. 6　Frame of 3DCNN-GCN-GRU

h个时刻。首先,基于各时空区块拥堵指数数据,采用三维卷积重构终端区相邻时空区块间的空间相关性特征;接着,基于终端区交通流网络,采用图网络重构终端区交通流上各时空区块间的空间相关性特征;然后,将2类空间相关性特征进行拼接,并输入GRU模型,捕获各时空区块交通拥堵的时间相关性特征;最后,经过全连接层得到各时空区块交通拥堵指数的预测结果。

3.2.1 基于3DCNN的空域三维网格空间特征重构

三维卷积技术更适合空域的三维空间特征。针对不同时段各三维网格拥堵指数数据,采用3DCNN技术重构邻近区块之间的空间相关性特征,具体流程如下:

1)三维卷积核构造。较小的卷积核能够捕捉空域内交通拥堵的细节,而较大的卷积核则能提高捕获交通拥堵全局特征的能力。为构建合适大小的卷积核,分别将多个不同大小的卷积核放到预测模型中,选取预测精度最高时所对应的卷积核大小。

2)卷积操作。为从不同角度学习邻近时空区块之间的相关关系,构建经度、纬度和高度3个通道,即令三维卷积核在终端区三维网格空域内,分别沿经度、纬度和高度进行滑动卷积操作,从而获取交通拥堵邻近空间特征的三通道卷积的特征图信息。

卷积层采用激活函数为ReLU的卷积操作提取特征,增强空间信息,一定程度上可以防止过拟合现象的发生。采用窗口大小为$2\times2\times2$的最大池化函数来增加感受野,减小特征图的尺寸,降低计算复杂度。

3)多通道卷积特征的拼接。对上一步得到的三通道卷积特征进行拼接,得到一个总体的三维卷积特征,计算式为

$$Y(a,b,c)=F\left(\sum_{a'=0}^{A-1}\sum_{b'=0}^{B-1}\sum_{c'=0}^{C-1}X(a+a',b+b',c+c')\cdot\omega(a',b',c')+\varsigma\right) \tag{7}$$

式中:$F(\cdot)$为激活函数,本文使用ReLU激活函数,ReLU激活函数可以减少模型过拟合的风险,提高模型的训练速度;$Y(a,b,c)$为卷积层输出的某个特定位置的值,通常也被称作特征图中的某个像素;$X(a+a',b+b',c+c')$为输入数据的某个位置的值及前一个卷积层输出(也可称作特征图)的某个位置的值;$\omega(a',b',c')$为卷积核的权重参数;ς为偏置项;A、B、C为卷积核的尺寸,用于指定卷积核在3个维度上的大小。

3.2.2 基于GCN的动态交通流网络空间特征重构

GCN能够很好地学习非欧式结构数据中的空间特征。考虑到终端区内部交通流网络具有典型的非欧特征,基于1.1节终端区空域交通流识别、三维区块划分及各区块拥堵指数的计算结果,构建不同时段的动态交通流网络,并利用图卷积技术重构动态交通网络上各时空区块之间的空间相关性特征。

1)交通流量计算。基于1.1节交通流识别结果,统计不同时段各区块之间的交通流量。

2)交通流网络构建。以各时空区块为节点,时空区块间连通关系为边,若两时空区块处于一条交通流上且存在航班经过,则两时空区块为连通状态,否则没有连边。由2.2节可知,拥堵指数与交通流量有一定相关性,因此,将交通流量作为网络边的权重,构建不同时段交通流网络的加权动态有向图$\boldsymbol{G}^2=[\boldsymbol{G}_1^2,\boldsymbol{G}_2^2,\cdots,\boldsymbol{G}_P^2]$,$\boldsymbol{G}_p^2=\boldsymbol{G}_p^2(U_p,E_p,W_p)$,其中,$p$为第$p$个时间段,$p=1,2,\cdots,P$,$U_p$为第$p$个时间段空域区块集(即交通流网络的点集),$E_p$为第$p$时间段区块间交通流的连通情况(即交通流网络的边集),值为0或1,W_p为第p个时间段不同网格间交通流量(即交通流网络的边权集)。第p时间段网络图$\boldsymbol{G}_p$所对应的邻接矩阵为$\boldsymbol{\Lambda}_p\in\mathbf{R}^{N'\times N'}$。限于篇幅所限,图7给出了部分时段的动态交通流网络图,图中数字为时空区块编号。可见,终端区交通量越大,网络结构越复杂。

