

引用格式: 匡育衡, 王正宁, 王正, 等. 基于双注意力时空图卷积神经网络的 4D 轨迹预测方法 [J]. 电子科技大学学报, 2025, 54(5): 641-651.
KUANG Y H, WANG Z N, WANG Z, et al. 4D Trajectory prediction based on dual-attention spatiotemporal graph convolutional neural network[J].
Journal of University of Electronic Science and Technology of China, 2025, 54(5): 641-651.

基于双注意力时空图卷积神经网络的 4D 轨迹 预测方法



匡育衡¹, 王正宁^{1*}, 王正², 石镇瑜¹, 张毓丁¹

(1. 电子科技大学 信息与通信工程学院, 成都 611731; 2. 中国航空工业集团公司 成都飞机设计研究所, 成都 610091)

摘要: 近年来, 4D 轨迹预测在空中交通管理系统中的重要性正在逐渐增加, 以其为核心技术的冲突检测和解决、飞机异常行为监测、密集飞行区域管控等任务的智能化需求也在逐年上升。机场终端区和密集空域的状况错综复杂且不断变化, 现有的方法无法充分捕捉这两个场景下飞机之间的相互作用关系。为了应对这些挑战, 提出了基于双注意力的时空图卷积神经网络模型来充分提取飞机之间的潜在时空相关性。该模型利用自注意力机制对邻接矩阵进行重构以便更好地捕捉图节点之间的相关性, 并通过图注意力计算提取节点之间的时空特征, 最终生成预测轨迹的概率分布。实验结果表明, 与现有主流算法相比, 利用自注意力机制重构的邻接矩阵和图注意力网络可以随着网络训练不断地优化, 从而更好地反应节点之间的潜在关联, 提升了 4D 轨迹预测结果的准确率。

关键词: 4D 轨迹预测; 时空图卷积神经网络; 自注意力机制; 深度学习

中图分类号: TP18;V355 **文献标志码:** A **DOI:** 10.12178/1001-0548.2024346

4D Trajectory prediction based on dual-attention spatiotemporal graph convolutional neural network

KUANG Yuheng¹, WANG Zhengning^{1*}, WANG Zheng², SHI Zhenyu¹, and ZHANG Yuding¹

(1. School of Information and Communication Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China;

2. AVIC Chengdu Aircraft Design and Research Institute, Chengdu 610091, China)

Abstract: In recent years, the importance of four-dimensional (4D) trajectory prediction in air traffic management systems has been gradually increasing. On this foundational technology, the demand for intelligent solutions of tasks, such as conflict detection and resolution, aircraft anomaly monitoring, and management of congested flight paths, has also been rising year by year. The dynamics in airport terminal zones and crowded airspaces are intricate and ever-changing. However, current methodologies cannot fully capture the interactions among aircrafts in these two scenarios. To tackle these challenges, a dual-attention based spatiotemporal graph convolutional network (DA-STGCN) model is proposed. This model reconstructs the adjacency matrix through a self-attention approach, enhancing the capture of node correlations, and employs graph attention to distill spatiotemporal characteristics, thereby generating a probabilistic distribution of predicted trajectories. The experimental results indicate that, compared with the existing main algorithms, the adjacency matrix reconstructed using self-attention mechanism and the graph attention network can be continuously optimized during the network training, thereby better reflecting the potential correlations between nodes, significantly improving the accuracy of 4D trajectory prediction results.

Key words: 4D trajectory prediction; spatiotemporal graph convolutional neural network; self-attention mechanism; deep learning

国际民航组织于 2019 年发布了第 6 版《全球空中航行计划》, 明确表示基于轨迹 (trajectory-based operations, TBO) 将作为“航空系统组块升

级”中各类引线的总集成和最终实现目标, 并计划于 2031 年后在全球推广应用。空中交通管理 (air traffic management, ATM) 从“基于指令运行”

收稿日期: 2024-12-18

基金项目: 四川省区域创新合作计划 (2024YFHZ0095); 四川省重大科技专项项目 (24JBG0075)

作者简介: 匡育衡, 博士生, 主要从事强化学习及无人机智能控制方面的研究。

*通信作者 E-mail: zhengning.wang@uestc.edu.cn

(command-based operations, CBO) 向 TBO 的转变
为 4D 轨迹预测功能与性能带来了全新的挑战^[1-2]。
4D 轨迹预测作为冲突检测和解决、飞机异常行为
监测、密集飞行区域管控、到达和离开排序等任务
的核心技术, 如何精准且高效地预测未来轨迹是当
前研究的主要困难之一。

目前, 业内将 4D 轨迹定义为飞机飞行路径的
四维描述, 包括经度、纬度、高度和时间^[3]。
ICAO 将定义扩展到地面运行, 将轨迹表示为飞机
在空中和地面运动的描述, 包括位置、时间、速
度、加速度等属性^[4]。由于空域拥挤、恶劣天气、
紧急事故等原因, 飞机的实际飞行过程有时并不遵
循事先规划好的航线, 这些突发状况降低了空中交
通的可预测性, 增加了 ATM 的难度, 严重阻碍了
ATM 系统的高效运行。如果能够提前预测飞机未
来的轨迹, 将有利于管理人员提前做出决策以应对
突发状况, 从而保障飞行的安全和效率, 因此, 预
测飞机的 4D 轨迹非常必要。

当前的 4D 轨迹预测方法难以在复杂度较高的
空域环境中得到准确的预测结果。在动态变化的空
中交通时, 飞机之间的相互作用(例如避让、并行
航行等)会对轨迹预测产生重大影响。现有模型难
以准确捕捉这些复杂的动态关系, 尤其是在高密度
航班时。本文主要针对上述问题开展研究。

1 相关工作

近年来, 针对 4D 轨迹预测方法的研究可以大
致分为 3 类: 状态估计方法、基于动力学方法以及
机器学习方法。状态估计模型根据飞机的位置、速
度、加速度等属性建立运动方程, 从而实现估计的
传播。该过程不涉及飞机质量、加速度、角度等状
态之间的关系, 因此模型相对简单。但由于不能准
确捕捉飞机长时间的机动不确定性, 会造成较大误
差, 所以只对短期预测有效。根据预测过程中对飞
机单模态或是多模态的不同假设, 可以将状态估计
模型划分为单模态估计和多模态估计。典型的单模
态估计方法包括卡尔曼滤波算法^[5-6]、粒子滤波算
法^[7]以及隐马尔可夫模型^[8-9]。但在复杂的航空环
境下, 飞机不仅要考虑飞行过程中的外部运动, 还
要考虑自身的状态, 如水平和垂直的三维状态等。
因此, 这些单模态估计方法会受到诸多限制, 一些
研究尝试根据飞机的连续状态来模拟飞机飞行模式
的转移概率, 为此提出了多模态估计方法^[10]。但总
体而言, 这些模型的预测推理时间较长, 难以部署在

实时预测的应用场景中。

基于动力学的轨迹预测模型可以看作一种物理
模型, 它基于飞机上的受力情况, 预测飞机的连续
未来轨迹点。具体来说, 给定飞机的当前状态、气
象条件、飞机性能参数及飞行意图, 基于微分方程
建模飞机动态模型, 通过求解方程来预测飞机未来
连续轨迹点。目前, 最常用的动力学模型是质点模
型^[11-13]。虽然动力学模型是从飞机受力的角度进行
分析, 但为了简化模型, 大部分研究都是在理想假
设下实现的, 很少考虑实际约束, 这导致模型预测
的结果无法满足现实需求。

