文章编号:1674-8190(XXXX)XX-001-08

基于改进Transformer方法的飞行轨迹预测研究

秦明奇,袁艺帠,孟啸月,杨洋
(昆明理工大学 信息工程与自动化学院,昆明 650500)

摘 要: 准确的飞行轨迹预测有助于基于航迹运行的航空交通管理,针对飞行轨迹预测问题的复杂性和当前预测精度较低的问题,提出一种使用空间注意力机制(SAM)的改进Transformer网络的预测方法,在编码器中采用空间注意力结构。对飞行轨迹数据进行时空特征联合建模,将编码器中的多头注意力替换为空间注意力,增强局部模式感知。结果表明:这种改进方法增强了对飞行轨迹的特征学习能力,飞行轨迹预测准确性得到提高,尤其在经度和纬度特征上表现优异,改进模型进一步提升了飞行轨迹预测的精度。

关键词: 飞行轨迹预测;空间注意力;Transformer;飞机;航空交通
中图分类号: V249 **文献标识码:** A
DOI: 10.16615/j.cnki.1674-8190.XXXX.XX.01

Research on flight trajectory prediction based on an improved Transformer approach

QIN Mingqi, YUAN Yige, MENG Xiaoyue, Yang Yang
(Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: Accurate flight trajectory prediction is crucial for trajectory-based operations (TBO) in air traffic management. To address the complexity of flight trajectory prediction and the low accuracy of existing methods, this study proposes an improved Transformer-based prediction method incorporating a Spatial Attention Mechanism (SAM). Specifically, the encoder employs a spatial attention structure to jointly model spatiotemporal features of flight trajectory data. By replacing the conventional multi-head attention mechanism in the encoder with SAM, the proposed approach enhances local pattern perception for trajectory dynamics. Experimental results demonstrate that this enhanced architecture significantly improves the feature learning capability for flight trajectories, leading to higher prediction accuracy. The method exhibits particularly superior performance in longitude and latitude feature predictions, indicating its potential to further advance the precision of flight trajectory forecasting.

Key words: flight trajectory prediction; spatial attention; Transformer; plane; air traffic

收稿日期: 2025-03-27; **修回日期:** 2025-05-28
基金项目: 云南省高校服务重点产业科技项目(FWCY-BSPY2024058); 云南省教育厅科研基金(2024Y129)
通信作者: 袁艺帠(1995—),女,博士研究生。E-mail: yigeyuan@stu.kust.edu.cn
引用格式: 秦明奇,袁艺帠,孟啸月,等. 基于改进Transformer方法的飞行轨迹预测研究[J]. 航空工程进展, XXXX, XX(XX): 1-8.
QIN Mingqi, YUAN Yige, MENG Xiaoyue, et al. Research on flight trajectory prediction based on an improved Transformer approach[J]. Advances in Aeronautical Science and Engineering, XXXX, XX(XX): 1-8. (in Chinese)

0 引 言

由于未来基于轨迹操作的强大支持能力，全球航空业正推广“基于轨迹的运行”（Trajectory Based Operation，TBO），以实现航空器4D轨迹（经度、纬度、高度、时间）的精准协同[1-2]。例如，中国民用航空局（Civil Aviation Administration of China，CAAC）在粤港澳大湾区试点TBO技术；单一欧洲天空空中交通管理研究（Single European Sky ATM Research，SESAR）以及美国下一代航空运输系统（NextGen）[3]。TBO的核心理念是通过优化飞行轨迹实现高效、安全和可持续发展的空中交通管理，飞行轨迹预测可以增强空中与地面的相互连接，实现安全有效的空中交通管制（Air Traffic Control，ATC）[4]。当前，飞行轨迹预测（Flight Trajectory Prediction，FTP）任务正在吸引全世界学术界和工业界越来越多的关注，它是现有空中交通管理的重要基础，也是未来空中交通运行的核心支撑。飞机四维（4D）轨迹的准确预测是提高TBO空中交通可预测性的基本技术，对完成下游任务具有重要意义，如预计到达时间[5-6]、冲突检测[7-8]、空中交通流量预测[9]。由于空域拥挤、天气、临时军事活动、空域限制等，飞机的实际飞行过程有时并不按照事先规划的路线飞行[7]。一些突发情况降低了空中交通的可预见性，增加了空中交通管理的难度，严重阻碍了空中交通管理系统的高效运行。2025年1月29日，一架从美国堪萨斯州起飞的商业客机在华盛顿哥伦比亚特区的罗纳德·里根国家机场附近与一架美军黑鹰直升机相撞，坠入波托马克河，事故造成67人死亡。因此提高飞机四维轨迹的准确预测对航空交通安全具有重要意义。FTP任务的主要目标是预测描述飞机离散轨迹点的运动属性，如经度、纬度、高度等。飞机的轨迹预测是空中交通管理中最重要的预测任务之一。

