http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0540

基于改进时空模型的终端区多航班航迹预测方法

贺怀清*，史小爽，刘浩翰，惠康华
(中国民航大学 计算机科学与技术学院，天津 300300)

摘　　要：由于终端区历史航迹数据量较大、存在丰富的时空特征和航迹位置点数据突变等特点，使得在进行终端区4D航迹预测时充满不确定性和复杂性。为此，给出一种基于改进时空模型的解决方法。该模型包括3部分：将时间卷积网络(TCN)和双向门控循环单元(BiGRU)引入航迹预测领域，并对TCN进行改进，提出双层多尺度时间卷积网络MMTCN，分别从全局和局部2个方面提取时间特征；将层归一化和残差引入图注意力网络GAT，以捕捉航班之间的复杂空间依赖关系；针对航迹位置点数据突变导致的数据不确定性问题，将得到的时空特征输入到条件变分自编码器(CVAE)中，以学习航迹数据的潜在表示，生成多条预测轨迹。在训练过程中采用学习率调整策略，加速模型训练。实验结果表明：改进模型在平均位移误差(ADE)和最终位移误差(FDE)2个指标上均表现最优，分别为0.082 6和0.111 1，显著优于其他基准模型；在通用航空数据集上，所提模型的ADE和FDE误差最大降低了约9.59%和7.75%，表明该模型能够更有效地提取时空特征，且具有训练稳定性。

关 键 词：终端区；航迹预测；改进时空模型；双层多尺度时间卷积；不确定性
中图分类号：V355; TP391
文献标志码：A　　**文章编号**：1001-5965(2026)11-3745-13

在空中交通管理(air traffic management, ATM)中，传统的航班进离场管理均以当前航班位置点、扇区运行为判断基础，缺乏对航班未来航迹的准确预测，在外界因素(如其他空域用户活动或复杂天气)的扰动下，很容易出现预判错误的情况，从而导致运行效率和安全水平的大幅度降低。同时，现有进离场管理系统的航班排序少有引入人工智能技术，决策的智能化程度不高，运行机制也较为僵化，难以快速适应运行环境的变化，不利于保障能力和运行效率的提升。为此，欧美等航空发达国家提出的基于航迹运行(trajectory-based operation, TBO)模式概念越来越受到关注，因为其可实现在高密度、大流量、小间隔条件下的有效空域管理。而4D航迹预测是实现TBO的基础，精准的4D航迹预测可以推进智慧化空管的发展。

ATM的繁忙区域为终端区，其涵盖了航班降落和起飞过程中的关键航段。航班需要在终端区有限的空间内合理调整航迹，确保航班安全、高效地降落，并与其他航班协同运行。通过准确预测航班在这一区域的航迹，ATM系统可以更好地协调航班的运动，规划航班的降落和起飞顺序，提高机场容量，减少等待时间，提高航班出发和到达效率，实现更高效的交通管理，加速空管自动化与智能化技术的应用与实施。

当前的航迹预测方法主要分为3类：采用动力学模型进行航迹预测、利用状态估计方法建立航迹预测模型、利用深度学习方法进行航迹预测。面向的对象有单航班航迹预测和终端区多航班航迹预

收稿日期：2024-07-18；**录用日期**：2024-11-01；**网络出版时间**：2025-01-02 09:40
网络出版地址：link.cnki.net/urlid/11.2625.V.20241231.1432.001
基金项目：国家重点研发计划(2020YFB1600101)
*通信作者. E-mail：hqhe@cauc.edu.cn

引用格式：贺怀清，史小爽，刘浩翰，等. 基于改进时空模型的终端区多航班航迹预测方法[J]. 北京航空航天大学学报，2026，52(11)：3745-3757. He H Q，Shi X S，Liu H H，et al. Multi-flight trajectory prediction method in terminal area based on an improved spatio-temporal model[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：3745-3757 (in Chinese).

测。单航班航迹预测能够准确地预测航班到达的时间及航迹点,在航班严重偏离航线时能及时发出警报。而终端区多航班航迹预测可以有效帮助管制员进行机场容量的调节,防止航班之间碰撞。传统的单航班航迹预测已无法满足高频次的终端区起降需求。因此,需要更准确、高效的多航班航迹预测方案,以应对复杂的终端区环境,并保障航班的安全运行。基于动力学方法[1-2]的航迹预测涉及大量参数,为简化模型,大多数研究是在理想假设下进行实验。因此,终端区多航班航迹预测研究主要集中在状态估计及机器学习或深度学习方法上。

在状态估计方法的研究中,Seah等[3]采用一种混合估计算法,开发了基于典型航班着陆剖面、起飞剖面和机场周围标准飞行路线的飞行模式转换方法。Lymperopoulos等[4]将多航班传感器融合问题表述为高维状态估计问题,并用实验证明了几种序列蒙特卡罗算法在涉及多航班问题可行性研究上的低效性,开发了一种新的粒子滤波算法来实现多航班航迹预测。Song等[5]利用数据挖掘提取航迹模式,通过聚类算法将具有相同时空特征的航迹聚类为一组,并采用混合估计算法进行航迹预测。Ayhan等[6]将空域视为三维网格网络,通过随机模型(即隐马尔可夫模型)来预测航迹点。状态估计算法通过不断地更新当前估计的状态,以适应传感器测量的新信息。因此,对传感器测量误差具有一定的鲁棒性。

基于深度学习的单航班航迹预测将航迹问题转换为时间序列问题,对大量历史航迹数据进行学习,从而预测未来航迹。目前,很多研究采用反向传播(back propagation, BP)神经网络、长短期记忆网络(long short-term memory, LSTM)、门控循环单元(gated recurrent unit, GRU)、时间卷积网络(temporal convolutional network, TCN)等进行航迹预测。Shi等[7]提出基于LSTM的航迹预测模型,LSTM中重复模块的4个交互层使其能够将长期依赖关系连接到当前的预测任务。Tran等[8]利用卷积层和GRU构建编码器和解码器结构进行建模,实现航迹预测。Huang等[9]提出一种基于TCN和双向门控循环单元(bidirectional gated recurrent unit, BiGRU)的新型航迹预测模型,并用贝叶斯算法对模型的超参数进行优化。焦卫东等[10]提出一种融合多尺度的TCN航迹预测方法,并通过时空双重注意力自适应地关注重要信息。

单航班航迹预测虽然只关注单个航班的时间特征趋势,但其也为多航班预测提供了研究基础。目前,越来越多的研究者利用深度学习处理多航班航迹预测问题。李楠等[11]提出一种基于遗传算法(genetic algorithm, GA)和BP神经网络的预测模型。针对4D航迹预测的实时性不强和存在迭代误差的问题,李旭娟等[12]提出了一种自动生成的条件变分自编码器(conditional variational autoencoder, CVAE)应用于终端区航迹预测。Zeng等[13]提出了一种序列间深度长短期记忆网络(sequence-to-sequence deep long short-term memory, SS-DLSTM),该网络可以有效地捕捉长短时间依赖关系和航迹之间的相似性。Xu等[14]提出一种基于社会长短期记忆网络(social long short-term memory, S-LSTM)的多航班航迹协同预测模型,通过建立池化层整合相关航班的隐藏状态,有效捕捉它们之间的交互。Pang等[15]提出了一种基于贝叶斯神经网络的3D航迹概率预测方法,但未考虑高度属性。除此之外,Pang等[16]还提出了基于Transformer的时空架构来模拟多个航班的空间和时间关系,并引入贝叶斯神经网络模拟航班之间的不确定性关系,但依旧未考虑航迹点的高度属性。Xu等[17]采用聚类算法挖掘典型的飞行模式,针对每类飞行模式训练时空卷积模型推断未来多个时间步长的航迹点。韩萍等[18]提出DBSCAN和GRU相结合的预测模型,使用聚类算法将航迹按照不同飞行模式进行聚类,并通过GRU对不同飞行模式航迹进行建模。尽管这些研究在航迹预测方面表现出一定的有效性,但聚类过程需要提前固定聚类参数,选择不合适的参数值可能导致航迹的聚类效果不佳,特别是在密度变化较大的区域。

综上所述,尽管目前先进的航迹预测方法在终端区航迹预测方面已经应用,但在预测维度上往往会忽略高度属性,在航迹生成时未考虑数据的不确定性,采用聚类算法时需要提前设置合适的参数值。本文针对以上问题,将改进时空模型应用在4D的航迹预测问题上。基于TCN的模型在并行处理、长时间依赖捕捉能力、梯度稳定性、参数共享和感受野灵活性方面均优于BP、LSTM和GRU,而基于BiGRU的模型能够提取双向特征信息。因此,本文模型以双层多尺度时间卷积网络MMTCN、BiGRU为基础提取航迹的时间特征;引入层归一化和残差的图注意力网络GAT提取终端区航班的交互信息,即航迹的空间特征;CVAE生成航迹分布解决数据不确定性。由此,该模型不会受到传感器的影响,不用提前选择参数值,是对时间、经度、纬度、高度的4D航迹预测,生成航迹时考虑了数据不确定性的影响。通过实验验证了模型在4D航迹预测方面的有效性。