目前, 更多研究聚焦在基于机器学习的方法。
传统的机器学习算法, 如回归模型^[14-16]、聚类算
法^[17-19]等虽然在预测准确度上超过了过去的状态估
计模型和基于动力学方法, 但在实时预测的性能上
仍然难以取得令人满意的效果。随后, 越来越多的
基于深度神经网络的算法被提出, 其中, 具有时间
序列信息挖掘能力的循环神经网络(recurrent neural
networks, RNNs)及其改进模型被广泛使用。文
献[20]基于飞机的动态特性, 提出了爬升、巡航
和进近 3 个阶段的约束条件, 采用长短期记忆网络
(long short-term memory, LSTM)和滑动窗口跟踪
轨迹的各个阶段进行预测。文献[21]采用卷积神
经网络(convolutional neural networks, CNN)挖掘
飞机航迹的空间特征, 然后采用 LSTM 提取飞机
的时间依赖性, 最终对航路阶段的单条轨迹进行航
迹预测。文献[22]将轨迹预测问题描述为一个序
列到序列(seq2seq)的学习问题, 并提出了一个
用于轨迹预测的 seq2seq 深度长短期记忆网络, 该
网络可以有效地捕获具有长短时依赖性和可重复性
的轨迹。文献[23]将 Social-LSTM 方法引入飞机
轨迹预测。在此之前, Social-LSTM 主要被运用在
行人轨迹预测任务中^[24]。在 Social-LSTM 中, 未
来轨迹序列和到达时间的预测不仅基于历史轨迹,
还考虑了其他相邻飞机的轨迹。与传统的 LSTM 方
法相比, Social-LSTM 降低了预测轨迹所需的数据
维度, 并能提供更准确的预测结果。文献[25]设
计了一个基于 seq2seq 模型的混合神经网络 Attention-
TCN-GRU, 该模型采用时间卷积神经网络(temporal
convolutional neural network, TCN)和门控循环单
元(gate recurrent unit, GRU)分别作为编码器和解
码器, 并引入注意力机制, 通过对历史飞行数据建
模, 实现了对终端空域飞机 4D 轨迹的预测。此
外, 文献[26]为解决长时预测时, 飞机轨迹数据

分布难以拟合的问题提出了一种基于 K-medoids 聚类和条件生成对抗网络的 4D 轨迹预测模型。文献 [27] 采用一种基于 Transformer 的长时轨迹预测模型来解决 4D 轨迹预测问题, 该模型通过自注意力机制从历史轨迹数据中提取时间序列特征以提高预测的准确率。但循环网络架构的使用存在局限性, 它难以有效提取飞机之间隐含的相互作用关系, 并且其训练的效率很低。

为了解决循环网络架构带来的局限性, 研究人员采用图卷积神经网络 (graph convolutional networks, GCN) 来预测轨迹。文献 [28] 针对过去的方法无法有效捕捉局部和全局属性特征以及属性间的潜在关联的问题, 结合 LSTM 和 GCN 提出了一种基于全局和局部属性间关系的图网络模型来解决飞机轨迹预测问题。文献 [29] 提出了一种基于时间注意力感知的双图卷积网络来预测空中交通流量。文献 [30] 提出一种时空图卷积神经网络 (spatio-temporal graph convolutional neural network, STGCNN) 来预测人类动态行为。与传统的 GCN 相比, STGCNN 能够同时捕捉节点的时间和空间特征, 在时序预测任务上具有更好的效果。文献 [31] 首次将 STGCNN 用于行人轨迹预测任务中, 并提出一种 Social-STGCNN 模型, Social-STGCNN 通过构建社会图中节点之间边的关系从而充分捕捉节点之间的时空相关性, 并通过时间外推卷积网络 (time-extrapolator convolution neural network, TXP-CNN) 在时间序列上预测轨迹的分布。随后, STGCNN 被分别用于飞机 4D 轨迹预测任务和船舶轨迹预测任务中 [32-33]。文献 [34] 利用管制数据和扇区交通数据完成空中交通态势的快速标定, 并利用 STGCN 实现大范围空域的态势预测。

尽管 STGCNN 在轨迹预测任务上取得了不错的成绩, 但这些方法通常采用人为定义的核函数来计算描述节点之间相互关系的邻接矩阵。在轨迹预测任务中, 这个核函数通常定义为节点之间距离的倒数 [30]。这种仅使用距离关系得到的邻接矩阵在面对机场终端区或密集空域这种高动态的复杂场景时, 并不能充分反应飞机之间真实的潜在关系。此外, GCN 无法处理动态图问题, 并且不容易实现分配不同的学习权重给不同的邻居节点, 这导致它无法有效聚合节点之间的相关性。本文针对以上问题, 提出了一种基于双注意力机制的时空图卷积神经网络 (dual-attention based spatio-temporal graph convolutional network, DA-STGCN) 模型, 与现有

方法相比, 该模型在飞机轨迹预测任务上取得了更好的结果。

2 理论方法

2.1 DA-STGCN 模型框架

图 1 显示了本文提出的 DA-STGCN 模型框架。其中, 双注意力模块主要体现在两个部分: 首先, 本文利用自注意力机制对邻接矩阵进行重构, 该邻接矩阵最初由节点之间距离的倒数定义, 这与过去将节点信息作为自注意力模块的输入来建模节点之间的全局相关性的方法不同 [35]。随后, 本文用重构后的邻接矩阵与时空图进行时空图卷积操作, 得到输出的第一部分。第二个注意力模块利用 GAT 对初始时空图进行注意力计算, 得到输出的第二部分, 这有利于更进一步聚合时空图上节点之间的相关性。值得注意的是, GAT 并不依赖于邻接矩阵, 因此本文的双注意力模块是相互独立运行的, 这使得两个注意力模块可以分别提取不同的节点关系特征, 并在最后进行汇聚从而更充分地利用节点之间的潜在相关性。最后, 本文将这两部分输出汇聚并输入 TXP-CNN 得到飞机 4D 轨迹预测的结果。本文的预测结果为轨迹的概率分布, 这将在后续章节进行详细介绍。

2.2 问题描述

本文将飞机 4D 轨迹预测问题定义如下: 给定空域中一组 N 个飞机及其在时间段 T_o 内的相应观测轨迹坐标 $J_o^i, i \in \{1, 2, \dots, N\}$, 需要根据给定的观测轨迹坐标来预测飞机在未来时间段 T_p 内的预测轨迹坐标 J_p^i 。对于其中一架飞机, 本文将对对应要预测的轨迹坐标定义为 $J_p^i = \{P_t^i = (x_t^i, y_t^i, z_t^i) | t \in \{1, 2, \dots, T_p\}\}$, 其中 (x_t^i, y_t^i, z_t^i) 是一组随机变量, 描述在 3D 空域中, 飞机 i 在时刻 t 时所处坐标的概率分布。本文假设 (x_t^i, y_t^i, z_t^i) 满足三元高斯分布, 使得 $P_t^i \sim \mathcal{N}(\mu_t^i, \Sigma_t^i)$, 其中 μ_t^i 为均值, Σ_t^i 为协方差矩阵。