刘通等[10]在状态估计方面提出一种基于交互式多模型卡尔曼滤波（IMMKF）算法的广播式自动相关监视（Automatic Dependent Surveillance Broadcast，ADS-B）监视应用目标跟踪方法，提升了民航飞机目标跟踪性能；方伟等[11]提出了将残差神经网络与长短期记忆模型（LSTM）结合起来的飞行轨迹预测算法，通过残差神经网络来读取序列并自动学习内部特征，最后用LSTM来处理数据的时间序列信息，但其预测步长仅为6步；杨任农等[12]提出了基于双向长短期记忆模型（Bi-LSTM）的无人机轨迹预测模型，虽然该方法应用于无人机但也给飞机轨迹预测提供了思路；孔建国等[13]提出了一种基于时域融合的Transformer模型用于4D航迹预测，其引入了下降率、时序分量等多元特征，但该研究使用的数据集仅包含7天的轨迹数据，数据量较少，模型容易出现过拟合的现象；刘宏等[14]通过在Transformer模型中改进卷积模块，利用普通卷积捕捉相邻时序点的关联关系来提高飞行轨迹预测的精度；张建祥等[15]提出一种改进滑动窗多项式拟合航迹预测方法，可以自适应调整拟合多项式阶数与滑动窗长度给航迹预测模式提供了新思路；冯霞等[16]通过应用时间序列预测中的Informer模型[17]进行长时轨迹预测研究，在数据嵌入层中增加全局时间戳模块，并采用了自注意力机制提取航迹数据特征；卢婷婷等[18]利用注意力机制和教师监督中的指数衰减采样方法提出了基于注意力机制的序列到序列方法的终端区域预测航迹模型，实现了多步预测；钱来等[19]提出一种基于C-GRU方法的飞行轨迹预测方法，使用的是飞行仿真模拟数据，将其用于网络模型训练；Yoon等[20]将时间序列预测研究中所提出的iTransformer[21]应用于飞行轨迹预测中，该模型可以将每个序列都独立地嵌入到变量标记中，该研究也与PatchTST[22]等先进模型进行了对比。

以上方法在提高飞行轨迹预测精度方面提出了不同的思路，但还存在预测步长较短，使用数据集较少的问题；也没有考虑经度，纬度和高度特征之间的空间关系。因此，本文采用空间注意力机制来捕捉各个特征之间的空间关系，并采用了近一年的数据进行训练，以提高预测多步序列中各个特征的预测精度。

1 基础模型介绍

1.1 空间注意力机制（SAM）

空间注意力机制（Spatial Attention Mechanism，SAM）是一种在深度学习模型中动态分配不

同空间位置权重的方法,其核心思想是让模型自动聚焦于输入数据中对当前任务更重要的区域。空间注意力的结构图如图 1 所示。

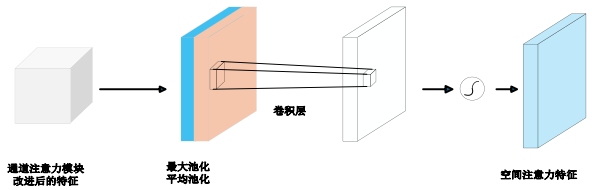

图 1　空间注意力机制

Fig. 1　Spatial attention mechanism

空间注意力机制的核心在于让模型自主学习“哪里重要”。首先进行特征图分析,对输入特征图的每个空间位置计算重要性分数;然后进行权重生成,将重要性分数归一化为概率分布,高权重区域表示模型需要重点关注的位置;最后进行特征增强,将注意力权重图与原特征图逐元素相乘,抑制无关区域并强化关键区域的特征响应。SAM 与通道注意力(如 SENet)关注“哪些通道重要”不同,空间注意力聚焦于特征图的空间维度($Width \times Height$),适用于需要定位关键区域的任务。

其数学原理如下:设输入特征图为 $X \in R^{C \times H \times W}$,空间注意力机制的输出为加权后的特征图 $Y \in R^{C \times H \times W}$:

$$Y = X \otimes S(X) \tag{1}$$

式中:$S(X) \in R^{1 \times H \times W}$ 为生成的空间注意力权重图,值域为[0,1];$\otimes$ 表示逐元素乘法,每个通道共享相同的空间权重。