1　航迹特征描述和数据预处理

1.1　数据源

本文实验数据源自上海浦东国际机场一周内的所有进出港航班，采样时间从 2023 年 7 月 1 日至 2023 年 7 月 7 日，采样时间间隔为 10 s，7 天共提取了 2 800 条以上海浦东国际机场为出发地或目的地的进出港航班飞行轨迹。经数据处理后，所有数据被划分为 179 个终端区飞行场景文件。随机选取部分场景终端区数据，其在数据重构和归一化前可视化结果如图 1 所示。

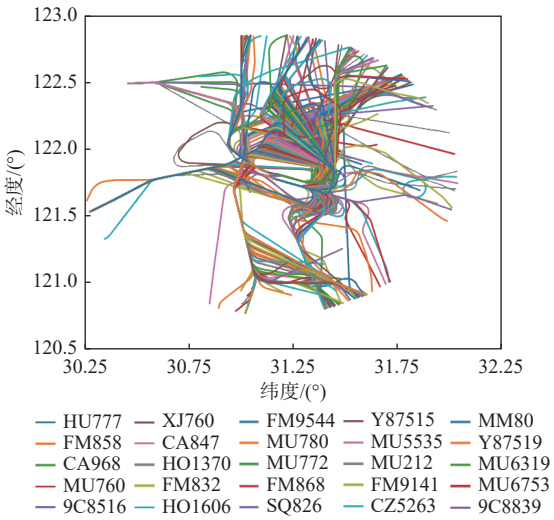

图 1　上海浦东国际机场部分场景终端区航迹

Fig. 1　Flight trajectory of some scene terminal areas of Shanghai Pudong International Airport

1.2　数据处理

1.2.1　提取终端区数据

根据《民用航空空中交通管理规则》(CCAR-93TM-R6)[19]，终端区域通常定义为水平范围 50 km 以内，垂直范围 6 000 m 以下、最低高度层以上。由于上海浦东国际机场与上海虹桥国际机场在同一个区，将水平范围划分在 100 km 以内。为方便预测，将经纬度转化为极坐标，删除高度超过 6 000 m 且距离机场超过 100 km 的数据点。

1.2.2　数据清洗和时序特征处理

由于传输错误、接收延迟、重复传输等原因，数据可能出现缺失、重复等问题。为了更好地训练，需要对数据进行清洗和重构，得到连续的时间序列数据。对于缺失问题，本文采用三次样条插值方法对数据进行插值处理，时间间隔为 10 s。对于重复问题，删除同一航班时间点重复的航迹数据。

1.2.3　数据重构

在进行归一化前，将“高度”属性值除以 1 000，减小数值幅度，能够提高模型的稳定性和收敛性。经纬度和高度属性值转化为直角坐标系下对应的坐标 x、y、z，方便后续预测。计算每个时间戳相对于第 1 个时间戳的时间差，整理成时间序列形式。为保证每个文件都是连续的时间序列，检查当前行的时间戳与前一行的时间戳之间的时间差是否大于 10 s，大于 10 s 就进行序列分割。最终，分割好的每个场景文件都是连续的时间序列。

1.2.4　数据归一化

对航迹数据中的 x、y、z 进行归一化处理，以消除不同特征间因量纲和类别不同而产生对数据分析结果的影响。本文采用最大-最小归一化方法，对 x 处理见式 (1)，对 y 和 z 采用类似处理。

$$x_i' = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \tag{1}$$

式中：$x_{\min}$ 为 x 维度的最小值；$x_{\max}$ 为 x 维度的最大值；x_i 为归一化前的数据；x_i' 为归一化后的数据。归一化后的数据分布在 [0,1] 区间内，并保持了原数据的完整性。

图 1 中的场景数据经上述数据处理后的航迹路线如图 2 所示。可以看出，一方面，上述数据处理操作不会破坏数据的整体空间布局，即该处理方法不会影响航迹预测的准确性；另一方面，终端区航迹比较复杂，在同一时间段内可能会有多个航班处于终端区范围内，为保证终端区起飞和降落安全及合理调度机场容量，准确的 4D 航迹预测是非常重要的。

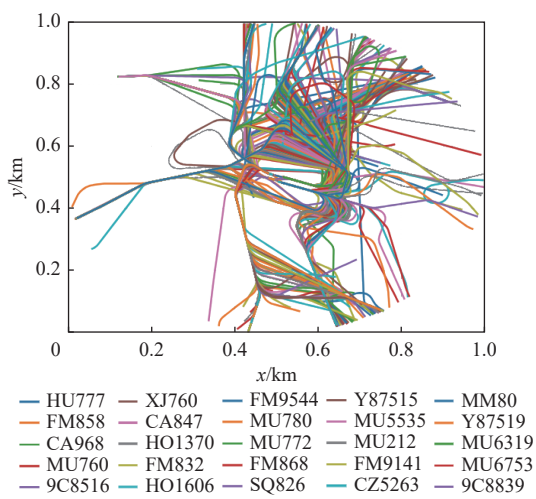

图 2　图 1 采用的数据经重构和归一化后的航迹数据

Fig. 2　Flight trajectory data after reconstruction and normalization of data used in Fig. 1

1.3　数据表示

假设预处理后航迹数据集合由 $\boldsymbol{I}$ 表示，如下：

$$\boldsymbol{I} = \{\boldsymbol{I}_1, \boldsymbol{I}_2, \cdots, \boldsymbol{I}_a, \cdots\} \qquad a \in R \tag{2}$$

式中：$\boldsymbol{I}_a$ 为航班 a 的航迹集合；R 为航班集合。

每条航迹由数量不等的航迹点组成，假设$\boldsymbol{d}_{ai}$表示航班a的第i个航迹点，航班a的航迹点集合如下：

$$\boldsymbol{I}_a=\{\boldsymbol{d}_{a1},\boldsymbol{d}_{a2},\cdots,\boldsymbol{d}_{ai},\cdots\} \tag{3}$$

每个航迹点包括时间、航班号、经度、纬度、高度所对应的直角坐标系下的坐标，如下：

$$\boldsymbol{d}_{ai}=(c_t,c_{\mathrm{id}},c_x,c_y,c_z) \tag{4}$$

式中：c_t为采样时间；c_{id}为航班号；c_x、c_y、c_z分别为经度、纬度、高度在直角坐标系下对应坐标。

2 改进时空模型

2.1 改进思想

航迹含有丰富的时空特征，通常情况下，航迹预测模型提取的时空特征越丰富，其预测结果越准确。因此，为了能够充分提取航迹数据的时间特征，根据对现有时间序列预测模型的分析，本文采用TCN和BiGRU。但是，随着TCN网络层数的增加，感受野也增大，较大的感受野会导致卷积应用在较大的时间跨度上，难以提取局部信息。因此，本文在TCN基础上引入双扩张层(dual dilated layer, DDL)[20]，既能考虑长期依赖关系，也能考虑短期依赖关系。DDL使用不同的卷积核提取多尺度信息，从而得到MMTCN。而BiGRU能够同时捕捉序列数据的前向和后向信息，从而更好地理解和预测序列中的模式。采用GAT提取航迹序列的空间特征，并受Transformer的启发，在GAT中引入层归一化和残差，提高模型收敛能力。针对航迹位置点数据突变导致的数据不确定性问题，使用CVAE去捕捉这种分布并学习航迹数据的潜在表示，通过采样的方式生成多条预测轨迹。为了下文叙述方便，将本文模型命名为改进时空预测模型(improved spatio-temporal prediction model, ISPM)。