与之类似, 本文定义模型的预测轨迹坐标 \hat{P}_t^i 同样满足三元高斯分布, 即 $\hat{P}_t^i \sim \mathcal{N}(\hat{\mu}_t^i, \hat{\Sigma}_t^i)$ 。因此, 模型的输出应为能够确定三元高斯分布的均值 $\hat{\mu}_t^i = (\hat{\mu}_x, \hat{\mu}_y, \hat{\mu}_z)_t^i$ 以及协方差矩阵 $\hat{\Sigma}_t^i$ 中的元素。但由于网络的输出不能总是满足协方差矩阵的正定性, 因此本文输出一个对角线为正的下三角矩阵 $L_t^i \in \mathbf{R}^{3 \times 3}$, 并通过 L_t^i 来构造协方差矩阵 $\hat{\Sigma}_t^i$:

$$\hat{\Sigma}_t^i = L_t^i \cdot (L_t^i)^T \quad (1)$$

基于上述定义, 本文通过最小化负对数似然损失函数来训练 DA-STGCN 模型, 定义如下:

$$L^i(\mathbf{W}_{\text{loss}}) = - \sum_{t=1}^{T_P} \log(\mathbb{P}(\mathbf{P}_t^i | \hat{\boldsymbol{\mu}}_t^i, \hat{\boldsymbol{\Sigma}}_t^i)) \quad (2)$$

式中, \mathbf{W}_{loss} 为模型的所有可学习参数; T_P 为预测时间序列的长度。该损失函数的值越小, 表明模型预测的轨迹分布与真实的轨迹分布越接近, 即预测的精度越高。

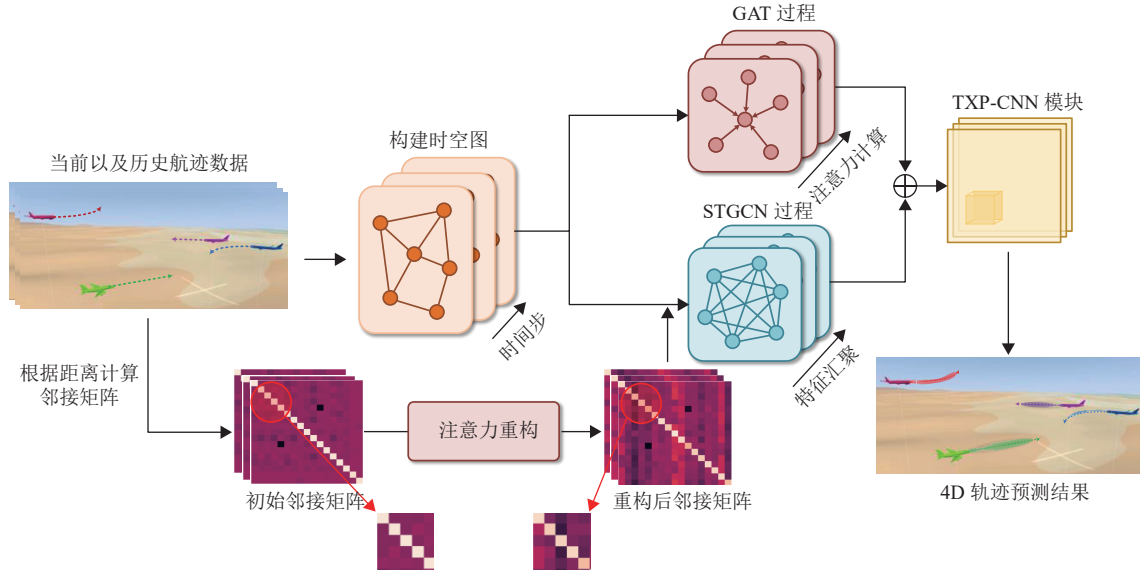


图 1 DA-STGCN 模型整体框架

2.3 构建时空图

图卷积是图神经网络的核心运算之一, 用于处理具有图结构的数据。图卷积计算的目的是充分利用图结构中的节点和边的信息, 通过对节点和邻接矩阵进行图卷积运算, 提取每个节点的特征。

首先, 根据飞机轨迹数据构建时空图, 这是进行图卷积运算的必要步骤。定义某一时刻 t 的空间图为 $\mathbf{G}_t = (\mathbf{V}_t, \mathbf{E}_t)$, 包含 2 个元素, 分别代表节点 \mathbf{V}_t 和边 \mathbf{E}_t 。其中 $\mathbf{V}_t = \{\mathbf{v}_t^i | i \in \{1, 2, \dots, N\}\}$ 是 \mathbf{G}_t 中所有节点向量的集合, 集合中的每个元素 \mathbf{v}_t^i 包含了 t 时刻第 i 架飞机的特征。在本文中, 这些特征分别为飞机的经度、纬度和海拔, 如下所示:

$$\mathbf{v}_t^i = [x_t^i, y_t^i, z_t^i] \quad (3)$$

$\mathbf{E}_t = \{e_t^{ij} | i, j \in \{1, 2, \dots, N\}\}$ 是 \mathbf{G}_t 中所有边的集合, 集合中的每个元素 e_t^{ij} 表征了节点 \mathbf{v}_t^i 和节点 \mathbf{v}_t^j 之间的连接关系, 这种连接关系可以视为两架飞机之间的相互影响程度。与文献 [32] 中相同, 本文采用核函数 $k(\mathbf{v}_t^i, \mathbf{v}_t^j)$ 来对两架飞机之间的相互作用进行衡量, 核函数 $k(\mathbf{v}_t^i, \mathbf{v}_t^j)$ 定义为:

$$e_t^{ij} = k(\mathbf{v}_t^i, \mathbf{v}_t^j) = \begin{cases} \frac{1}{\|\mathbf{v}_t^i - \mathbf{v}_t^j\|_2} & \|\mathbf{v}_t^i - \mathbf{v}_t^j\|_2 \neq 0 \\ 0 & \text{其他} \end{cases} \quad (4)$$

式中, $k(\mathbf{v}_t^i, \mathbf{v}_t^j)$ 的物理意义为两架飞机之间距离的倒数, 它代表两架飞机之间的距离越近, 其相互之间的影响程度越大, 反之亦然。因此, 可以根据 \mathbf{E}_t 将邻接矩阵 \mathbf{A}_t 构造为:

$$\mathbf{A}_t = \begin{bmatrix} 0 & e_t^{12} & \dots & e_t^{1N} \\ e_t^{21} & 0 & \dots & e_t^{2N} \\ \vdots & \vdots & \ddots & \vdots \\ e_t^{N1} & e_t^{N2} & \dots & 0 \end{bmatrix} \quad (5)$$

式中, $\mathbf{A}_t \in \mathbf{R}^{N \times N}$, 反映了 \mathbf{G}_t 中所有节点之间的相互影响关系。

为了方便后续图卷积运算, 需要对邻接矩阵 \mathbf{A}_t 进行归一化处理, 如式 (6) 所示:

$$\bar{\mathbf{A}}_t = \hat{\mathbf{D}}_t^{-\frac{1}{2}} \hat{\mathbf{A}}_t \hat{\mathbf{D}}_t^{-\frac{1}{2}} \quad (6)$$

式中, $\hat{\mathbf{A}}_t = \mathbf{A}_t + \mathbf{I}$, \mathbf{I} 为单位矩阵; $\hat{\mathbf{D}}_t$ 是归一化后的邻接矩阵 $\bar{\mathbf{A}}_t$ 的对角节点度矩阵。