3)图卷积操作。对交通流网络图$\boldsymbol{G}^2$进行图卷积操作:

$$H=\sigma(\boldsymbol{AV\theta}) \tag{8}$$

式中:H为图卷积的输出特征;$\sigma(\cdot)$为激活函数;$\boldsymbol{A}$为$\boldsymbol{G}^2$的邻接矩阵;$\boldsymbol{\theta}$为图卷积的参数向量。

3.2.3 基于GRU的时间特征重构

本节采用GRU捕获交通时间序列中固有的动态时间依赖性。GRU模型的输入为三维卷积$\boldsymbol{Y}^{\mathrm{3DCNN}}$和图卷积输出的重构特征$\boldsymbol{H}^{\mathrm{GCN}}$,输出为各网格未来的交通状态$\boldsymbol{V}_k$,计算式为

$$\boldsymbol{V}_k=\mathrm{GRU}\left(\boldsymbol{H}_{k-1}^{\mathrm{GCN}},\boldsymbol{Y}_{k-1}^{\mathrm{3DCNN}},\boldsymbol{H}_{k-2}^{\mathrm{GCN}},\boldsymbol{Y}_{k-2}^{\mathrm{3DCNN}},\cdots,\boldsymbol{H}_{k-l}^{\mathrm{GCN}},\boldsymbol{Y}_{k-l}^{\mathrm{3DCNN}}\right) \tag{9}$$

式中:GCN和3DCNN分别表示图卷积和三维卷积的重构特征。

3.3 模型评价

采用均方根误差(root mean squared error, RMSE)和平均绝对误差(mean absolute error, MAE)2个指标评估模型的预测性能。