生成 $S(X)$ 的典型方法:

1) 通道压缩:沿通道维度聚合信息,常用全局平均池化(GAP)或全局最大池化(GMP):

$$\begin{cases} F_{avg} = \frac{1}{C}\sum_{c=1}^{C} X_c \in R^{H \times W} \\ F_{max} = \max X_c \in R^{H \times W} \end{cases} \tag{2}$$

2) 特征拼接与卷积:将两种池化结果拼接后通过卷积层生成权重图:

$$S(X) = \sigma(Conv_{3\times 3}([F_{avg}; F_{max}])) \tag{3}$$

其中,$[F_{avg}; F_{max}]$ 表示沿通道维度的拼接,得到 $R^{2\times H\times W}$,$Conv_{3\times 3}$ 是 3×3 卷积核,输出通道为 1,σ 是 *Sigmoid* 函数,将值归一化。

空间注意力机制通过动态调整特征图的空间权重分布,使模型能够聚焦于关键区域,显著提升任务中对复杂结构的建模能力。

1.2　Transformer

Transformer 是一种完全基于自注意力机制(Self-Attention)的深度学习模型架构,由 Vaswani 等人在 2017 年的论文《Attention is All You Need》[23] 中首次提出。它通过并行化的注意力机制和位置编码技术,在自然语言处理、计算机视觉以及时间序列预测等任务中实现了突破性进展。

从结构组成来看,Transformer 采用编码器-解码器(Encoder-Decoder)双通路设计,二者均由多层模块堆叠而成,但功能分工明确。编码器的核心任务是将输入序列转化为富含上下文语义的隐藏表示,其每一层包含两个核心子模块:多头自注意力机制(Multi-Head Attention,MHA)与前馈神经网络。自注意力模块允许序列中的每个元素直接与其他元素交互,通过计算两两之间的关联权重动态聚合信息。

前馈神经网络则对注意力输出进行非线性变换,通过升维与降维操作增强特征表达能力。值得注意的是,每个子模块的输入与输出都会通过残差连接相加,再经过层归一化处理,这一设计有效缓解了深层网络训练中的梯度消失问题,使得堆叠数十层成为可能。

解码器的结构在编码器基础上增加了掩码自注意力和交叉注意力机制,以适应序列生成任务的需求。掩码自注意力通过遮蔽未来位置的信息,确保解码器在生成目标序列时仅依赖于已输出的部分,从而维持自回归生成的严格顺序。交叉注意力则充当编码器与解码器之间的桥梁,使解码器能够动态聚焦源序列中的关键内容。具体而言,解码器的查询(Query)向量来自目标序列的当前状态,而键(Key)向量和值(Value)向量源自编码器的输出,这种设计使得模型在生成每个目标词时,能够自适应地关联源语言中最相关的片段。整个架构通过多层堆叠逐步细化特征表示,最终在输出层通过线性变换与 *Softmax* 函数生成目标词的概率分布。

以上是空间注意力和原 Transformer 模型相关的介绍。

2 模型建立

2.1 飞行轨迹数据

飞行轨迹数据作为典型的时空序列数据，其每个记录点不仅包含经度、纬度、高度等空间坐标，还关联着时间戳、飞行器的身份等信息。本文采用的数据均为真实飞行数据，本文的数据来源于 https://flightadsb.variflight.com/，该网站保存了飞机每次执飞的原始飞行轨迹。本文采用的数据是中国四川航空的 3U8287 航班，是执飞中国昆明长水国际机场飞往中国郑州新郑国际机场的航班。航班 3U8287 的某次飞行路线如图 2 所示。

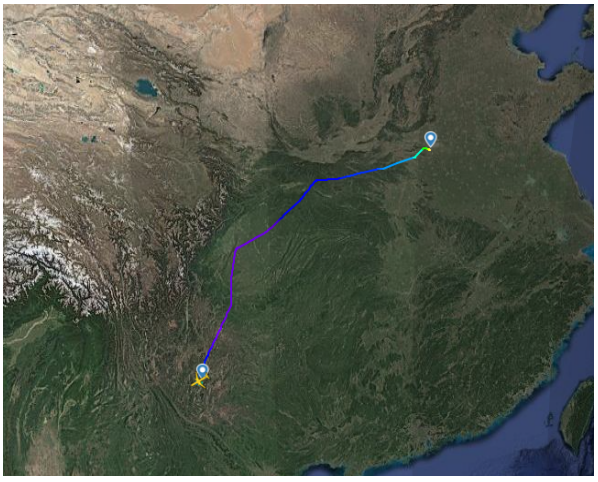

图 2 3U8287 航班飞行路线
Fig. 2 Flight route 3U8287

本文对该航班近一年的飞行轨迹进行了预处理，对轨迹预测无关的特征（如注册号等飞机的身份信息）进行删除只保留了时间戳、高度、速度、航向角、经度和纬度，构建了本文所用的数据集。

