http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0679

基于时空特征提取的GTA-Seq2Seq多步4D航迹预测模型

石庆研，赵婉彤，韩萍*

(中国民航大学 智能信号与图像处理天津市重点实验室，天津 300300)

摘 要：高精度多步航迹预测有助于实时调整飞行路径，避免潜在冲突，提高飞行安全。传统模型通常面临多步预测精度低、难以捕获飞行轨迹中时空特征之间非线性关系的问题。为此，提出一种在序列到序列(Seq2Seq)模型中使用门控循环单元(GRU)、时间卷积网络(TCN)和时序模式注意力(TPA)机制的多步4D航迹预测模型GTA-Seq2Seq。该模型分为编码器和解码器部分，编码器使用GRU提取航迹数据中时间依赖性，并结合TCN-GRU网络提取航迹数据的空间特征，通过TPA分配各隐藏特征的权重。在解码器部分，时空特征经过拼接后输入GRU中，实现高精度的多步航迹预测。实验表明：所提模型在预测精度上优于传统模型，该模型中第5步预测相较于对比模型中最优模型——基于时空特征融合的编码器-解码器(STED)模型，均方根误差(RMSE)减小了27.70%，平均绝对误差(MAE)减小了23.82%。此外，GTA-Seq2Seq模型在训练过程中所需的参数量相较于STED模型减少了67.42%，提高了模型的运算效率。

关 键 词：航迹预测；时空特征；时间卷积网络；注意力机制；编码解码；序列到序列模型
中图分类号：V355; TP391.9
文献标志码：A **文章编号**：1001-5965(2026)11-3894-13

近年来，航空运输业的快速发展使空中交通量不断增长，航班延误、空域紧张等现象时有发生[1]。为应对不断增加的空中交通量给空中交通管制(air traffic control, ATC)系统带来的挑战，国际民航组织(International Civil Aviation Organization, ICAO)将基于航迹运行(trajectory based operation, TBO)加入航空系统中[2]。TBO是以航空器全飞行周期的四维航迹为基础，在空管、机场、航空公司、航空器等相关方之间实时共享和动态维护航迹信息，进而实现多方协同决策[3-4]。2020年3月，中国民用航空局空中交通管理局制定了《中国民航空管现代化战略(CAAMS)实施路线图》[5]，将TBO和4D航迹预测列为未来空管现代化的核心目标，高精度的航迹预测对于提升空管系统的安全性和效率至关重要[6]。相比于单步预测，多步预测可以预测未来一段时间航班的飞行位置，有助于实时调整飞行路径，为避免潜在冲突提供关键信息，提高飞行安全。然而，现阶段多步航迹预测研究面临严峻挑战，其紧迫性日益凸显。目前，多步预测面临预测误差累积、时空特征捕捉能力不足及计算效率低等问题。因此，提高多步预测的精度和效率，已成为当前航空领域需解决的关键问题。

目前，有关短期航迹预测的方法大致可以分为基于质点运动、基于状态估计和基于机器学习3类。基于质点运动的航迹预测[7]是将空中飞行器看作一个粒子，对其进行受力分析，将运动学模型及飞机参数结合起来建立预测模型。该方法存在所需飞机自身及运动学相关参数过多的问题。基

收稿日期：2024-09-18；**录用日期**：2024-11-22；**网络出版时间**：2024-12-20 13:04
网络出版地址：link.cnki.net/urlid/11.2625.V.20241219.1708.001
基金项目：民航局安全能力建设资金(KJZ49420210082)
* **通信作者**. E-mail：hanpingcauc@163.com

引用格式：石庆研，赵婉彤，韩萍. 基于时空特征提取的GTA-Seq2Seq多步4D航迹预测模型[J]. 北京航空航天大学学报，2026，52(11)：3894-3906. Shi Q Y，Zhao W T，Han P. GTA-Seq2Seq multi-step 4D trajectory prediction model based on spatio-temporal feature extraction[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：3894-3906 (in Chinese).

于状态估计的航迹预测[8]将飞机的运动过程看作状态转移过程, 通过运动方程构建状态转移矩阵, 研究未来时间点的位置与历史时间点中位置、速度、加速度等状态之间的关系。然而, 这种方法所构建的模型在处理航迹数据时存在明显局限, 难以应对其中复杂的非线性关系和外部干扰等问题, 且计算复杂度较高。