1)RMSE是预测值与真实值之间差异的平均

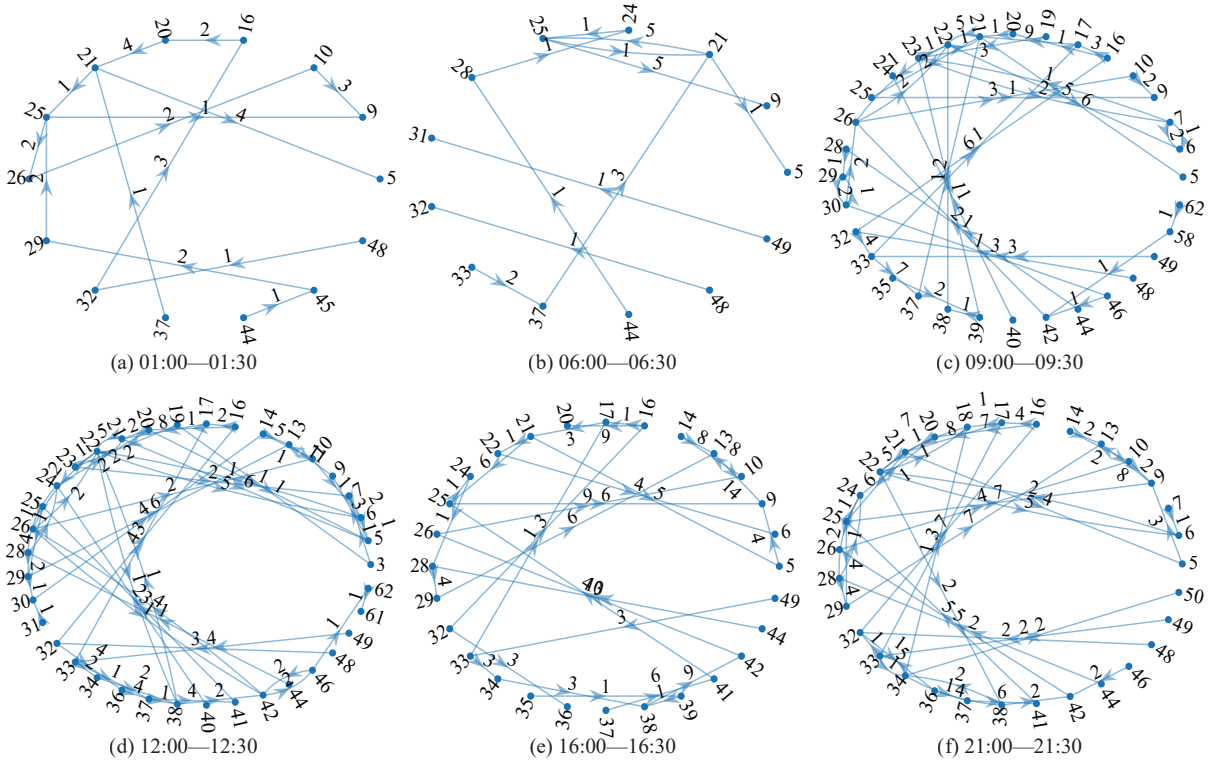

图 7　邻接网络

Fig. 7　Adjacency network

标准差, 计算式为

$$Q_{\mathrm{RMSE}}=\sqrt{\frac{1}{n'}\sum_{i'=1}^{n'}\left(y_{i'}-\hat{y}_{i'}\right)^2} \tag{10}$$

式中: $\hat{y}_{i'}$ 和 $y_{i'}$ 分别为第 i' 个样本的预测值和真实值; n' 为样本总数。

2) MAE 是预测值与真实值之间差异的平均绝对值, 计算式为

$$Q_{\mathrm{MAE}}=\frac{1}{n'}\sum_{i'=1}^{n'}\left|y_{i'}-\hat{y}_{i'}\right| \tag{11}$$

4　算例分析

4.1　实验设置

本文预测模型使用 Python 语言, 基于 Tensorflow 搭建。通过试算, 确定卷积核大小为 3×3×3, 模型使用 Adam 优化器进行优化, 学习率设置为 0.001, 激活函数为 ReLU, 以 MAE 作为目标函数, 并采用 L_2 正则化操作, 减少模型过拟合风险。在训练过程中, 以 128 个样本为一个训练批次, 共训练 100 轮, 通过 split 函数指定 20% 的数据作为验证集, 输入序列长度为 6, 预测序列长度分别为 1。为避免预测模型产生严重的过拟合, 采用早停策略用于在验证集损失不再改善时停止训练, 并恢复到在验证集上得到最佳性能时的权重。

实验过程中本文模型历史数据输入序列长度主要通过试算获得。例如, 对于 30 min 时间尺度, 分别采用输入序列长度为 4、5、6、7、8 进行对比实验, 其 MAE 对比如图 8 所示。可知, 当输入序列长度为 6 时, 模型训练误差值最小。对于 3DCNN+GCN+GRU 预测模型来说, 太小的输入序列长度不能获得足够的历史信息, 导致模型无法学习足够的时间依赖特征来支持终端区交通拥堵预测任务, 导致模型误差较大; 当输入序列长度过大时, 预测模型在学习时空数据相关性时会弱化靠前序列的比

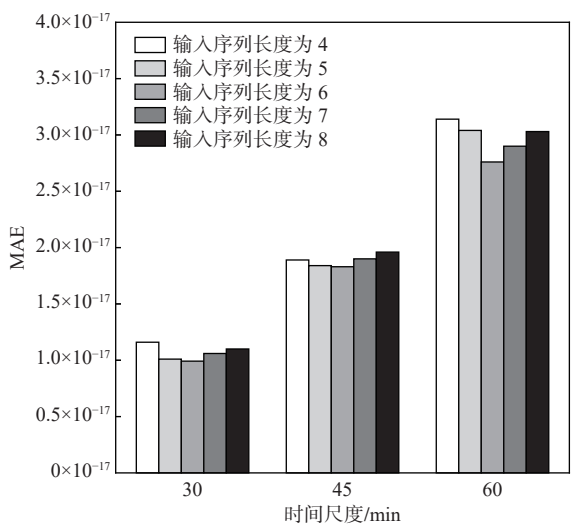

图 8　不同输入序列长度下各模型预测误差对比

Fig. 8　Comparison of prediction errors of various models under different input sequence steps