将时刻 $t \in \{1, 2, \dots, T\}$ 的所有 \mathbf{G}_t 堆叠在一起, 便得到了最终的时空图 $\mathbf{G} = (\mathbf{V}, \mathbf{E}) = \{\mathbf{G}_t | t \in \{1, 2, \dots, T\}\}$, 其中 $\mathbf{V} \in \mathbf{R}^{3 \times T \times N} = \{\mathbf{V}_t | t \in \{1, 2, \dots, T\}\}$, \mathbf{E} 可以由 $\bar{\mathbf{A}} \in \mathbf{R}^{T \times N \times N} = \{\bar{\mathbf{A}}_t | t \in \{1, 2, \dots, T\}\}$ 表征, N 代表飞机的数量。值得注意的是, 时刻 $t \in \{1, 2, \dots, T\}$ 的所有 \mathbf{G}_t 需要具有相同的拓扑结构, 仅当 t 发生变化时, \mathbf{V}_t 中每个节点的特征向量发生变化。

2.4 基于注意力重构邻接矩阵

在上文中提到, 由核函数 $k(\cdot)$ 定义的邻接矩阵 A_t 中的每个元素仅能反映两架飞机之间的距离关系, 而不能反映更多飞机之间的潜在关联。为了解决这个问题, 基于注意力机制的全局信息汇聚能力, 本文提出一个利用自注意力对初始邻接矩阵进行优化的注意力重构模块, 如图2所示。




图2 基于自注意力机制的邻接矩阵重构模块

首先, 对输入的邻接矩阵 \bar{A} 使用3个不同的可训练权重矩阵 W_q 、 W_k 、 W_v 进行线性变换, 生成相应的特征向量, 如式(7)所示:

$$q_{\text{att}}^i = W_q \bar{A}_i, k_{\text{att}}^j = W_k \bar{A}_j, v_{\text{att}}^j = W_v \bar{A}_j \quad (7)$$

式中, \bar{A}_i 和 \bar{A}_j 分别为邻接矩阵 \bar{A} 的第 i 和第 j 行, 表示图中节点 i 和 j 的连接关系。

随后计算注意力得分 ε_{ij} , 并对其进行归一化处理得到注意力权重 α_{ij} :

$$\varepsilon_{ij} = (q_{\text{att}}^i)^T k_{\text{att}}^j \quad (8)$$

$$\alpha_{ij} = \frac{\exp(\varepsilon_{ij})}{\sum_{k=1}^n \exp(\varepsilon_{ik})} \quad (9)$$

式中, q_{att}^i 是节点 i 的Query向量; k_{att}^j 是节点 j 的Key向量; ε_{ij} 反映了节点 i 和节点 j 之间的关联强度。

最后, 将注意力权重 α_{ij} 与特征向量 v_{att}^j 进行加权求和, 以获得节点 i 重构后的特征 h'_i :

$$h'_i = \sum_{j=1}^n \alpha_{ij} v_{\text{att}}^j \quad (10)$$

将所有节点的特征进行拼接以得到重构后的邻接矩阵 A' 。 A' 能够基于全局信息动态调整关系权

重, 而不局限于预定义的局部连接。这使得模型能够更好地捕捉节点之间隐含的复杂关系, 提高对飞机未来轨迹的预测能力。

2.5 基于STGCN和GAT的特征提取

2.5.1 STGCN过程

首先利用重构后的邻接矩阵 A' 进行STGCN运算。定义第 l 层网络层中所有飞机在时刻 t 时的特征为 $V_t^{(l)}$, 关于 V_t 的具体定义已在2.3节进行了讨论, 本文用 $V^{(l)}$ 表示 $V_t^{(l)}$ 在时间维度上的堆叠。STGCN每一层的图卷积运算实现如下:

$$V^{(l+1)} = \sigma(A' V^{(l)} W_s^l) \quad (11)$$

式中, W_s^l 是第 l 层的可训练网络参数; $\sigma(\cdot)$ 是激活函数。最终, 将STGCN输出的嵌入结果表示为 $\tilde{V} \in R^{T \times \hat{M} \times N}$, 其中 \hat{M} 为输出的维度。

2.5.2 GAT过程

在GCN中, 节点信息的聚合是基于图的邻接矩阵的固定权重进行的, 这会导致信息传播的不足。尽管经过注意力重构模块优化后的邻接矩阵 A' 已经汇聚了丰富的全局信息, 但这种全局信息是基于距离的, 需要得到距离特征以外的更多隐含特征。因此, 采用GAT来增强时空图中的特征提取, 如图3所示, 这一过程与STGCN的运算同时进行。




图3 STGCN与GAT特征提取流程

GAT并不依赖于预先定义的邻接矩阵, 它通过自注意力机制动态地为每个邻居分配不同的权重, 使得模型能够捕捉节点之间更多的潜在联系, 超越了基于距离的关系限制。通过式(12)实现GAT中注意力系数的计算^[36]:

$$\alpha_{\text{gat}}^{ij} = \frac{\exp(F(a^T [W_{\text{GAT}} v_i || W_{\text{GAT}} v_j]))}{\sum_{k \in N_i} \exp(F(a^T [W_{\text{GAT}} v_i || W_{\text{GAT}} v_k]))} \quad (12)$$

式中, α_{gat}^{ij} 是节点 j 到节点 i 的注意力系数; N_i 表示

节点 i 的邻居节点集合；节点的输入特征为 $\mathbf{v} = \{v_1, v_2, \dots, v_N\}$ ， N 表示节点的个数，节点的输出特征为 $\mathbf{v}' = \{v'_1, v'_2, \dots, v'_N\}$ ； \mathbf{W}_{GAT} 是在每一个节点上应用的线性变换权重矩阵； \mathbf{a} 是权重向量，它可以将输入映射到特征空间上； $F(\cdot)$ 是激活函数，通常使用 LeakyReLU 激活函数以提供非线性输出，并使用 SoftMax 函数进行归一化。

最终，节点的输出特征如下：

$$\mathbf{v}'_i = \sigma \left(\frac{1}{K} \sum_{k=1}^K \sum_{j \in N_i} (\alpha_{\text{gat}}^{ij})^k \mathbf{W}_{\text{GAT}}^k \mathbf{v}_j \right) \quad (13)$$

式中， $(\alpha_{\text{gat}}^{ij})^k$ 是第 k 个注意力头归一化的注意力系数； $\mathbf{W}_{\text{GAT}}^k$ 为第 k 个注意力头的线性变换权重矩阵； \mathbf{v}_j 为第 j 个节点的输入特征； $\sigma(\cdot)$ 为激活函数。最后，汇聚 STGCN 与 GAT 的输出，得到的结果同时包含了基于全局距离关系的潜在特征以及基于全局节点信息的额外特征。

3 实验验证

3.1 数据集和评估指标

关于用于飞机 4D 轨迹预测的 ADS-B 数据，目前没有公开可用的数据集。因此，本文收集了以两个大型机场（IATA: BOS 和 IATA: JFK）为中心、半径 50 km 范围内的空域，以及某两个密集空域（半径为 100 km）的真实开源 ADS-B 数据，并以此制作了符合本文任务要求的数据集。将其分别命名为 ATA1（airport terminal area 1）、ATA2（airport terminal area 2）、DA1（dense airspace 1）及 DA2（dense airspace 2）。

经统计，本文制作的数据集共有 85 463 条轨迹数据，每条轨迹数据包括时刻、飞机编号、飞机经度、飞机纬度和飞机海拔这 5 项信息。具体而言，ATA1 数据集共有 21 043 条数据，其中训练集为 13 183 条、验证集为 4 200 条、测试集为 3 660 条；ATA2 数据集共有 20 581 条数据，其中训练集为 12 886 条，验证集为 4 254 条、测试集为 3 441 条；DA1 数据集共有 22 450 条数据，其中训练集为 14 104 条，验证集为 4 253 条、测试集为 4 093 条；DA2 数据集共有 21 389 条数据，其中训练集为 13 561 条，验证集为 3 961 条、测试集为 3 867 条。