2.2 模型结构

ISPM模型共包含3个核心部分：时间特征学习部分、空间特征学习部分及预测轨迹生成部分。模型的总体结构如图3所示。

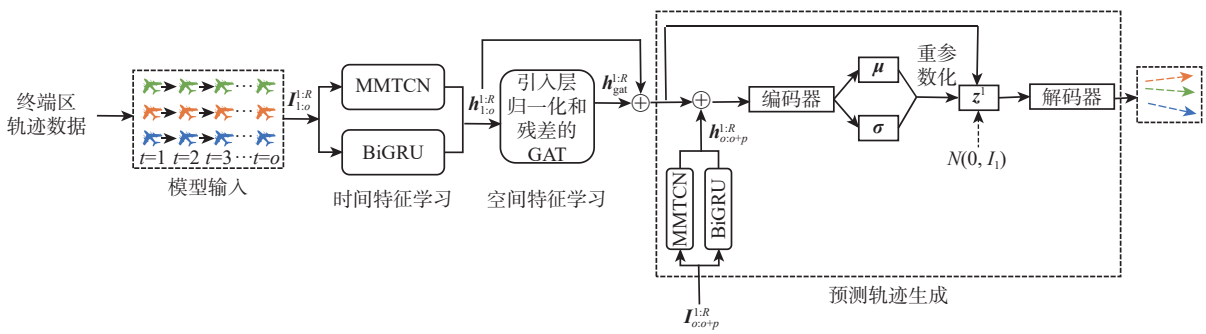

图3 ISPM模型的总体结构

Fig. 3 Overall structure of ISPM model

2.2.1 网络的输入

考虑预测某段时间内所有航班的未来航迹分布问题，设$\boldsymbol{I}_t^a=(x_t^a,y_t^a,z_t^a)$表示$t$时刻航班$a$的位置信息，并令$\boldsymbol{I}_{t_1:t_2}^{1:R}$表示$t_1\sim t_2$时间范围内所有航班的位置集合，上标表示航班集合，下标表示时间段。将航迹预测问题定义为：根据历史航迹信息$\boldsymbol{I}_{1:o}^{1:R}$找到未来航迹的分布$\boldsymbol{I}'^{1:R}_{o:o+p}$。

2.2.2 时间特征学习部分——MMTCN+BiGRU

时间特征学习是模型中用于处理时间序列信息的层，主要包含2个模块：MMTCN模块和BiGRU模块，以更全面地捕获时间序列数据中的特征和模式。

MMTCN模块是在传统TCN基础上引入了双层多尺度卷积。传统的TCN由残差结构组成，如图4所示。图中，残差连接由2个膨胀因子相同的卷积层组成，并采用权重初始化和正则化层解决梯度消失或爆炸问题。卷积操作后，通过残差连接将输入与卷积输出进行相加，即通过跨层连接来传递信息。膨胀卷积是在标准的卷积里注入空洞，以此来增加感受野。膨胀卷积的结构如图5所示。逐层膨胀因子d以2的指数增长，使得高层的感受野变大，很大的感受野会导致卷积应用在很大的时间跨度上，从而捕捉长期依赖关系，而短期的依赖关系很容易被忽略。因此，针对该问题，MMTCN在TCN基础上引入DDL和多尺度卷积。DDL结合了2种不同的膨胀卷积以增加模型对时间序列中长期和短期依赖关系的捕捉能力。DDL由2个并行的膨胀卷积层组成，每层使用不同的膨胀因子和卷积核。一个膨胀因子逐层递增捕捉长期依赖关系，另一个膨胀因子逐层递减更好地捕捉短期依赖关系，最终对提取的特征进行融合。MMTCN的结构如图6所示。

BiGRU是一种改进的循环神经网络(recurrent neural network, RNN)结构，如图7所示。通过结合2个独立的GRU层，一个沿正向处理序列，另一个

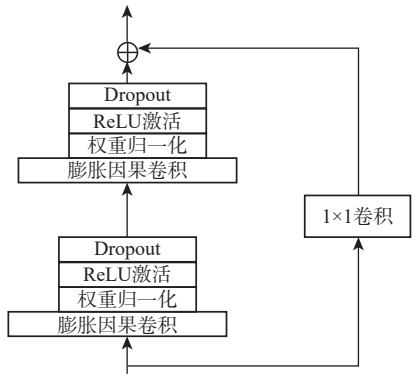

图 4　TCN 的残差结构

Fig. 4　Residual structure of TCN

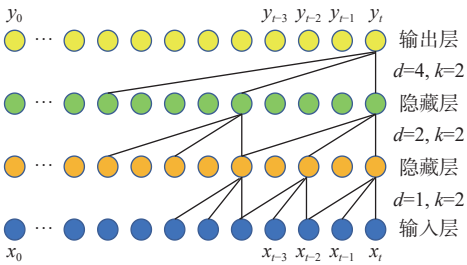

图 5　膨胀卷积结构

Fig. 5　Structure of dilated convolutional

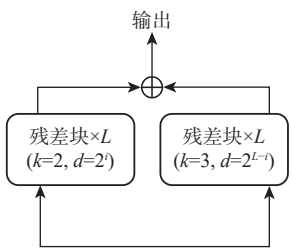

图 6　MMTCN 结构

Fig. 6　Structure of MMTCN

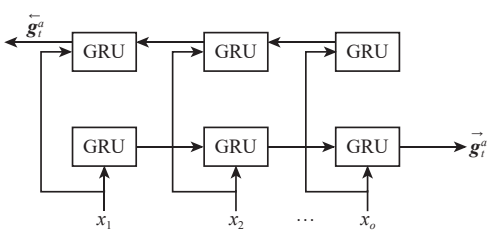

图 7　BiGRU 结构

Fig. 7　Structure of BiGRU

沿反向处理序列，增强了对时间序列数据中长距离依赖关系的捕捉能力。从图 7 可以看出，输入序列数据 $\boldsymbol{I}_{1:o}^{a}$ 得到正向隐藏状态输出 $\overrightarrow{\boldsymbol{g}}_t^a$ 和反向隐藏状态输出 $\overleftarrow{\boldsymbol{g}}_t^a$。BiGRU 通过双向处理序列数据，能够捕捉更复杂的时间模式和长距离依赖关系，从而提高预测的准确性。

2.2.3　空间特征学习部分——GAT*

GAT 通过引入注意力机制，为每个节点计算其邻居节点的重要性权重，根据这些权重来聚合邻居节点的空间位置和关系，即学习节点的空间特征。但随着网络深度的加深，网络参数更新可能导致训练不稳定，训练时往往需要很长时间收敛。因此，受 Transformer 启发，为提高训练效率，对 GAT 进行改进，得到 GAT*。Transformer 在进行自注意力后，使用残差连接和层归一化来加速训练和提高模型性能。类似地，可以将残差连接和层归一化引入到 GAT 中，以加速梯度传播和模型收敛，并降低训练过程中的梯度消失问题。与 GAT 一样，GAT*引入了注意力机制，使得每个航班节点可以根据与邻居节点的关系动态地分配不同的注意力权重，使得模型能够更加灵活地捕获节点之间的相互影响。GAT*网络结构如图 8 所示，图中，不同颜色代表多个头部，多个头部计算完注意力权重后进行拼接得到最终的输出特征。

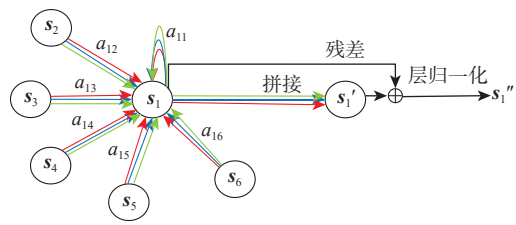

图 8　GAT*网络结构

Fig. 8　Structure of GAT* network

GAT*输入节点特征集合表示为

$$\boldsymbol{s}=\{\boldsymbol{s}_1,\boldsymbol{s}_2,\cdots,\boldsymbol{s}_i,\cdots\} \tag{5}$$

式中：$\boldsymbol{s}_i$ 为 i 航班初始节点特征向量。

经过 GAT*得到最终的嵌入向量集合，如下：

$$\boldsymbol{s}''=\{\boldsymbol{s}_1'',\boldsymbol{s}_2'',\cdots,\boldsymbol{s}_i'',\cdots\} \tag{6}$$

本文使用权值矩阵 $\boldsymbol{W}$ 作用在每个航班节点，用式 (7) 计算每个节点的权重系数：

$$e_{ij}=\frac{\mathrm{LeakyReLU}(\boldsymbol{a}_1^{\mathrm{T}}[\boldsymbol{W}\boldsymbol{s}_i\|\boldsymbol{W}\boldsymbol{s}_j])}{\sqrt{d_{\mathrm{model}}}}\qquad j\in N_i \tag{7}$$

式中：d_{model} 为 GAT*输入时嵌入向量的维度；$\boldsymbol{a}_1^{\mathrm{T}}$ 为可学习的参数向量；N_i 为节点 i 的邻居节点。

使用 Softmax 函数对当前航班节点的邻居节点做归一化处理。归一化后的权重系数为

$$\alpha_{ij}=\mathrm{softmax}(e_{ij})=\frac{\exp(e_{ij})}{\sum\limits_{j\in N_i}\exp(e_{ij})} \tag{8}$$