将数据集输入模型前需要划分训练集、验证集和测试集，本文将 70% 的数据划分为训练集，10% 的数据划分为验证集，20% 的数据划分为测试集。训练集用于训练神经网络模型中的权重，使模型从数据中学习规律；验证集在训练过程中评估模型性能，用于超参数的优化和监控模型泛化能力；测试集是模型从未见过的数据，反映实际应用中的表现，仅使用一次以评估模型的最终泛化性能。

2.2 改进的 Transformer 模型结构

基于飞行轨迹预测所面临的问题，本文结合空间注意力机制（SAM）的优势在标准 Transformer 编码器中引入了空间注意力机制，实现全局-局部特征联合优化。将原编码器中的多头注意力替换为空间注意力机制使其在特征维度计算跨通道注意力，建模多维轨迹参数（经度/纬度/高度）的空间耦合关系；为了便于描述，本文将改进的 Transformer 模型简称为 SAMformer，下文均以 SAMformer 进行表述。SAMformer 的模型结构如图 3 所示。

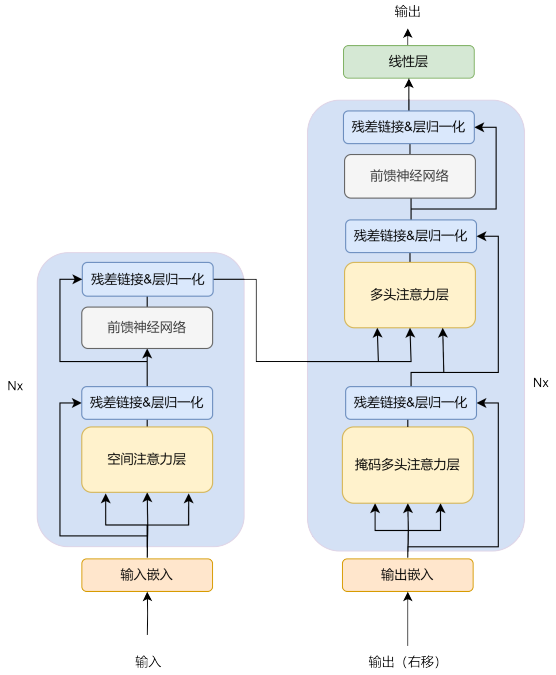

图 3 SAMformer 模型结构
Fig. 3 Architecture of the SAMformer model

SAMformer 模型基于 Transformer 架构，主要创新点在于在编码器中运用了空间注意力机制，通过多组件协同工作提升飞行轨迹预测的精度与效率。输入数据首先经过嵌入层处理，将原始飞行参数（如经度、纬度、高度）和时间戳信息（如小时、分钟）映射到高维特征空间，保留时空信息的连续性。编码器由多个堆叠层构成，每层包含两个核心部分：空间注意力模块在特征维度计算权重，分析不同飞行参数间的物理关联，例如自动识别高度变化与速度调整的动态关系；前馈网络则通过非线性变换增强特征表达能力。这种设计使得模型能够同时关注特征间的耦合关系与时间维度的演变规律。

Transformer 的 MHA 设计初衷是捕捉序列中的全局依赖关系。在轨迹预测中,MHA 通常是建模“时间步之间的关系”。而 SAM 重点关注的是输入数据中不同空间位置之间的关系;其原本用于图像、视频或其他空间结构数据。而在飞行轨迹中,空间信息包含了飞机在不同经纬度、不同空域、高度层的相互作用。其次,多头注意力是全连接的,对于轨迹预测来说,有些历史点在空间上其实没有太大影响,但 MHA 仍可能关注它。而空间注意力可以更有选择性地关注空间上相关的轨迹点,提高注意力效率。