重。更严重的是,较长的输入序列会使模型参数数量激增,使模型性能下降。由图 8 可知,MAE 先随着输入序列长度的增加而减小,此时说明模型捕捉时空数据的相关性较好。当序列达到一定长度时,再增加序列长度时,MAE 又会逐渐增大。

4.2 结果分析

4.2.1 不同模型预测结果对比

为检验本文模型的优越性,将本文模型与历史平均 (history average, HA) 模型、指数加权平均 (exponential moving average, EMA) 模型、支持向量机回归 (support vector regression, SVR) 模型等经典模型,以及 CNN+GRU 模型、GCN+GRU 模型、CNN+GCN+LSTM 模型等变体模型进行对比试验,结果如表 2 和图 9 所示。可以看出,所有模型随着时间尺度的增加,预测准确率均下降,30 min 时间尺度下预测效果最好,且 CNN+GCN+GRU 模型在所有模型中都是表现最好的。相较于 HA 模型、EMA 模型、SVR 模型,CNN+GCN+GRU 模型的 RMSE 和 MAE 分别下降 21% 和 57%、38% 和 72%、19% 和 51%;相较于只学习邻接空间特征、只学习交通流空间特征、改用 LSTM 学习时间特征,CNN+GCN+GRU 模型的 RMSE 和 MAE 分别下降 36% 和 40%、6% 和 8%、2% 和 2%。相较于 30 min 时间尺度,45 min 和 60 min 时间尺度预测结果的 MAE 和 RMSE 分别增加了 84% 和 48%、178% 和 118%。说明较短的时间尺度允许模型更好地捕捉数据中的时空相关性,从而提高预测准确性。图 9 给出终端区时空区块 22 不同尺度下 CNN+GCN+GRU 模型预测值与真实值的对比。可以看出,本文模型能够较好地学习到真实值的变化趋势。

表 2 模型误差对比

Table 2 Comparison of model errors

模型	MAE			RMSE		
	时间尺度为30 min	时间尺度为45 min	时间尺度为60 min	时间尺度为30 min	时间尺度为45 min	时间尺度为60 min
HA	2.32×10^{-17}	3.91×10^{-17}	5.70×10^{-17}	5.60×10^{-17}	8.38×10^{-17}	1.11×10^{-16}
EMA	3.56×10^{-17}	3.25×10^{-17}	4.72×10^{-17}	7.17×10^{-17}	6.49×10^{-17}	8.58×10^{-17}
SVR	2.02×10^{-17}	3.45×10^{-17}	5.02×10^{-17}	5.47×10^{-17}	8.20×10^{-17}	1.09×10^{-16}
CNN+GRU	1.08×10^{-17}	1.85×10^{-17}	2.95×10^{-17}	4.74×10^{-17}	8.02×10^{-17}	1.11×10^{-16}
GCN+GRU	1.64×10^{-17}	2.84×10^{-17}	4.32×10^{-17}	6.93×10^{-17}	1.03×10^{-16}	1.41×10^{-16}
CNN+GCN+LSTM	1.02×10^{-17}	1.98×10^{-17}	3.24×10^{-17}	4.52×10^{-17}	7.36×10^{-17}	1.02×10^{-16}
CNN+GCN+GRU	9.92×10^{-18}	1.83×10^{-17}	2.76×10^{-17}	4.41×10^{-17}	6.51×10^{-17}	9.61×10^{-17}