每架飞机的编号风格并不统一，本文对飞机编号进行了编码处理，以便模型能够更好地训练。根据本文收集的 ADS-B 数据，每架飞机的两条轨迹数据之间的时间间隔为 10 s。本文使用轨迹预测任

务中常用的平均位移误差（average displacement error, ADE）和最终位移误差（final displacement error, FDE）对模型的性能进行定量评估^[32]：

$$\text{ADE} = \frac{\sum_{i \in N} \sum_{t \in T_p} \|\hat{p}_i^t - p_i^t\|_2}{N \times T_p} \quad (14)$$

$$\text{FDE} = \frac{\sum_{i \in N} \|\hat{p}_i^t - p_i^t\|_2}{N} \quad (15)$$

式中， p_i^t 和 \hat{p}_i^t 分别为飞机真实的轨迹坐标和模型预测的轨迹坐标； T_p 为预测的时间范围； N 为飞机的数量。此外，由于飞机经纬度坐标的量纲与海拔高度的量纲并不一致，在计算预测误差之前需要将它们的量纲统一为米。通过式 (16) 和式 (17) 分别实现纬度坐标与经度坐标量纲的统一：

$$\Delta y = \Delta \text{lat} \times 111000 \quad (16)$$

$$\Delta x = \Delta \text{lon} \times 111000 \times \cos \left(\text{lat} \times \frac{\pi}{180} \right) \quad (17)$$

式中， Δlon 和 Δlat 分别代表飞机原始的经纬度坐标差； Δx 和 Δy 分别代表量纲统一后的飞机经纬度坐标差。

3.2 实验参数设置

DA-STGCN 模型以 128 的批量进行训练，采用 ReLU 激活函数（GAT 中采用 LeakyReLU）。神经网络的训练优化器选择 Adam，初始学习率为 0.001，当训练轮数达到 200 轮后，学习率衰减为 0.000 2，最终总共训练 400 个轮数。

3.3 实验结果分析

3.3.1 网络层数选择

首先对 STGCN 和 TXP-CNN 的网络层数选择进行了消融实验，分别对比 STGCN 和 TXP-CNN 的层数设置为 1、3、5、7 时的预测性能，实验的结果如表 1 所示。其中，每一行代表 STGCN 的层数，每一列代表 TXP-CNN 的层数，表中的数字代表在对应层数选择下飞机预测轨迹的 ADE。

表 1 网络层数选择消融实验结果

STGCN 层数	TXP-CNN 层数			
	1	3	5	7
1	937.1	984.8	895.4	974.1
3	911.5	1 083.7	939.6	1 394.4
5	1 180.1	1 159.4	1 039.2	917.9
7	1 082.1	1 009.7	1 258.3	1 064.9

结果表明, 当 STGCN 和 TXP-CNN 的层数分别选择 1 和 5 时, DA-STGCN 模型的飞机未来轨迹预测性能最优。

3.3.2 DA-STGCN 模型性能定量分析

本文在 ATA1、ATA2、DA1 和 DA2 这 4 个数据集上测试和比较了 DA-STGCN 模型的预测性能, 实验结果如表 2 所示。

本文选择当前 4D 轨迹预测领域最常用且性能

较好的轨迹预测模型作为对比实验的基线方法, 包括: MLP^[37]、LSTM^[38]、Social-LSTM^[39]、STGAT^[40]、Social-STGCNN^[32] 以及 Graph-TERN^[41]。在实验过程中, 本文设置所有模型的最大训练轮数为 400, 批量大小为 128, 初始学习率为 0.001。其中, MLP 的隐藏层数设置为 5, LSTM 的隐藏层数设置为 3, Social-LSTM、STGAT、Social-STGCNN 及 Graph-TERN 均采用参考文献中推荐的参数设置。

表 2 DA-STGCN 模型与基线模型的对比实验结果

模型	时长	ATA1数据集		ATA2数据集		DA1数据集		DA2数据集	
	T_p/s	ADE/m	FDE/m	ADE/m	FDE/m	ADE/m	FDE/m	ADE/m	FDE/m
MLP	60	1 659.7	2 268.2	2 145.3	2 609.5	1 942.1	2 503.3	2 212.3	2 953.5
	90	2 460.1	2 908.6	2 840.9	3 364.9	2 409.8	3 092.7	2 924.2	3 231.8
	120	3 674.6	4 511.7	3 851.7	4 549.1	3 381.9	4 041.5	3 638.2	3 833.8
LSTM	60	999.4	1 377.4	1 234.1	1 933.9	1 549.1	1 951.1	1 513.6	1 909.1
	90	1 254.9	1 836.9	1 868.3	3 050.8	2 228.9	3 529.9	1 734.9	2 721.6
	120	1 768.8	2 645.8	2 280.9	3 714.3	2 916.4	4 386.7	2 476.9	3 671.7
Social-LSTM	60	948.3	1 283.5	1 048.5	1 497.1	1 398.9	1 771.3	1 271.5	1 729.9
	90	1 387.1	2 023.6	1 558.2	2 454.3	2 305.2	2 906.9	2 023.1	2 881.9
	120	1 639.6	2 444.4	2 071.2	3 405.7	2 639.4	3 656.1	2 642.8	3 747.8
STGAT	60	916.6	1 251.7	948.5	1 452.6	1 196.6	1 347.8	1 326.9	1 649.9
	90	1 182.6	1 731.9	1 317.5	2 218.5	1 484.9	1 915.8	1 652.9	2 343.4
	120	1 493.2	2 222.1	1 735.8	2 891.1	2 170.3	2 989.5	2 446.6	3 547.5
Social-STGCNN	60	736.6	1 004.9	731.5	989.1	963.8	1 120.1	1 203.7	1 591.9
	90	1 103.2	1 491.6	1 027.1	1 643.5	1 518.2	2 254.6	1 422.1	2 063.5
	120	1 341.3	2 008.6	1 334.7	2 255.6	1 906.2	3 215.9	1 941.3	3 225.2
Graph-TERN	60	698.6	1 082.9	690.9	1 113.8	1 087.8	1 389.9	1 119.2	1 487.9
	90	1 182.1	1 566.2	998.2	1 677.8	1 488.5	2 162.6	1 396.4	2 017.7
	120	1 329.3	2 197.9	1 304.9	2 249.6	1 982.6	3 340.4	2 053.6	3 435.9
DA-STGCN (本文模型)	60	705.5	951.1	714.9	978.5	794.03	952.3	1 054.9	1 329.2
	90	934.5	1 375.7	984.5	1 598.6	1 265.5	1 791.4	1 366.9	2 033.4
	120	1 281.2	1 983.8	1 322.8	2 279.3	1 888.7	2 807.1	1 891.8	3 215.8

表 2 的实验结果显示, 本文提出的 DA-STGCN 模型在 4 个数据集上的预测精度均优于其他算法。具体来说, 在所有预测时长中, DA-STGCN 模型在 ADE 和 FDE 这两个指标上的综合表现均优于目前效果最好的 Graph-TERN 模型。而且, 当预测时长为 60 s 时, DA-STGCN 模型在 ADE 指标上比原始的 Social-STGCNN 模型约低 10.1%, 在 FDE 指标上比 Social-STGCNN 模型约低 11.8%。

此外, 随着预测时间范围的延长, 所有预测模型的 ADE 和 FDE 指标都有不同程度的增加, 但本文提出的 DA-STGCN 模型仍然表现出了最好的预测性能, 这表明 DA-STGCN 模型能够有效捕捉轨迹数据之间的长期相关性, 可以有效缓解长期预测中的误差累计问题。