为稳定注意力机制的学习过程，GAT*选择使用多头注意力层。最终计算得到输出特征为

$$\boldsymbol{s}_i'=\mathrm{sigmoid}\left(\frac{1}{K}\sum_{k=1}^{K}\sum_{j\in N_i}\alpha_{ij}^{k}\boldsymbol{W}^{k}\boldsymbol{s}_j\right) \tag{9}$$

式中：$\boldsymbol{s}_i'$ 为融合了邻域信息的嵌入向量；sigmoid为激活函数；K 为多个头部。

引入残差连接和层归一化后的嵌入向量 $\boldsymbol{s}_i''$ 为

$$\boldsymbol{s}_i''=\mathrm{LayerNorm}(\boldsymbol{s}_i+\boldsymbol{s}_i') \tag{10}$$

GAT*为每个节点生成嵌入向量$\boldsymbol{s}_i''$。这些嵌入向量综合了节点自身的特征及其邻居节点的特征，反映了每个节点的空间位置和关系。这可以表示航班节点在空间中的位置及其运动趋势。

2.2.4 预测轨迹生成部分

在航迹数据中固然存在一些不确定性，对潜在变量$\boldsymbol{z}^1$进行多次采样，通常是为了在给定相同的输入和条件下，生成多样化的输出。据此，CVAE 方法利用了变分自编码器潜在空间中的随机性来生成不同的样本，从而可以更好地捕捉数据分布中的多样性，其结构如图 9 所示。

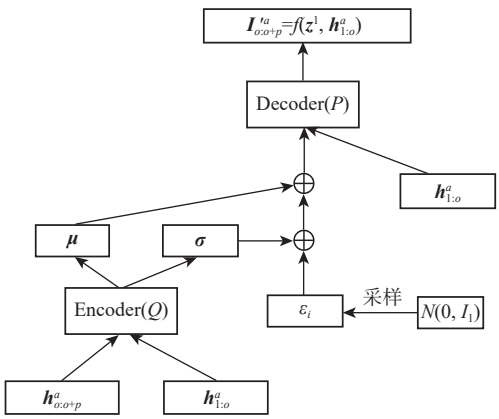

图 9 CVAE 网络结构

Fig. 9 Structure of CVAE network

将提取到的观察值特征$\boldsymbol{h}^a_{1:\,o}$作为数据内容，提取到的目标值特征$\boldsymbol{h}^a_{o:\,o+p}$作为标签一同输入 CVAE 的编码器 Encoder(Q) 中。Encoder(Q) 的任务是将输入数据映射到潜在空间中的分布参数：均值向量$\boldsymbol{\mu}$和方差向量$\boldsymbol{\sigma}$。模型训练时，需要从学习到的潜在分布中采样，为使模型可微分，通常使用重参数化技巧。重参数化技巧是从标准正态分布$N(0,I_1)$中采样得到多个随机变量ε_i，随机变量ε_i与$\boldsymbol{\mu}$和$\boldsymbol{\sigma}$结合起来，得到多个潜在空间中的样本点$\boldsymbol{z}_i^1=\boldsymbol{\mu}+\varepsilon_i\boldsymbol{\sigma}$。从潜在空间中采样得到的样本点$\boldsymbol{z}_i^1$和观察值特征$\boldsymbol{h}^a_{1:\,o}$一同输入到解码器 Decoder($P$)，生成多个预测值。

2.3 网络的输出和损失

在 2.2.4 节所述采样过程中，设置采样次数为 M，即对于输入数据，经过 M 次采样后得到 M 个不同的随机变量ε_i，分布参数和对应的随机变量结合后得到不同的潜在空间样本点$\boldsymbol{z}_i^1$。最终进入解码器生成 M 组不同的航迹数据，并计算 M 条航迹与真实航迹的损失，选择损失最小的一条航迹作为最终预测结果。

CVAE 的损失函数由 2 部分组成，即重构损失和 KL 散度。

$$L^{\mathrm{Loss}}=L_{\mathrm{RL}}^{\mathrm{Loss}}+L_{\mathrm{KL}}^{\mathrm{Loss}} \tag{11}$$

式中：L^{Loss}为整体损失；$L_{\mathrm{RL}}^{\mathrm{Loss}}$为重构损失；$L_{\mathrm{KL}}^{\mathrm{Loss}}$为 KL 散度。

重构损失是衡量解码器生成数据与原始数据之间的差异，使用均方误差（mean squared error, MSE）来计算：

$$L_{\mathrm{RL}}^{\mathrm{Loss}}=\left\|\boldsymbol{I}^a_{o:\,o+p}-\boldsymbol{I}'^a_{o:\,o+p}\right\|^2 \tag{12}$$

式中：$\boldsymbol{I}^a_{o:\,o+p}$为实际目标值；$\boldsymbol{I}'^a_{o:\,o+p}$为预测值。

KL 散度可以衡量潜在分布与标准正态分布之间的差异，促使学习到的潜在分布接近于标准正态分布：

$$L_{\mathrm{KL}}^{\mathrm{Loss}}=\mathrm{KL}\{N(\boldsymbol{\mu},\boldsymbol{\sigma}),N(0,I_1)\} \tag{13}$$

式中：$N(\boldsymbol{\mu},\boldsymbol{\sigma})$为潜在空间分布；$N(0,I_1)$为标准正态分布。

2.4 模型训练时学习率的调整策略

适当的学习率 (learning rate, LR) 可以帮助模型更快地收敛到最优解，从而提高预测精度。如果学习率过高，可能导致模型在参数空间中跳跃太大，错过最优解，甚至无法收敛。如果学习率过低，模型更新的步长太小，可能会导致训练过程非常缓慢，甚至停滞不前。采用合适的学习率调整策略可以在训练过程中平衡速度和精度。

学习率调整策略可以分为如下 4 种：

1）固定学习率。在整个训练过程中，保持学习率不变。这是最简单的策略之一，但在训练过程中可能无法很好地适应模型参数的变化。固定学习率为 0.001，其他动态学习率初始值也为 0.001。

2）学习率衰减。随着训练的进行，逐渐减小学习率。LambdaLR 是一种自定义学习率调整策略，定义 lambda 函数为 1/(e+1)，随着 e 的增加（e 为训练轮数），学习率会按照该函数的规则进行调整。

3）学习率增加。在训练初期逐渐增加学习率，这可以帮助模型更快地找到合适的参数范围。ConstantLR 在设置的周期内将初始学习率乘以 0.1，设置的周期外恢复原学习率。

4）其他调整策略。①CosineAnnealingLR 是余弦退火学习率，在训练周期内通过一系列的学习率循环来调整学习率，而不是像其他调整策略那样单调地递减或递增学习率，因为最佳学习率可能会出现在上升或下降过程中。该策略余弦周期设为 20，学习率最小值设为 0.000 1，最大设为 0.001。②ReduceLROnPlateau 根据性能指标自动调节学习率，当性能指标停止改善时，其会逐渐减小学习率，以便模型更好地收敛。

不同的学习率调整策略导致 ISPM 模型训练时的学习率变化趋势如图 10 所示。

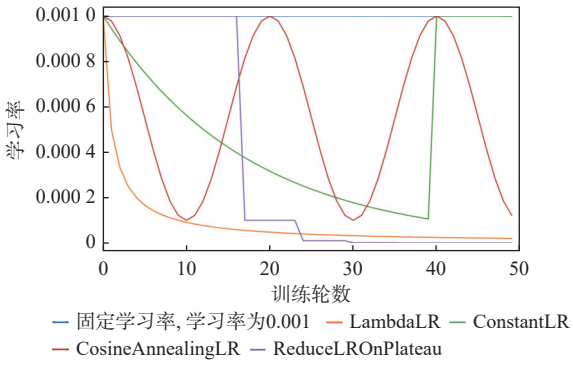

图 10　不同学习率调整策略的学习率变化趋势

Fig. 10　Trends in learning rates for different learning rate adjustment strategies

图 11～图 13 为采用不同的学习率调整策略得到的 ISPM 模型训练损失、平均位移误差 (average displacement error, ADE) 和最终位移误差 (final displacement error, FDE)。

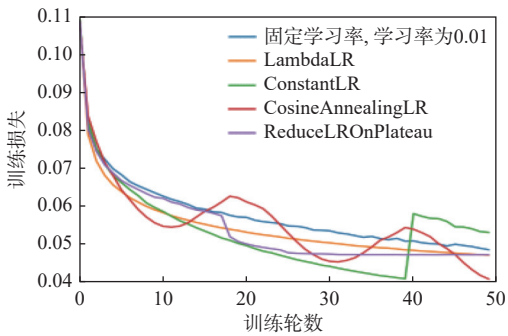

图 11　不同学习率调整策略的训练损失变化趋势

Fig. 11　Trends in training loss for different learning rate adjustment strategies