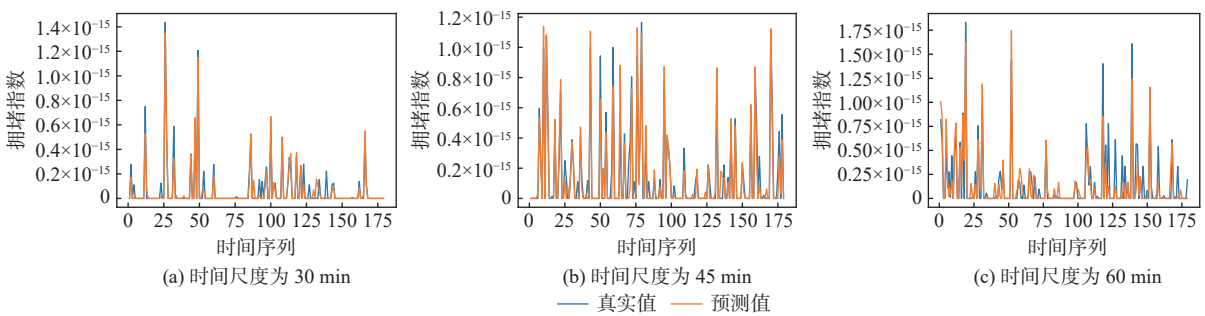

图 9 模型预测结果

Fig. 9 Model predicts results

另外,对比 CNN+GRU 模型和 GCN+GRU 模型这 2 个模型的预测结果可以看出,相比同一交通流的区域,邻接区域的交通状态对目标区域影响较大。因此,当某区域发生交通拥堵时,管制员应首先关注其对周围区域的影响,其次关注与拥堵区域在同一交通流的其他区域。

4.2.2 不同高度层预测结果对比

由于本文将空域划分为4×4×4的网格,在高度上将空域划分为 4 个高度层。基于本文模型得到各网格拥堵指数预测结果,分别统计不同时间尺度下各高度层上所有网格 MAE 均值,如图 10 所示,其中,图 10(b)中数字为水平区块编号。以 30 min 时间尺度为例,可发现低高度层(0~1 500 m)的预测准确性最高,MAE 达到 7.72×10^{-18},其原因可能由于靠近机场的低高度层空域通常会有较多的固定航线,飞行路径相对固定,导致拥堵情况的出现具有较强规律性,因此,拥堵预测的准确性也会提高。中高度层(1 500~4 500 m)MAE 有所增大,达到

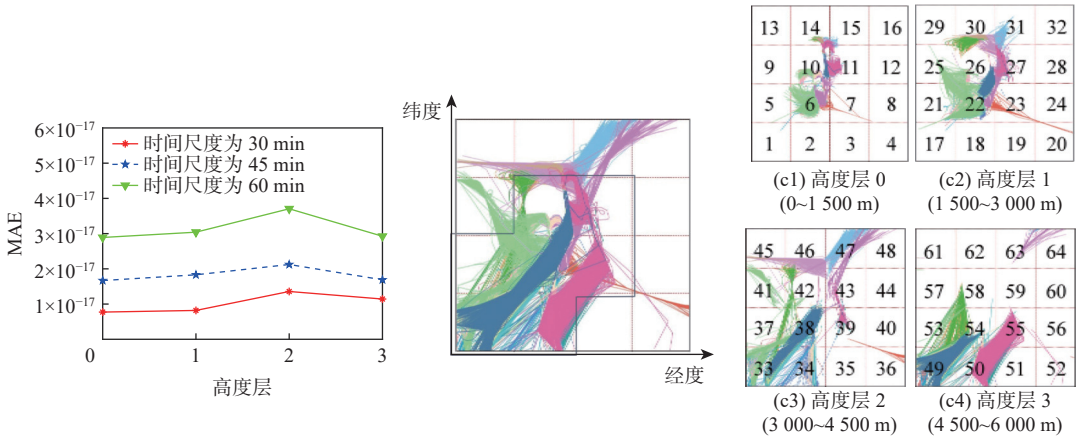

(a) 高度层误差折线图　(b) 水平航迹 (不考虑高度)　(c) 水平航迹 (考虑高度)

图 10　不同高度层误差及水平航迹

Fig. 10　Error of different altitude layers and horizontal track

1.14×10^{-17}, 高高度层(4 500～6 000 m)MAE 又有所降低, 达到 1.36×10^{-17}。

对比图 10(c) 可见, 由于高高度层航空器刚进入终端区时, 汇聚现象较弱, 以及低高度层航空器基本已完成落地排序, 航空器之间间隔已具备, 因此, 在这些高度范围内, 管制员对航空器实施减速、雷达引导等行为较少。而在中高度层, 航空器冲突态势较为严重, 管制员通常会对航空器实施较多的雷达引导等操作, 导致航迹分布较为复杂, 交通态势演变的规律特征有所减弱, 因此, 在中高度层, 拥堵预测的准确性最差。而当高度上升到一定程度后, 预测误差又随着高度的上升而减小, 其原因在于在该高度飞行的航空器大多刚刚完成移交, 航空器之间存在移交间隔, 航空器运行规律性较强, 预测误差变小。因此, 中高度层交通态势演化较为复杂, 终端区管制员在指挥飞机时, 尤其要关注中高度层上的交通态势情况。