此外, 所有预测模型在机场终端区数据集上的

预测准确率均优于密集空域数据集。当预测时长为 60 s 时, 本文提出的 DA-STGCN 模型在机场终端区数据集上的 ADE 和 FDE 比密集空域数据集分别降低了大约 23.2% 和 15.5%。这是由于空域结构的不同导致的, 对于机场终端区附近的空域, 飞机之间的相互影响程度更大, 此时还有许多飞机没有进入平稳飞行状态或是处于降落状态, 本文提出的双注意力模块能在这样的场景下提取更多有效信息, 这对模型的预测性能是有利的。

3.3.3 DA-STGCN 模型消融实验结果分析

为了验证所提出的双注意力模块有效, 设计了相应的消融实验, 实验的结果如表 3 所示。在消融实验中, 本文同样在 4 个数据集上进行测试, 预测时长同样采用 60 s、90 s 和 120 s。

表中的第一个模型为不采用自注意力重构模

块, 第二个模型为不采用 GAT 模块, 最后一个模型为本文提出的 DA-STGCN。实验结果表明, DA-STGCN 模型在 4 个数据集上的 ADE 和 FDE 指标

都为最低值, 取得了最好的预测效果, 即同时采用自注意力重构模块和 GAT 模块能有效提高模型的轨迹预测性能, 这证明了本文模型的有效性。

表 3 DA-STGCN 模型各模块消融实验结果

模型	时长 T_p/s	ATA1数据集		ATA2数据集		DA1数据集		DA2数据集	
		ADE/m	FDE/m	ADE/m	FDE/m	ADE/m	FDE/m	ADE/m	FDE/m
无自注意力 重构模块	60	733.2	981.7	857.7	1 058.8	838.3	960.8	1 148.6	1 456.2
	90	962.1	1 421.9	1 012.9	1 707.8	1 485.6	1 897.2	1 424.1	2 088.2
	120	1 373.1	2 055.5	1 392.4	2 402.7	1 956.9	2 928.9	1 981.1	3 490.3
无GAT模块	60	711.1	996.5	746.1	1 023.9	849.8	973.1	1 088.9	1 381.1
	90	937.2	1 392.8	1 024.7	1 688.4	1 344.9	1 923.9	1 465.2	2 070.1
	120	1 390.2	2 410.4	1 394.1	2 331.8	1 929.9	2 923.9	1 938.8	3 319.8
DA-STGCN (本文模型)	60	705.5	951.1	714.9	978.5	794.03	952.3	1 054.9	1 329.2
	90	934.5	1 375.7	984.5	1 598.6	1 265.5	1 791.4	1 366.9	2 033.4
	120	1 281.2	1 983.8	1 322.8	2 279.3	1 888.7	2 807.1	1 891.8	3 215.8

3.3.4 DA-STGCN 模型性能定性分析

图 4 展示了 DA-STGCN 模型和 Social-STGCNN 模型在同一场景下的预测轨迹可视化结果, 其中图 4a 和图 4b 分别为 DA-STGCN 模型预测的在机场终端区某一场景下, 飞机在水平维度和垂直维度

上的轨迹分布, 图 4c 和图 4d 为 Social-STGCNN 模型在同一场景下的预测结果。值得注意的是, 图 4a 中的 5 号飞机和图 4c 中的 5 号飞机并未起飞, 因此它们不存在轨迹分布。

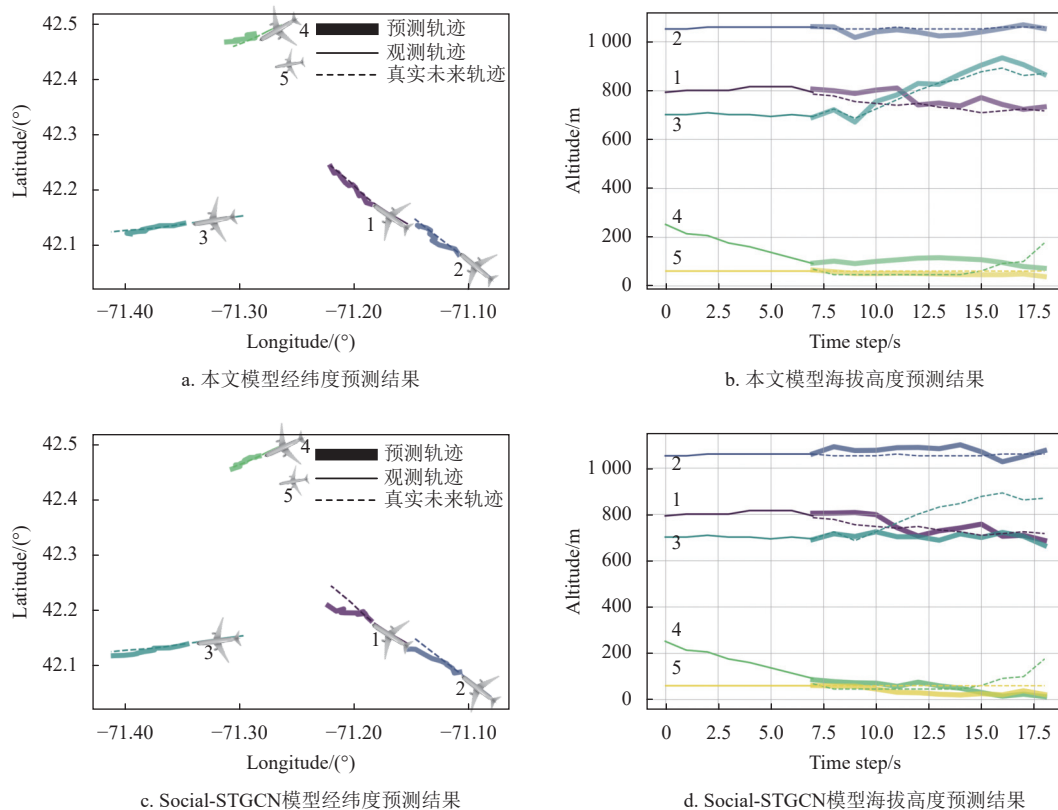


图 4 飞机轨迹预测结果定性分析

如图 4 所示, DA-STGCN 得到的预测轨迹基本能够反映飞机真实的未来轨迹, 且比 Social-STGCNN 模型的效果更好。在 DA-STGCN 模型的

预测结果中, 1 号飞机和 2 号飞机的预测轨迹与真实的未来轨迹基本一致, 而 Social-STGCNN 模型对这两架飞机的预测轨迹与真实的未来轨迹之间存

在较大的偏移。可见 DA-STGCN 模型可以更好地利用两架距离相近飞机之间的潜在相关性, 从而得到更准确的预测结果。对于海拔的预测结果, DA-STGCN 模型可以很好地预测每一架飞机的未来高度, 尽管有一些微小的偏移。但是, Social-STGCNN 模型对 3 号飞机的高度预测出现了较大的误差。总的来说, DA-STGCN 模型对飞机未来轨迹的预测性能优于 Social-STGCNN 模型, 这证明了本文方法的有效性。

对基于自注意力机制重构的邻接矩阵进行定性分析。图 5 展示了 DA-STGCN 模型在机场终端区某一场景下的飞机轨迹预测结果及其对应的邻接矩阵。其中, 图 5a 和图 5b 分别为飞机在水平维度和垂直维度上的轨迹分布, 图 5c 和图 5d 分别为初始邻接矩阵和重构邻接矩阵。邻接矩阵中某一行和某一列的值表征了这一行所对应的飞机对这一列所对应的飞机的影响程度。直观对比图 5c 和图 5d 可以看出, 重构邻接矩阵具有更加丰富的特征信息, 飞机与飞机之间的相互影响更加明显。可以看到, 在