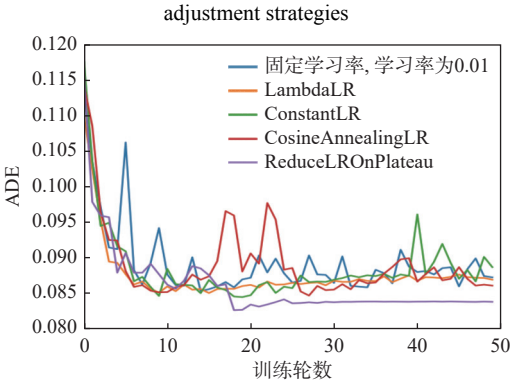

图 12　不同学习率调整策略的 ADE 变化趋势

Fig. 12　ADE trends of different learning rate adjustment strategies

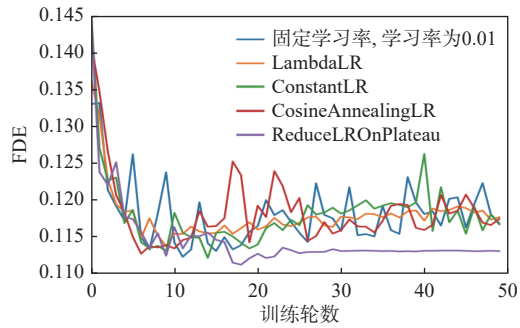

图 13　不同学习率调整策略的 FDE 变化趋势

Fig. 13　FDE trends of different learning rate adjustment strategies

cement error, FDE)。

综上所述，动态的学习率调整策略要比固定的学习率更有效，且经过实验测试，ReduceLROnPlateau 是 ISPM 模型最适合的学习率调整策略，因为其在降低训练和测试损失方面提供了良好的平衡，确保了模型的良好泛化和稳定性。

3　实　验

实验步骤包括数据处理、数据集划分、模型训练过程、结果评估和分析等，详见图 14。

3.1　实验数据和实验环境

航迹数据按时间顺序分布，经第 1 部分处理后的数据样本示例如表 1 所示。表中，时间列是处理后的，时间间隔 1 表示 10 s，后 3 列表示归一化后的直角坐标系下的经纬度和高度坐标。每条航班的时间总步各不相同。每个航迹点包含航班号、时间、经度、纬度和高度信息，以前 5 天的数据作为训练集，后 2 天的数据作为测试集。实验基于 Ubuntu 18.04 系统搭建，使用 Python 3.7.16 语言与 PyTorch1.7.0(CUDA10.1)深度学习框架，开发工具为 VS Code；硬件搭载 Intel Xeon Silver 4214 CPU、Quadro RTX 5000 GPU，内存容量 32 GB。

3.2　试验超参数设置

超参数的设置对模型的训练至关重要，合适的参数设置才能发挥出模型的较大潜力。本文模型超参数设置均源于实验测试，最终结果如表 2 所示。

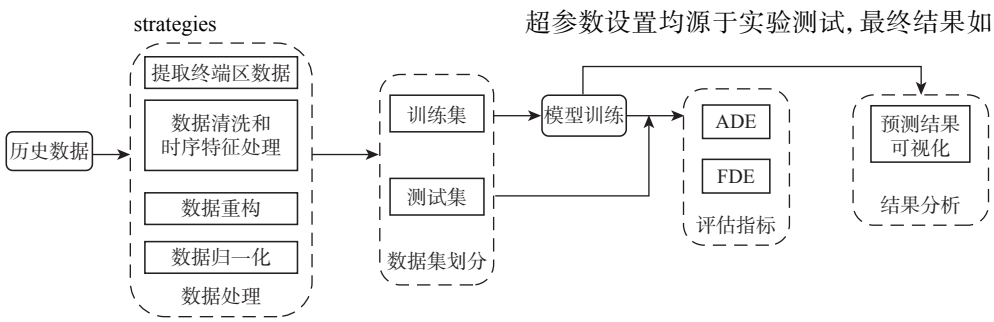

图 14　航迹预测实验过程

Fig. 14　Process of flight trajectory prediction experiment

表1 航迹数据样本示例

Table 1 Sample example of flight trajectory data

时间	航班号	x	y	z
364	MM898	0.525 287 060 658 0	0.755 073 711 662 53	0.670 43
365	MM898	0.531 720 409 931 5	0.762 855 410 616 43	0.692 91
366	MM898	0.537 913 300 176 0	0.770 273 390 965 28	0.719 70
367	MM898	0.544 069 273 704 9	0.777 706 549 421 61	0.737 87
368	MU779	0.487 693 439 718 6	0.509 826 542 767 41	0.070 76
368	MM898	0.550 259 272 881 3	0.785 354 425 281 30	0.748 79
369	MU779	0.483 954 572 085 1	0.511 351 278 489 04	0.094 10
369	MM898	0.556 525 940 959 7	0.793 172 262 586 36	0.756 92
370	MM898	0.562 468 920 606 6	0.801 642 702 915 90	0.762 63
370	MU779	0.480 143 921 949 0	0.512 975 391 587 61	0.111 63

表2 模型超参数设置

Table 2 Model hyperparameter settings

参数	数值
TCN卷积层输出的总通道数	256
TCN层数	2
TCN中卷积核的大小	[2,3]
TCN中的膨胀系数(i为卷积层数,G为总层数)	$[2^i, 2^{(G-1-i)}]$
TCN中的Dropout	0.2
BiGRU网络层数	2
BiGRU中隐藏层大小	128
GAT*中的注意力头数量	16
GAT*模型中隐藏层大小	256
GAT*中激活函数的负斜率参数	0.2
CVAE中隐藏层大小	128
CVAE中卷积层输出的通道数	128
CVAE网络层数	2
采样次数M	5

3.3 实验类型和指标

通过对比实验、参数敏感性实验验证ISPM模型的收敛性、准确性和时空特征提取的强有效性,以及历史时间步长对预测结果的影响,并通过消融实验验证各功能模块的作用。

本文评价指标采用ADE和FDE。目前,航迹预测常用的指标有平均绝对误差(mean absolute error, MAE)和MSE。MAE和MSE衡量经纬度和高度3个维度上真实值与预测值之间差异的整体情况,但在轨迹预测中,MAE和MSE没有针对性地考虑轨迹的时间序列特性及最终位置的准确性,无法很好地体现轨迹预测的关键要点。经过文献查阅比较,最终本文采用了行人轨迹预测中常用的ADE和FDE。

ADE为在所有时间上真实航迹和预测航迹之间的平均位移误差:

$$A_m^{\mathrm{ADE}} = \frac{1}{R}\cdot\frac{1}{T}\min_{m=1}^{M}\sum_{a=1}^{R}\sum_{t=o}^{o+p}\left\|\boldsymbol{I}_t^{a,m}-\boldsymbol{I}_t^{a,m}\right\|^2 \tag{14}$$

式中:$\boldsymbol{I}_t^{a,m}$为真实航迹;$\boldsymbol{I}_t^{a,m}$为预测航迹;T为时间段内时间点的数量;A为这段时间内所存在的航班数。

FDE表示最终时间的真实航迹和预测航迹之间的位移误差:

$$F_m^{\mathrm{FDE}} = \frac{1}{R}\min_{m=1}^{M}\sum_{a=1}^{R}\left\|\boldsymbol{I}_{o+p}^{a,m}-\boldsymbol{I}_{o+p}^{a,m}\right\|^2 \tag{15}$$

3.3.1 实验1

随着训练轮次的增加,收敛良好的模型的损失函数值逐渐减少并趋于稳定,这表明模型在训练数据上的表现越来越好。在TCN基础上进行实验,并通过损失函数曲线分析模型的收敛性。

为简化实验,初始模型为TCN-GAT-CVAE,实验结果如图15所示。图中,蓝线Traj表示初始模型,学习率固定为0.001,可以看出,训练损失上下震荡非常大;橙线Traj+lr1是在初始模型基础上调整测试损失计算方式,并加入了学习率调整策略,初始测试损失计算方式是先对所有航班预测结果进行采样,找到采样的最优解,但对于不同的航班预测结果来说,可能最优解出现在不同的采样中,因此,选择对不同的航班预测轨迹分别采样;绿线Traj+lr1+AN表示在Traj+lr1方案基础上加入了层归一化和残差,可以加速模型的训练过程,使其更快地收敛。根据图15的结果,在模型中引入学习率调整策略及在GAT中引入层归一化及残差对加速模型收敛是有效的,其始终显示出最低的训练损失,并且相较于其他2种方式可以更快地稳定。