4.2.3　不同水平区块预测结果对比

忽略高度的影响, 基于本文模型得到各网格拥堵指数预测结果, 以 30 min 时间尺度为例, 统计各水平区块上所有高度网格 MAE 的均值, 结果如表 3 所示, 同时, 绘制如图 10(b) 所示的航迹图。对比表 3 和图 10(b) 可以发现, 航迹越复杂的时空区块, 其拥堵预测的误差越大, 如水平区块 1、水平区块 2、水平区块 6 及水平区块 7 的 MAE 均值分别为 2.54×10^{-17}、1.74×10^{-17}、2.56×10^{-17} 及 2.08×10^{-17}, MAE 标准差较大; 有较少或没有航迹穿越的时空区块, 预测误差较低, 如水平区块 3、水平区块 4、水平区块 12 及水平区块 16 的 MAE 均值分别为 1.05×10^{-18}、5.33×10^{-18}、6.60×10^{-18} 及 5.56×10^{-20}, MAE 标准差较小。因此, 航迹复杂区域的交通拥堵演化较为复杂, 终端区管制员在指挥飞机时, 尤其要关注水平区块 1、水平区块 2、水平区块 6、水平区块 7 等航迹复杂区域的交通拥堵态势。

表 3　水平区块误差

Table 3　Horizontal block error

水平区块	MAE均值	MAE标准差
1	2.54×10^{-17}	8.63×10^{-17}
2	1.74×10^{-17}	8.80×10^{-17}
3	1.05×10^{-18}	1.44×10^{-17}
4	5.33×10^{-18}	4.32×10^{-17}
5	1.48×10^{-17}	6.84×10^{-17}
6	2.56×10^{-17}	5.99×10^{-17}
7	2.08×10^{-17}	7.69×10^{-17}
8	1.07×10^{-17}	6.02×10^{-17}
9	5.17×10^{-19}	1.46×10^{-17}
10	1.39×10^{-17}	6.45×10^{-17}
11	1.34×10^{-17}	6.15×10^{-17}
12	6.60×10^{-18}	4.67×10^{-17}
13	1.40×10^{-18}	2.07×10^{-17}
14	2.01×10^{-18}	2.66×10^{-17}
15	1.14×10^{-19}	1.23×10^{-17}
16	5.56×10^{-20}	3.29×10^{-18}

可见, 基于水平区域的拥堵预测的准确性较高, 可提醒管制员提前关注即将拥堵的区域, 通过雷达引导、减速等行为限制未来某时段内进入该区域的航空器数量, 降低该区域航空器飞行路径的复杂性。同时, 综合考虑各区块的拥堵态势, 也有利于管制员较为精细地规划航空器在终端区的飞行路径。

5　结　论

本文研究了一种新的考虑多模态时空相关性的终端区交通拥堵预测方法, 并选择北京终端区为

例，构造了终端区交通拥堵指数数据集对所用方法进行了验证，主要结论如下：

1）综合考虑空中交通拥堵状态下，航空器的滞留特性、管制负荷增加及交通流异质性等特点，提出终端区交通拥堵指数及其计算方法，使拥堵度量结果更符合管制员的认知，对管制工作更有指导作用。

2）充分挖掘终端区邻接区域之间，以及同一交通流上不同区域之间的动态空间相关性，构建基于3DCNN+GCN+GRU的终端区交通拥堵精细化预测模型，实现对终端区内部不同三维区域的拥堵预测，有助于提升空管人员对终端区交通拥堵程度掌握的精细化、科学性和准确性，也为未来TBO空管模式的实现提供了理论基础。