图 5d 中 1 号飞机与 3 号飞机之间的影响程度小于图 5c, 这是因为这两架飞机正在朝着完全相反的方向飞行, 且它们之间的高度差很大, 本文的自注意力重构模块捕捉到了这些信息并对邻接矩阵进行了优化。此外, 初始邻接矩阵认为 2 号飞机和 3 号飞机之间具有较大的相关性, 此外, 初始邻接矩阵显示 2 号飞机和 3 号飞机之间具有较大的相关性, 但由于这两架飞机正在朝着相反的方向飞行, 它们之间的实际影响程度相对较小, 重构邻接矩阵对初始邻接矩阵进行了优化, 减小了它们之间的影响程度。总的来说, 本文的自注意力重构模块能够很好地优化邻接矩阵, 使其能够捕捉更加真实且丰富的节点相关信息, 这证明了本文方法的有效性。最后, 本文对各模型在预测时长分别为 60、90、120 s 的情况下进行了推理速度的对比实验分析, 结果如表 4 所示。DA-STGCN 模型在效率和性能之间保持了一个较好的平衡, 与 Social-STGCNN 模型相比, 在不大幅度降低推理效率的同时, 取得了更好的轨迹预测性能。

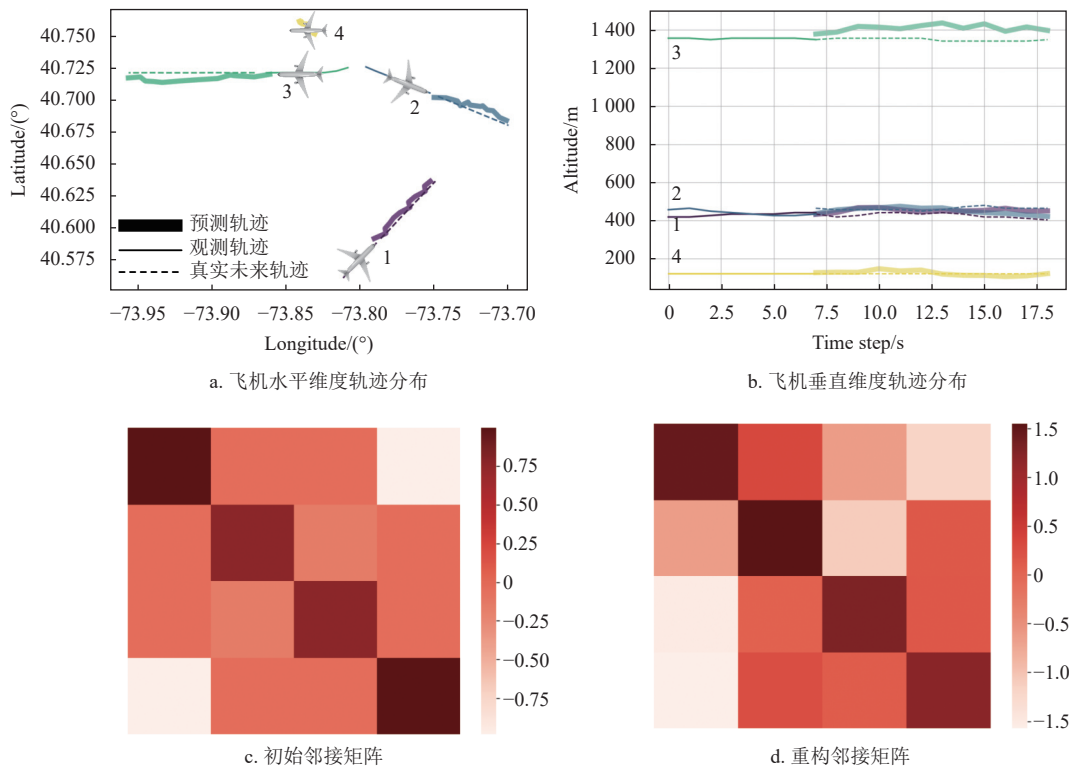


图 5 自注意力重构邻接矩阵定性分析

表 4 模型推理速度对比实验结果

预测时长	DA-STGCN	Graph-TERN	S-STGCNN	STGAT	Social-LSTM	LSTM	MLP
60	0.002 3	0.001 9	0.001 5	0.001 6	0.008 2	0.007 1	0.001 3
90	0.002 4	0.002 2	0.001 3	0.001 8	0.008 3	0.007 1	0.001 5
120	0.002 5	0.002 0	0.001 6	0.001 7	0.008 4	0.007 3	0.001 6

4 结束语

本文针对现有的飞机轨迹预测方法无法有效捕捉飞机之间潜在相关性的问题,提出了一种基于双注意力机制的时空图卷积网络模型。该模型首先利用自注意力机制对基于核函数定义的邻接矩阵进行重构,使其能够捕捉更加真实且丰富的节点相关信息,而非仅依赖于距离关系。随后,本文利用 GAT 进行了额外的节点特征汇聚,对原本的特征嵌入结果进行了补充,进一步强化了模型对节点相关性的捕捉。本文在 4 个真实的 ADS-B 数据集上对模型的效果进行了验证,对实验结果的定量分析表明 DA-STGCN 模型在 ADE 和 FDE 这两个指标上的综合表现均优于现有的飞机轨迹预测方法。对比原始的 Social-STGCNN 模型,在 ADE 度量上下降了大约 10.1%,在 FDE 度量上下降了大约 11.8%。对实验结果的定性分析表明本文提出的双注意力模块能够有效优化邻接矩阵对节点信息的描述并汇聚更加丰富的额外信息。

未来考虑将飞机更多的状态信息纳入节点特征中,如飞机的航向、航速、型号等等,使模型能够根据更加丰富的特征信息提高其预测的精度。此外,将更多地考虑环境中的一些因素,如气象、风速等,将本文模型从单模态扩展到多模态预测。