飞行轨迹预测需处理复杂的时空数据,飞行轨迹中存在重要空间事件(如起飞、降落、转弯、避障),空间注意力能自动识别这些关键点,提升模型对局部突变的敏感度。传统循环神经网络(Recurrent Neural Network,RNN)和长短期记忆网络(Long Short Term Memory,LSTM)难以建模长距离空间依赖,而空间注意力可直接关联任意距离的位置,缓解长序列梯度消失问题。轨迹数据常含噪声或冗余点,空间注意力通过抑制低权重区域,提升模型鲁棒性。空间注意力机制还可以增强动态特征,如在飞机即将降落的轨迹段,空间注意力会赋予跑道附近坐标更高权重,帮助模型聚焦降落阶段的精细调整。

SAMformer 模型基于 Transformer 架构改进,核心创新是在编码器中融合了空间注意力机制。其编码器工作原理可分为以下阶段:

1) 输入嵌入:将原始飞行参数(经度、纬度、高度、速度、航向角)和时间戳编码映射到高维空间,保留时空关联性过程如下:

首先将原始特征 $X\in\mathbb{R}^{B\times L\times C}$(B:batch 大小,L:序列长度,C:特征数)通过线性变换映射到高维空间:

$$X_{emb}=X\cdot W_e+b_e\ (W_e\in\mathbb{R}^{C\times dmodel}) \tag{4}$$

同时,使用傅里叶基编码的时间戳特征 $T\in\mathbb{R}^{B\times L\times D_t}$:

$$T_{emb}=FourierEncoding(T)\cdot W_t+b_t \tag{5}$$

通过以上操作后将编码结果输入到空间注意力中,以下是融合输出的结果:

$$H^{(0)}=LayerNorm(X_{emb}+T_{emb})\ (H^{(0)}\in\mathbb{R}^{B\times L\times d_{model}}) \tag{6}$$

2) 编码处理:通过多层堆叠的编码器,交替使用空间注意力(建模特征关系)提取多尺度时空特征。空间注意力在特征维度(而非时间维度)计算权重,其核心在于建模不同飞行参数间的动态耦合关系。

空间注意力将输入拆分为 H 个头:

$$Q,K,V=H\cdot W_q,H\cdot W_k,H\cdot W_v\ (Q,K,V\in\mathbb{R}^{B\times L\times H\times d_h}) \tag{7}$$

其中,$d_h=d_{\text{model}}/H$。

然后进行特征维度注意力计算,先转置维度在特征空间计算相似度:

$$Q'=Q^{\top(2,3)},K'=K^{\top(2,3)},V'=V^{\top(2,3)}\ (\mathbb{R}^{B\times L\times d_h\times H}) \tag{8}$$

计算注意力分数矩阵:

$$Scores=\frac{Q'\cdot K'^{\top}}{\sqrt{d_h}}\ (\mathbb{R}^{B\times L\times d_h\times d_h}) \tag{9}$$

应用 Softmax 和 Dropout 进行权重归一化与聚合:

$$A=Dropout(Softmax(Scores,dim=-1)) \tag{10}$$

加权聚合 Values:

$$Output=(A\cdot V')^{\top(2,3)}\ (\mathbb{R}^{B\times L\times H\times d_h}) \tag{11}$$

最后输入编码器中得到预测结果。

3　实验结果

为了评估 SAMformer 在飞行轨迹预测任务中表现,本文对预测飞行轨迹未来 96 步的经度(Longitude)、纬度(Latitude)和高度(Height)特征分别进行了实验,以评估模型的预测性能,为证明改进模型的有效性,本文与 iTransformer、Crossformer、PatchTST、FEDformer 和 Informer 模型进行了对比。评价指标选取回归预测中常用的平均绝对误差(Mean Absolute Error, MAE)和均方误差(Mean Square Error,MSE),两者结果越小表明预测准确性越高。

具体实验结果如表 1~表 3 所示,表 1 是在经度特征上的预测结果,表 2 是各个模型在纬度特征

上的预测结果，表3是在高度特征上的预测结果。

表1 经度预测结果对比

Table 1 Comparison of longitude prediction results

Model	MSE	MAE
iTransformer	0.318 3	0.246 5
Crossformer	0.123 8	0.129 1
PatchTST	0.295 0	0.310 6
FEDformer	0.178 0	0.243 8
Informer	0.152 1	0.142 1
SAMformer	0.082 9	0.103 4