3）实例验证结果表明，邻接特征较交通流特征对拥堵预测准确性提升更为明显；随高度的上升，预测误差呈现出先增大后减小的变化趋势；航迹复杂区域预测准确性较低。说明中高度区域和航迹复杂区域交通拥堵演化较为复杂，管制员应重点关注这些区域的交通运行情况。

本文主要研究常发性拥堵的预测问题，终端区交通较易受恶劣天气的影响，未来可挖掘恶劣天气气象要素与交通拥堵的相互作用特征，将天气信息考虑到预测模型中，提高恶劣天气下交通拥堵预测的准确性。

参考文献（References）

[1] 殷建棠, 刘继新, 田文, 等. 基于时空图卷积的航段拥挤态势预测[J]. 北京航空航天大学学报, 2025, 51(11): 3906-3915.
Yin J T, Liu J X, Tian W, et al. Segment congestion situation prediction based on spatiotemporal graph convolution[J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(11): 3906-3915(in Chinese).

[2] 李桂毅, 胡明华, 张洪海. 基于FCM-SVM方法的时空航路网交通状态识别研究[J]. 武汉理工大学学报 (交通科学与工程版), 2018, 42(4): 569-573.
Li G Y, Hu M H, Zhang H H. Research on traffic state identification of spatio-temporal air route network based on FCM-SVM method[J]. Journal of Wuhan University of Technology (Transportation Science & Engineering), 2018, 42(4): 569-573(in Chinese).

[3] Williams K, Reichmuth J. An assessment of air traffic management in Europe during the calendar year 2004[EB/OL]. (2005-04-13)[2024-07-01]. https://www.eurocontrol.int/publication/performance-review-report-prr-2004.

[4] 李善梅, 徐肖豪, 王超, 等. 基于灰色聚类的交叉航路拥挤识别方法[J]. 西南交通大学学报, 2015, 50(1): 189-197.
Li S M, Xu X H, Wang C, et al. Congestion identification of crossing air routes based on gray clustering method[J]. Journal of Southwest Jiaotong University, 2015, 50(1): 189-197(in Chinese).

[5] Tan X H, Sun Y S, Zeng W L, et al. Congestion recognition of the air traffic control sector based on deep active learning[J]. Aerospace, 2022, 9(6): 302.

[6] Lin Y, Zhang J W, Liu H. An algorithm for trajectory prediction of flight plan based on relative motion between positions[J]. Frontiers of Information Technology & Electronic Engineering, 2018, 19(7): 905-916.

[7] 张军峰, 蒋海行, 武晓光, 等. 基于BADA及航空器意图的四维航迹预测[J]. 西南交通大学学报, 2014, 49(3): 553-558.
Zhang J F, Jiang H X, Wu X G, et al. 4D trajectory prediction based on BADA and aircraft intent[J]. Journal of Southwest Jiaotong University, 2014, 49(3): 553-558(in Chinese).

[8] Saraf A P, Slater G L. Adaptive eulerian modeling for air traffic flow management[J]. Journal of Aircraft, 2008, 45(5): 1585-1600.

[9] 毛利民, 彭瑛, 李杰, 等. 基于随机森林的对流天气下终端区容量预测[J]. 系统工程理论与实践, 2021, 41(8): 2125-2136.
Mao L M, Peng Y, Li J, et al. Random-forest based terminal capacity prediction under convective weather[J]. Systems Engineering-Theory & Practice, 2021, 41(8): 2125-2136(in Chinese).

[10] 李桂毅, 郭铭宇, 罗一帆. 基于集成学习算法的航路网络航段交通拥挤识别方法研究[J]. 交通运输系统工程与信息, 2020, 20(2): 166-173.
Li G Y, Guo M Y, Luo Y F. Traffic congestion identification of air route network segment based on ensemble learning algorithms[J]. Journal of Transportation Systems Engineering and Information Technology, 2020, 20(2): 166-173(in Chinese).

[11] Khanmohammadi S, Tutun S, Kucuk Y. A new multilevel input layer artificial neural network for predicting flight delays at JFK airport[J]. Procedia Computer Science, 2016, 95: 237-244.

[12] Cai K Q, Shen Z Q, Luo X Y, et al. Temporal attention aware dual-graph convolution network for air traffic flow prediction[J]. Journal of Air Transport Management, 2023, 106: 102301.