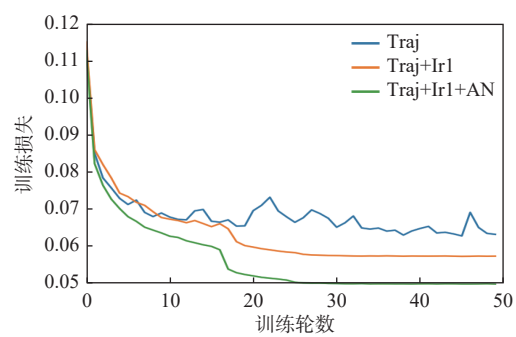

图15 模型训练过程收敛性对比实验分析

Fig. 15 Comparative experimental analysis of convergence of model training process

为验证模型性能,将本文模型与X-GAT*-CVAE在上海浦东国际机场数据集上做对比实验,所选基准模型X为LSTM、GRU、BP等网络,实验结果如表3所示。观察值时间步长为12,预测步长为60,

表 3　不同模型对比实验分析

Table 3　Comparative experimental analysis of different models

模型	ADE	FDE
BP-GAT*-CVAE	0.093 8	0.118 4
LSTM-GAT*-CVAE	0.089 9	0.121 9
GRU-GAT*-CVAE	0.089 5	0.121 2
ISPM	0.082 6	0.111 1

预测结果以每 6 个时间步输出一次。实验结果表明，ISPM 模型的预测误差低于所有基准模型，表明其在提取时空特征方面更有效。

以测试集中的一个场景为例进行可视化，可视化前需要将航迹数据进行反归一化，反归一化后的航迹是直角坐标系的坐标。可视化结果如图 16～图 19 所示。从该场景可视化结果分析，存在航班为 1,2,3,4 的情况，既包含了单航班，也包含了多航班的情况。因此，可以说明该模型既可以处理单航班 4D 航迹预测，也可以处理多航班 4D 航迹预测问题。且从可视化结果可以看出，ISPM 模型比其他基准模型的预测结果都更接近真实航迹。

3.3.2　实验 2

历史数据长度对航迹预测模型的精度影响很大，其决定了模型能够利用多少历史数据来进行预测。如果历史数据的长度较短，无法更好地捕捉数据的长期趋势和模式；如果历史数据的长度较长，可能会导致模型过度拟合历史数据，降低对未来数据的泛化能力。因此，在预测长度和其他参数不变的情况下，预测结果以每 6 个时间步输出一次，相当于预测间隔为 1 min。对不同长度历史数据进行实验对比，相关分析结果如表 4 所示。当观察时间步长为 12 时，预测结果最优。

3.3.3　实验 3

为证明模型的普适性，将本文模型运用在通用航空数据集中。该数据集是匹兹堡-巴特勒地区机场无塔式航站楼空域中的航迹数据，共包含 4 个连续 7 天的子数据集：7days1、7days2、7days3、7days4。由于该数据集考虑了天气属性，为方便和通用航空模型 Trajairnet[21] 作对比实验，本文在 ISPM 模型的结构上使用 CNN 提取天气特征。历史时间步长为 11，预测时间步长为 120，时间间隔为 1 s。实验对比结果如表 5 所示，实验证明模型在通用航空数据

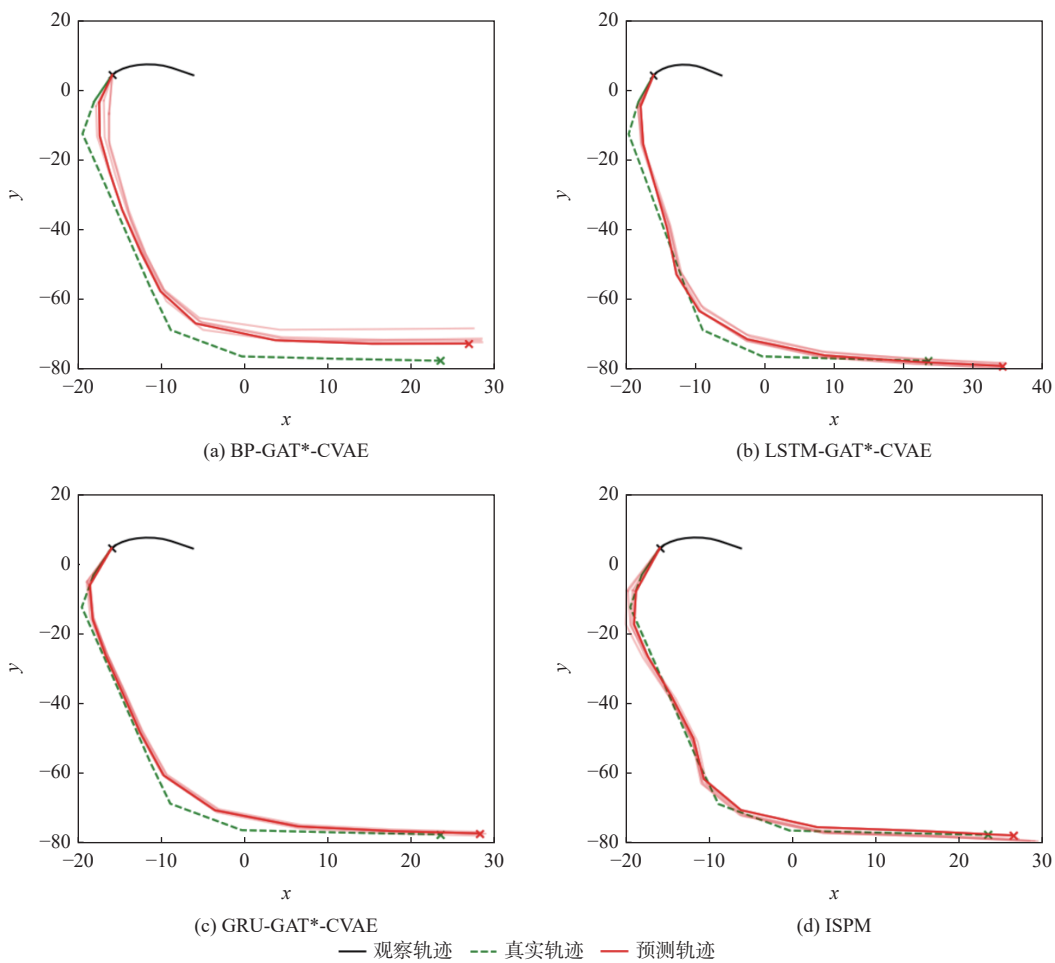

图 16　场景中只有 1 个航班时不同模型对比结果

Fig. 16　Comparison results of different models when there is one flight in the scene

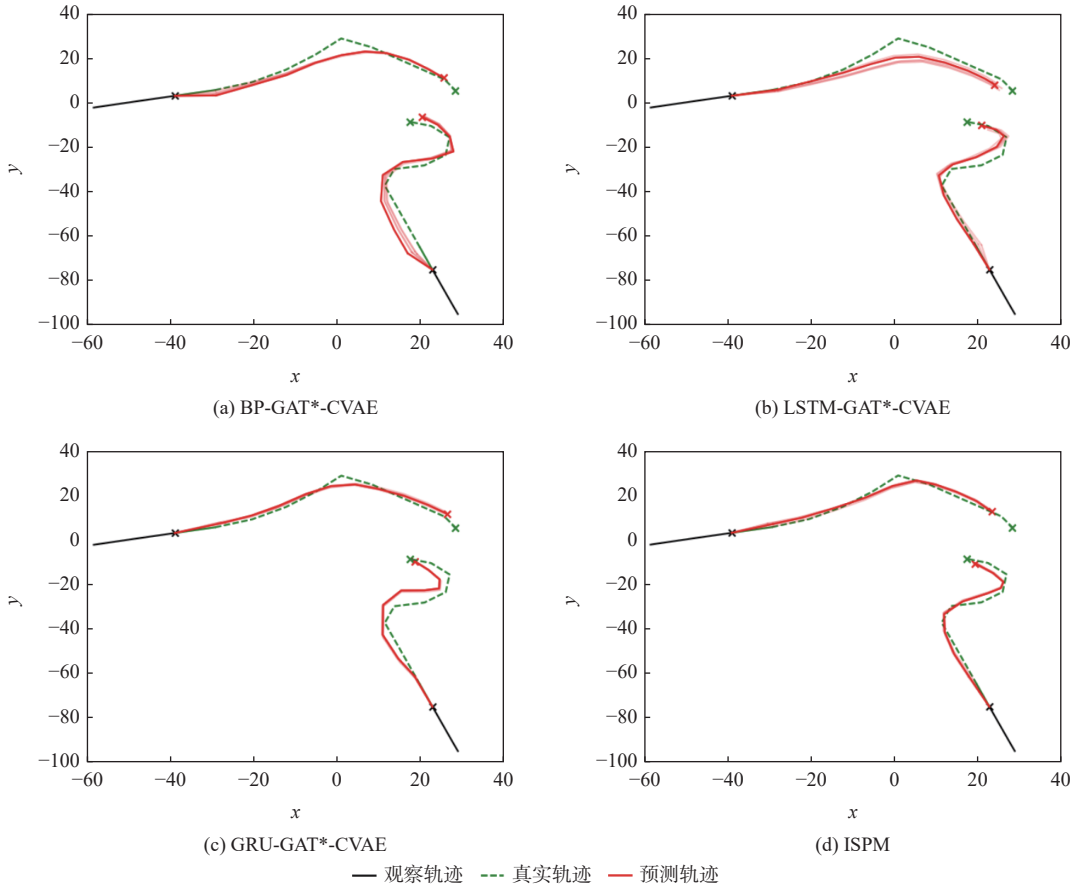

图 17 场景中有 2 个航班时不同模型对比结果

Fig. 17 Comparison results of different models when there are two flights in the scene