表2 纬度预测结果对比

Table 2 Comparison of latitude prediction results

Model	MSE	MAE
iTransformer	0.318 3	0.246 5
Crossformer	0.090 5	0.131 2
PatchTST	0.180 1	0.303 9
FEDformer	0.157 0	0.224 8
Informer	0.125 7	0.109 1
SAMformer	0.074 9	0.088 6

表3 高度预测结果对比

Table 3 Comparison of Height prediction results

Model	MSE	MAE
iTransformer	0.244 9	0.336 9
Crossformer	0.105 3	0.241 1
PatchTST	0.180 1	0.303 9
FEDformer	0.238 3	0.345 3
Informer	0.185 9	0.288 0
SAMformer	0.131 2	0.254 7

为了便于查看各个模型在特征上的指标，将其绘制为柱状图如图4所示；图四中纵坐标表示评价指标的计算值（越小越好），横坐标表示各个指标。

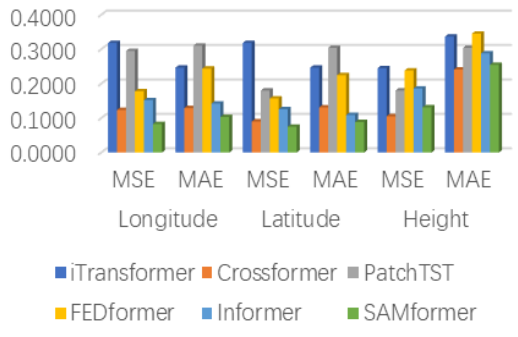

图4 不同模型的实验结果对比

Fig. 4 Experimental results between different models

从实验结果中看，本文提出的SAMformer在飞行轨迹预测中展现了显著的竞争力，在96步预测任务中，SAMformer在经度和纬度预测上的MSE和MAE均明显优于其他模型。

例如，SAMformer在经度特征上进行预测的MSE指标比次优模型Crossformer（0.123 8）降低了33.2%，在纬度特征上预测的MAE指标较Crossformer（0.131 2）降低了32.5%，即本文模型在经纬度特征上的预测准确性表现较好。在高度这一特征的预测任务中，SAMformer在评价指标MSE（0.131 4）上略高于Crossformer（0.105 3），出现这样的情况可能因为经纬度处在一直较规律变化过程，而高度这一特征因数据采集间隔原因出现高度变化速率高于实际的情况，进而导致模型难以学习到完整细节，所以导致高度预测计算结果较高；但在MAE指标上本模型较优模型（0.254 7 vs 0.241 1）两个结果相差无几，说明模型在高度预测中虽略弱于Crossformer，但因在经度和纬度上的优势本文所提出的模型整体预测效果更准确。