[13] 焦卫东, 杨蓓. 一种融合MSC和时空双重注意力的TCN航迹预测方法[J]. 北京航空航天大学学报, 2026, 52(1): 15-27.
Jiao W D, Yang B. A TCN trajectory prediction method fusing MSC and spatio-temporal dual attention[J]. Journal of Beijing University of Aeronautics and Astronautics, 2026, 52(1): 15-27(in Chinese).

[14] Wang K, Ma C X, Qiao Y H, et al. A hybrid deep learning model with 1DCNN-LSTM-Attention networks for short-term traffic flow prediction[J]. Physica A: Statistical Mechanics and its Applications, 2021, 583: 126293.

[15] 刘晓琳, 郭梦娇, 李卓. 基于AAGC-GRU的航班延误组合预测方法[J]. 北京航空航天大学学报, 2025, 51(1): 30-42.
Liu X L, Guo M J, Li Z. Combined prediction method of flight delay based on attention-based adaptive graph convolution-gated recurrentunit[J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(1): 30-42(in Chinese).

[16] Cao M M, Li V O K, Shuai Q Q. DeepGAL: intelligent vehicle control for traffic congestion alleviation at intersections[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(7): 6836-6848.

[17] Sun F R, Xu X J, Zhang H M, et al. Evolution mechanism and optimisation of traffic congestion[J]. The Aeronautical Journal, 2024, 128(1321): 598-630.

Refined prediction of terminal area traffic congestion based on multimodal spatio-temporal feature fusion

LI Shanmei*, SONG Sini, WANG Hongyong, WANG Duanyang, ZHAO Mo

(College of Air Traffic Management, Civil Aviation University of China, Tianjin 300300, China)

Abstract: In order to enhance the accuracy and refinement of grasping the future traffic dynamics in the terminal area, a set of traffic congestion prediction methods based on the fusion of multimodal spatio-temporal features is proposed. First, from the standpoint of aircraft detention and control load, a traffic flow clustering technique is used to provide a traffic congestion index calculation method that takes traffic flow heterogeneity into account. Further, the airspace of the terminal area is divided into four-dimensional spatio-temporal blocks, and the spatio-temporal blocks are used as the nodes for constructing the dynamic adjacency network and the traffic flow network, which characterize the spatial correlation of the terminal area in a multimodal way. Finally, a three-dimensional convolutional neural network (3DCNN)+graph convolutional network (GCN)+gated recurrent unit (GRU)-based traffic congestion prediction model for terminal areas is proposed. The model validation was performed using Beijing terminal area trajectory data, and the results show that the method of this paper is superior to the classical baseline model, with the best prediction effect at 30 min compared to 45 min and 60 min time scales, and the root mean squared error (RMSE) and mean absolute error (MAE) compared to the history average (HA) model, exponential moving average (EMA) model, and support vector regression (SVR) regression model and MAE decreased by 21% and 57%, 38% and 72%, and 19% and 51%, respectively. The RMSE and MAE of this paper's model fall by 36% and 40%, 6% and 8%, and 2% and 2%, respectively, as compared to learning only neighbor space features, learning only traffic flow space features, and transitioning to long short-term memory (LSTM) to learn temporal characteristics. At the same time, the prediction results show that the more complex the trajectory is, the greater its prediction error is, and with the rise in the altitude of the airspace, the prediction error shows an increase and then a decrease. Meanwhile, the prediction results show that the more complicated the trajectory is, the larger the prediction error is, and with the increase of airspace altitude, the prediction error shows an increase and then decrease.

Keywords: air transportation; congestion prediction; deep learning; traffic flow network; four-dimensional trajectory

Received: 2024-07-21; **Accepted**: 2024-08-23; **Published Online**: 2024-09-05 10:38

URL: link.cnki.net/urlid/11.2625.V.20240904.1558.001

Foundation items: National Natural Science Foundation of China (52672428,52202404); Tianjin Natural Science Foundation (24JCYBJC01170); Graduate Research Innovation Project of Civil Aviation University of China (2025YJSKC03001)

* **Corresponding author**. E-mail: sm-li@cauc.edu.cn