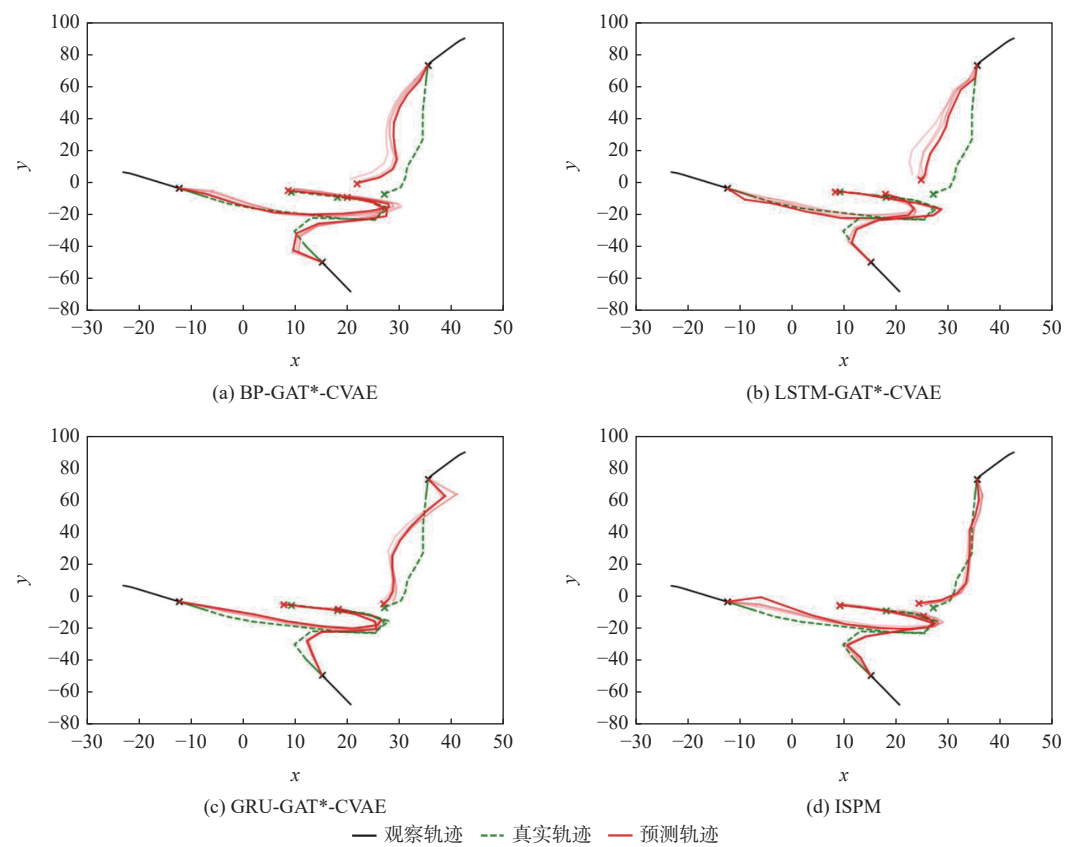

图 18 场景中有 3 个航班时不同模型对比结果

Fig. 18 Comparison results of different models when there are three flights in the scene

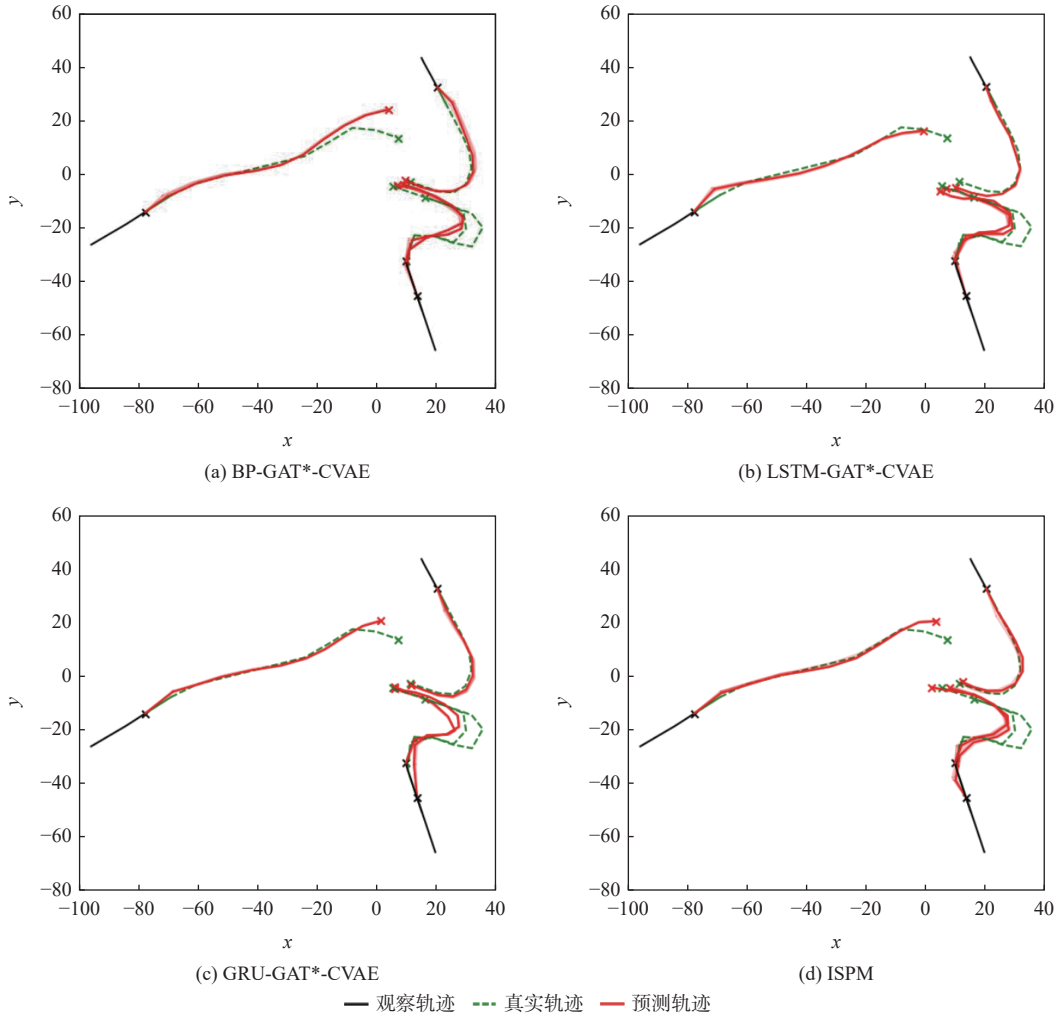

图 19　场景中有 4 个航班时不同模型对比结果

Fig. 19　Comparison results of different models when there are four flights in the scene

表 4　历史数据的长度敏感性分析

Table 4　Length sensitivity analysis of historical data

历史数据长度	预测时间步长	时间步	ADE	FDE
8	60	6	0.091 3	0.124 3
12	60	6	0.082 6	0.111 1
24	60	6	0.088 1	0.111 9
36	60	6	0.095 4	0.116 9

表 5　通用航空数据集上的对比结果

Table 5　Compare results on general aviation datasets

模型	数据集	ADE	FDE
Trajairnet	7days1	0.73	1.42
	7days2	0.81	1.63
	7days3	0.86	1.72
	7days4	0.71	1.41
ISPM	7days1	0.66	1.31
	7days2	0.73	1.44
	7days3	0.83	1.65
	7days4	0.66	1.33