为体现本文模型的实际预测效果，经纬度和高度预测曲线和真实曲线的对比结果图如图5～图7所示；横坐标表示步长，纵坐标为归一化后的数值。

图5展示了预测经度96步长的预测效果，虽有些许波动，但整体拟合了未来96步的真实数据。

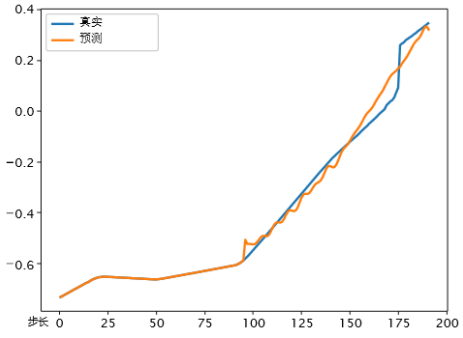

图5 预测经度结果对比图

Fig. 5 Comparison of predicted longitude results

图6展示了本文所提出的改进模型在预测纬度时的效果，表明了模型几乎拟合了未来96步的真实数据，表明预测结果较好。

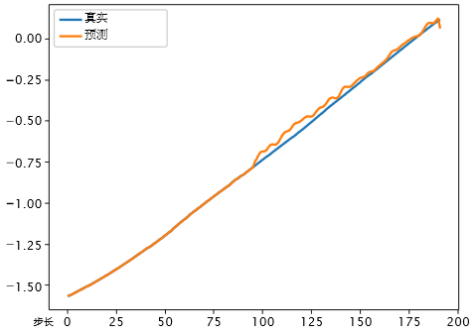

图 6　预测纬度结果对比图

Fig. 6　Comparison of predicted latitude results

图 7 表示的是模型在预测高度这一特征所表现的效果,整体上模型学习了飞行轨迹未来的趋势。

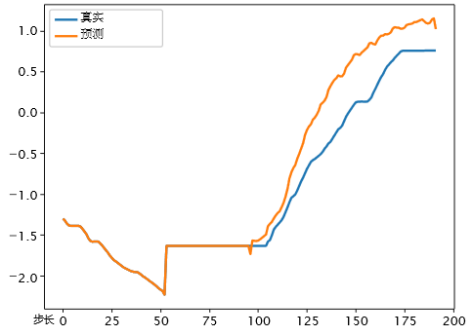

图 7　预测高度结果对比图

Fig. 7　Comparison of predicted Height results

图中横坐标为时间步长,纵坐标为标准化后的数值,图中真实值用蓝色线表示,预测值用橙色线条表示,本文使用滑动窗口的形式进行预测,利用前 96 步的真实数据预测未来 96 步的数据,因此前 96 步的数据被橙色线所覆盖,后 96 步可以看到预测值与真实值之间的差距。

从图 5～图 7 所示预测结果来看,其预测效果基本与实验结果表中的数据相符。这表明了本文所提出的改进方法在提高飞行轨迹预测精度方面有一定的作用。

不同方法预测全程轨迹的效果图如图 8 所示,Ture 代表真实飞行轨迹,A 代表 PatchTST 方法,B 代表 Crossformer,C 代表 Informer 方法,D 代表 iTransformer 方法,E 代表 FEDformer 方法,F 代表本文 SAMformer 方法,可以看出本文方法比较接进真实轨迹,证明本文模型的预测准确性较其它模型较好。

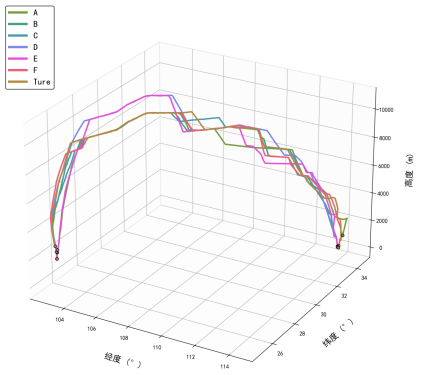

图 8　3D 飞行轨迹预测结果对比图

Fig. 8　Comparison of 3D flight path prediction results

4　结　论

1）空间注意力机制有效提升时空特征建模能力,通过引入空间注意力机制(SAM),改进后的 Transformer 模型实现了对飞行轨迹数据中经度、纬度、高度等特征间空间耦合关系的动态建模,提升了预测稳定性和准确性,在评价指标 MSE 和 MAE 上较次优模型 Crossformer 分别降低 33.2% 和 32.5%。

2）全局—局部特征协同优化效果显著,编码器的改进设计实现了全局依赖与局部模式感知的协同优化,使模型总体性能与对比模型表现更优。

参 考 文 献

[1] JIA P Y, CHEN H P, ZHANG L, et al. Attention-LSTM based prediction model for aircraft 4-D trajectory[J]. Scientific Reports, 2022, 12: 15533.

[2] GUO D Y, LIN Y, YOU X H, et al. M2ATS: A real-world multimodal air traffic situation benchmark dataset and beyond[C]// Proceedings of the 31st ACM International Conference on Multimedia. Ottawa ON Canada: ACM, 2023: 213-221.

[3] BROOKER P. SESAR and NextGen: investing in new paradigms[J]. Journal of Navigation, 2008, 61(2): 195-208.

[4] CHEN Z M, GUO D Y, LIN Y. A deep Gaussian process-based flight trajectory prediction approach and its application on conflict detection[J]. Algorithms, 2020, 13(11): 293.

[5] STROHMEIER M, SCHÄFER M, LENDERS V, et al. Realities and challenges of nextgen air traffic management: the case of ADS-B[J]. IEEE Communications Magazine, 2014, 52(5): 111-118.

[6] ZHANG Z, GUO D Y, ZHOU S Z, et al. Flight trajectory prediction enabled by time-frequency wavelet transform[J]. Nature Communications, 2023, 14: 5258.

[7] 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.

[8] YANG Z J, KANG X L, GONG Y H, et al. Aircraft trajectory prediction and aviation safety in ADS-B failure conditions based on neural network[J]. Scientific Reports, 2023, 13: 19677.

[9] ZHANG M Y, CHEN S W, SUN L J, et al. Characterizing flight delay profiles with a tensor factorization framework [J]. Engineering, 2021, 7(4): 465-472.