参考文献

- [1] RUIZ S, LOPEZ L J, RANIERI A. A novel performance framework and methodology to analyze the impact of 4D trajectory based operations in the future air traffic management system[EB/OL]. [2024-11-18]. <https://onlinelibrary.wiley.com/doi/full/10.1155/2018/1601295>.
- [2] SONG Y, CHENG P, MU C D. An improved trajectory prediction algorithm based on trajectory data mining for air traffic management[C]//2012 IEEE International Conference on Information and Automation. Shenyang: IEEE, 2012: 981-986.
- [3] ZENG W L, CHU X, XU Z F, et al. Aircraft 4D trajectory prediction in civil aviation: A review[J]. *Aerospace*, 2022, 9(2): 91.
- [4] International Civil Aviation Organization. Global air traffic management operational concept[EB/OL]. [2024-11-18]. https://www.icao.int/Meetings/anconf12/Document%20Archive/9854_cons_en%5B1%5D.pdf.
- [5] AVANZINI G. Frenet-based algorithm for trajectory prediction[J]. *Journal of Guidance, Control, and Dynamics*, 2004, 27(1): 127-135.
- [6] WANG T B. 4D flight trajectory prediction model based on improved kalman filter[J]. *Journal of Computer Applications*, 2014, 34(6): 1812.
- [7] LYMPEROPOULOS I, LYGEROS J. Sequential monte carlo methods for multi-aircraft trajectory prediction in air traffic management[J]. *International Journal of Adaptive Control and Signal Processing*, 2010, 24(10): 830-849.
- [8] AYHAN S, SAMET H. Aircraft trajectory prediction made easy with predictive analytics[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco: ACM, 2016: 21-30.
- [9] LIN Y, YANG B, ZHANG J W, et al. Approach for 4-D trajectory management based on HMM and trajectory similarity[J]. *Journal of Marine Science and Technology*, 2019, 27(3): 7.
- [10] 汤新民, 李腾, 陈强超, 等. 基于交互式多模型的短期 4D 航迹预测[J]. *武汉理工大学学报(交通科学与工程版)*, 2020, 44(1): 39-45.
TANG X M, LI T, CHEN Q C, et al. Short-term 4D trajectory prediction based on interactive multi-models[J]. *Journal of Wuhan University of Technology (Transportation Science & Engineering)*, 2020, 44(1): 39-45.
- [11] WEITZ L A. Derivation of a point-mass aircraft model used for fast-time simulation[EB/OL]. [2024-11-18]. https://www.mitre.org/sites/default/files/publications/pr_15-1318-derivation-of-point-mass-aircraft-model-used-for-fast-time-simulation.pdf.
- [12] LEE J, LEE S, HWANG I. Hybrid system modeling and estimation for arrival time prediction in terminal airspace[J]. *Journal of Guidance, Control, and Dynamics*, 2016, 39(4): 903-910.
- [13] CHANG Z N, HU M H, ZHANG Y, et al. A 4D trajectory prediction method for aircraft under wind[C]//Second International Conference on Electronic Information Engineering, Big Data, and Computer Technology (EIBDCT 2023). Xishuangbanna: SPIE, 2023: 206-211.
- [14] DE L A, VAN P M, MULDER M. A machine learning approach to trajectory prediction[C]//AIAA Guidance, Navigation, and Control (GNC) Conference. Boston: AIAA, 2013: 4782-4795.
- [15] TASTAMBEKOV K, PUECHMOREL S, DELAHAYE D, et al. Aircraft trajectory forecasting using local functional regression in sobolev space[J]. *Transportation Research Part C: Emerging Technologies*, 2014, 39: 1-22.
- [16] KANNEGANTI S T, CHILSON P B, HUCK R. Visualization and prediction of aircraft trajectory using ads-b[C]//NAECON 2018-IEEE National Aerospace and Electronics Conference. Dayton: IEEE, 2018: 529-532.
- [17] GEORGIOU H, PELEKIS N, SIDERIDIS S, et al. Semantic-aware aircraft trajectory prediction using flight plans[J]. *International Journal of Data Science and Analytics*, 2020, 9(2): 215-228.
- [18] WANG Z Y, LIANG M, DELAHAYE D. Short-term 4D trajectory prediction using machine learning methods[C]//SID 2017, 7th SESAR Innovation Days. Belgrade: SESAR, 2017: 1-9.
- [19] BARRATT S T, KOCHENDERFER M J, BOYD S P. Learning probabilistic trajectory models of aircraft in terminal airspace from position data[J]. *IEEE Transactions*

- on Intelligent Transportation Systems, 2018, 20(9): 3536-3545.
- [20] SHI Z Y, XU M, PAN Q. 4-D flight trajectory prediction with constrained LSTM network[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 22(11): 7242-7255.
- [21] MA L, TIAN S. A hybrid CNN-LSTM model for aircraft 4D trajectory prediction[J]. *IEEE Access*, 2020, 8: 134668-134680.
- [22] ZENG W L, QUAN Z B, ZHAO Z Y, et al. A deep learning approach for aircraft trajectory prediction in terminal airspace[J]. *IEEE Access*, 2020, 8: 151250-151266.
- [23] XU Z F, ZENG W L, CHU X, et al. Multi-aircraft trajectory collaborative prediction based on social long short-term memory network[J]. *Aerospace*, 2021, 8(4): 115.
- [24] ALAHI A, GOEL K, RAMANATHAN V, et al. Social LSTM: human trajectory prediction in crowded spaces[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 961-971.
- [25] MA L, MENG X R, WU Z J. Data-driven 4D trajectory prediction model using Attention-TCN-GRU[J]. *Aerospace*, 2024, 11(4): 313.
- [26] ZHANG H Y, LIU Z Z. Four-dimensional aircraft trajectory prediction with a generative deep learning and clustering approach[J]. *Journal of Aerospace Information Systems*, 2025, 22(2): 90-102.
- [27] LUO A F, LUO Y X, LIU H, et al. An improved transformer-based model for long-term 4D trajectory prediction in civil aviation[J]. *IET Intelligent Transport Systems*, 2024, 18(9): 1588-1598.
- [28] FAN Y Q, TAN Y J, WU L W, et al. Global and local inter-attribute relationships based graph convolutional network for flight trajectory prediction[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2024, 60(3): 2642-2657.
- [29] 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.
- [30] YAN S J, XIONG Y J, LIN D H. Spatial temporal graph convolutional networks for skeleton-based action recognition[C]//Proceedings of the AAAI Conference on Artificial Intelligence. New Orleans: AAAI, 2018: 7444-7452.
- [31] MOHAMED A, QIAN K, ELHOSEINY M, et al. Social-STGCNN: A social spatio-temporal graph convolutional neural network for human trajectory prediction[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 14424-14432.
- [32] XU Z F, LIU Y, CHU X, et al. Aircraft trajectory prediction for terminal airspace employing social spatiotemporal graph convolutional network[J]. *Journal of Aerospace Information Systems*, 2023, 20(6): 319-333.
- [33] LIAO W Q, WU Y G, ZHOU P L, et al. Dynamic navigation: Integrating GL-STGCNN and MPC for collision avoidance with future awareness[J]. *Ocean Engineering*, 2024, 309: 118416.
- [34] SUI D, LIU K C, LI Q. Dynamic prediction of air traffic situation in large-scale airspace[J]. *Aerospace*, 2022, 9(10): 568.
- [35] CHEN W H, WANG F F, SUN H B. S2tnet: Spatio-temporal transformer networks for trajectory prediction in autonomous driving[EB/OL]. [2024-11-18]. <https://proceedings.mlr.press/v157/chen21a.html>.
- [36] VELICKOVIC P, CUCURULL G, CASANOVA A, et al. Graph attention networks[EB/OL]. [2024-11-18]. <https://arxiv.org/abs/1710.10903>.
- [37] ZHANG Y B, ZHENG L Y. Pedestrian trajectory prediction with MLP-social-GRU[C]//Proceedings of the 2021 13th International Conference on Machine Learning and Computing. Shenzhen: ACM, 2021: 368-372.
- [38] SHI Z Y, XU M, PAN Q, et al. LSTM-based flight trajectory prediction[C]//2018 International Joint Conference on Neural Networks (IJCNN). Rio de Janeiro: IEEE, 2018: 1-8.
- [39] POLEWCZYK J, SCHWARZE A, GOVAERS F. Aircraft trajectory prediction and time estimation adapting social-LSTM[EB/OL]. [2024-11-18]. <https://www.researchsquare.com/article/rs-4195725/v1>.
- [40] HUANG Y F, BI H K, LI Z X, et al. Stgat: Modeling spatial-temporal interactions for human trajectory prediction[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019: 6272-6281.
- [41] BAE I, JEON H G. A set of control points conditioned pedestrian trajectory prediction[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Washington DC: AAAI, 2023: 6155-6165.

编辑 刘飞阳