集上的表现也较好。

3.3.4　实验 4

实验 1 已对本文模型与基线模型做了对比实验，结果说明了模型的有效性。为验证本文模型改进模块的作用，进行了一系列的消融实验。以 ISPM 模型为基础，分别移除 BiGRU、MMTCN、多尺度、DDL 等模块，实验结果如表 6 所示。表中：ISPM-B 模型是在整体的基础上去除 BiGRU，ISPM-T 模型是在原模型基础上去除 MMTCN 模块，ISPM-M 是在原模型基础上去除多尺度卷积，ISPM-D 是在原模型基础上去除 DDL。由表 6 表明，移除任何一个模块，实验预测精度都会有一定程度的下降，这说明每个模块对模型的预测性能都起到了一定的作用。

表 6　消融实验结果

Table 6　Results of ablation experiments

功能模块	ADE	FDE
ISPM-B	0.083 9	0.111 7
ISPM-T	0.085 4	0.113 7
ISPM-M	0.085 2	0.115 4
ISPM-D	0.084 6	0.114 2
ISPM	0.082 6	0.111 1

4 结 论

本文提出一种改进时空模型ISPM用于解决终端区4D航迹预测问题，基于航迹数据集完成对比实验，实验结果在2个评价指标ADE和FDE上均优于基准模型。主要结论如下：

1）ISPM模型架构的创新。融合了MMTCN和BiGRU的优势，以提取序列数据的时间特征；采用GAT计算当前航班的权重矩阵，提取空间特征；引入Transformer的设计理念，在GAT中加入残差连接和层归一化处理，以调节训练过程中的不稳定性。

2）训练策略。训练过程中采用学习率调整策略，提高了模型的收敛性和预测准确性。

3）模型性能。ISPM与X-GAT*-CVAE在上海浦东国际机场数据集上做对比实验，所选基准模型X为LSTM、GRU、BP等较为先进的航迹预测模型，实验结果表明，ISPM比其他基准模型的预测结果都更接近真实航迹。

4）模型的普适性。更换数据集，ISPM与通用航空模型Trajairnet在通用航空数据集上做对比实验，ISPM模型实验结果优于Trajairnet。

ISPM没有考虑天气、航空器故障等不确定性因素及航速航向对航迹预测的影响，因此下一步工作将解决这些问题，以进一步提升预测精度；同时探索在线更新模型参数的方式以便面对新的数据时能够及时调整和优化，进一步提升终端区航迹预测的准确性。

参考文献（References）

[1] Tang X M, Han Y X. 4D trajectory estimation for air traffic control automation system based on hybrid system theory[J]. PROMET-Traffic& Transportation, 2012, 24(2): 91-98.

[2] 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.

[3] Seah C E, Hwang I. Terminal-area aircraft tracking using hybrid estimation[J]. Journal of Guidance, Control, and Dynamics, 2009, 32(3): 836-849.

[4] 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.

[5] Song Y, Cheng P, Mu C D. An improved trajectory prediction algorithm based on trajectory data mining for air traffic management[C]//Proceedings of the IEEE International Conference on Information and Automation. Piscataway: IEEE Press, 2012: 981-986.

[6] 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. New York: ACM, 2016: 21-30.

[7] Shi Z Y, Xu M, Pan Q, et al. LSTM-based flight trajectory prediction[C]//Proceedings of the International Joint Conference on Neural Networks. Piscataway: IEEE Press, 2018: 1-8.

[8] Tran P N, Nguyen H Q V, Pham D T, et al. Aircraft trajectory prediction with enriched intent using encoder-decoder architecture[J]. IEEE Access, 2022, 10: 17881-17896.

[9] Huang J, Ding W J. Aircraft trajectory prediction based on Bayesian optimised temporal convolutional network-bidirectional gated recurrent unit hybrid neural network[J]. International Journal of Aerospace Engineering, 2022, 2022. : 1-19.

[10] 焦卫东, 杨蓓. 一种融合MSC和时空注意力的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 attention[J]. Journal of Beijing University of Aeronautics and Astronautics, 2026, 52(1): 15-27 (in Chinese).

[11] 李楠, 孙伯鑫, 焦庆宇, 等. 基于GA-BP神经网络的终端区航迹预测[C]//世界交通运输工程技术论坛. 北京: 中国公路学会, 2021: 396-405.
Li N, Sun B X, Jiao Q Y, et al. Trajectory prediction of terminal area based on GA-BP neural network[C]//Proceedings of the World Transport Convention. Beijing: China Highway and Transportation Society, 2021: 396-405(in Chinese).

[12] 李旭娟, 皮建勇, 黄飞翔, 等. 基于自生成深度神经网络的4D航迹预测[J]. 计算机应用, 2021, 41(5): 1492-1499.
Li X J, Pi J Y, Huang F X, et al. Self-generated deep neural network based 4D trajectory prediction[J]. Journal of Computer Applications, 2021, 41(5): 1492-1499(in Chinese).

[13] 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.

[14] 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.

[15] Pang Y T, Liu Y M. Probabilistic aircraft trajectory prediction considering weather uncertainties using dropout as Bayesian approximate variational inference[C]//Proceedings of the Scitech 2020 Forum. Reston: AIAA, 2020: 1413.

[16] Pang Y T, Zhao X Y, Hu J M, et al. Bayesian spatio-temporal graph Transformer network (B-STAR) for multi-aircraft trajectory prediction[J]. Knowledge-Based Systems, 2022, 249: 108998.

[17] 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.

[18] 韩萍, 张启, 石庆研, 等. 基于DBSCAN-GRU算法的终端区4D航迹预测[J]. 信号处理, 2023, 39(3): 439-449.
Han P, Zhang Q, Shi Q Y, et al. 4D trajectory prediction of terminal area based on DBSCAN-GRU algorithm[J]. Journal of Signal Processing, 2023, 39(3): 439-449 (in Chinese).

[19] CCAR-93TM-R6 民用航空空中交通管理规则[S].
CCAR-93TM-R6 Civil aviation air traffic management rules[S] (in Chinese).

[20] Lin Z, Yue W Q, Huang J, et al. Ship trajectory prediction based on

the TTCN-attention-GRU model[J]. Electronics, 2023, 12(12): 2556.
[21] Patrikar J, Moon B, Oh J, et al. Predicting like a pilot: dataset and method to predict socially-aware aircraft trajectories in non-towered terminal airspace[C]//Proceedings of the International Conference on Robotics and Automation. Piscataway: IEEE Press, 2022: 2525-2531.

Multi-flight trajectory prediction method in terminal area based on an improved spatio-temporal model

HE Huaiqing*，SHI Xiaoshuang，LIU Haohan，HUI Kanghua

(College of Computer Science and Technology，Civil Aviation University of China，Tianjin 300300，China)

Abstract：4D trajectory prediction in this setting is extremely unpredictable and difficult due to the large amount of past trajectory data in the terminal area, its rich spatio-temporal properties, and the sudden changes in trajectory point placements. To address these challenges, we propose a solution based on an improved spatio-temporal model comprising three components. First, we introduce temporal convolutional networks (TCN) and bidirectional gated recurrent units (BiGRU) into the field of flight trajectory prediction, improving the TCN architecture. This leads to the development of a double-layer multi-scale temporal convolution network MMTCN that effectively extracts temporal features from both global and local perspectives. Second, we integrate layer normalization and residual connections into the graph attention network GAT to capture the intricate spatial dependencies among flights. Third, to mitigate data uncertainty stemming from abrupt changes in trajectory point locations, we input the extracted spatio-temporal characteristics into a conditional variational autoencoder (CVAE) to learn the latent representations of flight trajectory data, ultimately generating multiple predictive trajectories. Throughout the training process, a learning rate adjustment strategy is employed to enhance training efficiency. The experimental results demonstrate that the improved model achieves optimal performance on two metrics, with an average displacement error (ADE) of 0.082 6 and a final displacement error (FDE) of 0.111 1, significantly outperforming other baseline models. Additionally, the suggested model lowers the maximum error on the general aviation dataset by roughly 7.75% for FDE and 9.59% for ADE. This model not only effectively extracts spatio-temporal characteristics but also exhibits training stability.

Keywords：terminal area；trajectory prediction；improved spatio-temporal model；double-layer multi-scale temporal convolution；uncertainty

Received：2024-07-18；**Accepted**：2024-11-01；**Published Online**：2025-01-02 09：40

URL：link.cnki.net/urlid/11.2625.V.20241231.1432.001

Foundation item：National Key Research and Development Program of China (2020YFB1600101)

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