[10] 刘通, 王飞, 严忠平. 基于IMMKF算法的ADS-B监视应用目标跟踪[J]. 航空工程进展, 2024, 15(1): 182-190.
LIU Tong, WANG Fei, YAN Zhongping. ADS-B surveillance application target tracking based on IMMKF algorithm [J]. Advances in Aeronautical Science and Engineering, 2024, 15(1): 182-190. (in Chinese)

[11] 方伟, 汤淼, 闫文君, 等. 基于残差神经网络和LSTM的飞行轨迹预测[J]. 舰船电子工程, 2023, 43(10): 42-46.
FANG Wei, TANG Miao, YAN Wenjun, et al. Flight trajectory prediction based on residual neural network and LSTM[J]. Ship Electronic Engineering, 2023, 43(10): 42-46. (in Chinese)

[12] 杨任农, 岳龙飞, 宋敏, 等. 基于Bi-LSTM的无人机轨迹预测模型及仿真[J]. 航空工程进展, 2020, 11(1): 77-84.
YANG Rennong, YUE Longfei, SONG Min, et al. UVA trajectory prediction model and simulation based on Bi-LSTM[J]. Advances in Aeronautical Science and Engineering, 2020, 11(1): 77-84. (in Chinese)

[13] 孔建国, 马珂昕, 梁海军, 等. 一种基于时域融合Transformer的4D航迹预测方法[J]. 电讯技术, 2024, 1-12.
KONG Jianguo, MA Kexin, LIANG Haijun, et al. A 4D trajectory prediction method based on temporal fusion transformer[J]. Telecommunications Technology, 2024, 1-12. (in Chinese)

[14] 刘宏, 张鑫迪, 卢飞, 等. 基于改进Transformer模型的四维航迹预测[J]. 中国安全科学学报, 2024, 34(12): 74-83.
LIU Hong, ZHANG Xindi, LU Fei, et al. Research on 4D flight trajectory prediction based on improved Transformer model[J]. China Safety Science Journal, 2024, 34(12): 74-83. (in Chinese)

[15] 张建祥, 甘旭升, 周志靖, 等. 基于改进滑动窗多项式拟合法的航空器4D航迹预测[J]. 航空工程进展, 2019, 10(5): 601-608.
ZHANG Jianxiang, GAN Xusheng, ZHOU Zhijing, et al. 4D track prediction of aircraft based on improved sliding window polynomial fitting method[J]. Advances in Aeronautical Science and Engineering, 2019, 10(5): 601-608. (in Chinese)

[16] 冯霞, 孙琦琦, 左海超. 基于Informer的客机长时4D航迹预测方法[J]. 交通信息与安全, 2023, 41(4): 111-121.
FENG Xia, SUN Qiqi, ZUO Haichao. A method for predicting long-term 4D trajectory of airplanes based on informer[J]. Journal of Transport Information and Safety, 2023, 41(4): 111-121. (in Chinese)

[17] ZHOU H Y, ZHANG S H, PENG J Q, et al. Informer: Beyond efficient transformer for long sequence time-series forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(12): 11106-11115.

[18] 卢婷婷, 刘博, 李纯柱. 基于注意力Seq2Seq模型的终端区航空器航迹预测[J]. 科学技术与工程, 2024, 24(9): 3882-3895.
LU Tingting, LIU Bo, LI Chunzhu. Aircraft trajectory prediction within terminal area based on Seq2Seq-attention model[J]. Science Technology and Engineering, 2024, 24(9): 3882-3895. (in Chinese)

[19] 钱来, 王伟. 一种基于C-GRU飞行轨迹预测方法[J]. 电子测量技术, 2022, 45(10): 87-92.
QIAN Lai, WANG Wei. A C-GRU based flight trajectory prediction method [J]. Electronic Measurement Technology, 2022, 45(10): 87-92. (in Chinese)

[20] YOON S, LEE K. Aircraft trajectory prediction with inverted transformer[J]. IEEE Access, 2025, 13: 26318-26330.

[21] LIU Y, HU T, ZHANG H, et al. Itransformer: inverted transformers are effective for time series forecasting [J]. arXiv preprint arXiv:2310.06625, 2023.

[22] NIE Y, NGUYEN N H, SINTHONG P, KALAGNANAM J. A time series is worth 64 words: Long-term forecasting with transformers [J]. arXiv preprint arXiv: 2211.14730, 2022.

[23] VASWANI A. Attention is all you need [C]// 31st Conference on Neural Information Processing Systems. USA: NeurIPS Proceedings , 2017: 30.

(编辑:马文静)