基于机器学习的算法逐渐应用于航迹预测。机器学习在大量航迹数据中挖掘隐藏信息, 建立神经网络, 提取航迹信息之间的非线性关系, 这对于提高航迹预测精度至关重要。短期航迹预测根据预测范围分为单步预测和多步预测。目前, 用于航迹预测的经典神经网络有反向传播 (back propagation, BP) 神经网络[9]、长短期记忆 (long short-term memory, LSTM) 网络[10-12]、门控循环单元 (gate recurrent unit, GRU)[13-14] 等循环神经网络 (recurrent neural network, RNN) 的变体。然而, RNN 及其变体依赖于递归机制来处理时间序列, 即通过前一个时间步的隐藏状态传递信息, 导致计算效率较低, 难以并行处理。近年来, 卷积神经网络 (convolutional neural network, CNN)[15] 和时间卷积网络 (temporal convolutional networks, TCN)[16] 逐渐应用在航迹预测中。在多步航迹预测中, 焦卫东等[17] 采用多尺度卷积 (multi-scale convolution, MSC) 网络和时空双重注意力 (spatio-temporal dual attention, STDA) 机制相结合的 TCN 来提高多步预测的连续性和准确性。随着深度学习的发展, 能够捕捉航迹序列长时间依赖关系的编码器-解码器结构应用到多步航迹预测中。卢婷婷等[18] 提出一种基于序列到序列 (sequence-to-sequence, Seq2Seq) 框架的机场终端区航迹预测模型, 结合注意力机制和教师强制中的指数衰减采样方法预测航迹序列, 以提高预测的准确性和模型的训练效率。Tran 等[19] 通过编码器-解码器结构建模和整合飞机的战术意图来进行多步航迹预测。Zeng 等[20] 同样采用编码器-解码器架构, 专注于挖掘航迹之间的长时间依赖关系, 以预测终端区的未来飞行轨迹。Zhang 等[21] 除使用编码器-解码器架构外, 还引入了时间频率小波变换, 以提高模型获取飞行数据中时间-频率特征的能力。石庆研等[22] 提出一种新型的基于时空特征融合的编码器-解码器 (spatio-temporal encoder-decoder, STED)模型, 通过集成 GRU、CNN 和注意力机制来精确提取航迹数据的时空特征。单步预测通常关注于根据输入信息预测下一时刻的状态, 而多步预测更适合捕捉未来轨迹的变化趋势, 尽管误差累积和模型复杂度较高, 但能够提供更完整的轨迹信息。上述多步预测的方法都有一定有效性, 在一定程度上改进了传统迭代多步预测中误差累积的问题, 但仍存在时空特征提取不完全, 以及多步预测误差随着预测步数增加而出现不稳定变化的问题。

鉴于此, 本文以编码器-解码器架构为基础, 提出一种在 Seq2Seq 模型中使用 GRU、TCN 和时序模式注意力 (temporal pattern attention, TPA) 机制的多步 4D 航迹预测模型 GTA-Seq2Seq。模型中编码器部分采用 GRU 提取航迹数据中的时间依赖性, 为提取航迹中多维度空间特征, 使用 TCN 和 GRU 结合的网络输出高级隐藏信息, 并对高级隐藏特征通过 TPA 使用评分函数分配各隐藏特征的权重, 不同隐藏特征的权值大小对未来预测航迹的精度有不同影响。在解码器中, 将编码器提取到的时空特征输入 GRU, 实现高精度的多步航迹预测。本文利用真实数据集进行实验, 并与其他模型进行比较, 以验证本文模型的有效性。

1　GTA-Seq2Seq 多步航迹预测模型

1.1　问题定义

本文关注短期多步航迹预测任务, 即根据给定的历史输入序列, 预测接下来几个时间步的飞机位置。在处理航迹数据时, 通常设置长度为 p 和 s 的滑动窗口分别构造输入数据和标签数据。从第 1 个航迹点开始, 选取 p 个航迹点作为模型的输入数据, 再选取后面要预测的 s 个真实航迹点作为标签数据, 生成第 1 个样本。每次滑动可以提取出一组新的数据样本, 输入数据 $\boldsymbol{X}$ 和标签数据 $\boldsymbol{Y}$ 分别为

$$\boldsymbol{X}=[\boldsymbol{X}_1,\boldsymbol{X}_2,\cdots,\boldsymbol{X}_N] \tag{1}$$

$$\boldsymbol{Y}=[\boldsymbol{Y}_1,\boldsymbol{Y}_2,\cdots,\boldsymbol{Y}_N] \tag{2}$$

$$\boldsymbol{X}_t=\left[\boldsymbol{x}_t,\boldsymbol{x}_{t+1},\cdots,\boldsymbol{x}_{t+p-1}\right] \tag{3}$$

$$\boldsymbol{Y}_t=\left[\boldsymbol{y}_{t+p},\boldsymbol{y}_{t+p+1},\cdots,\boldsymbol{y}_{t+p+s-1}\right] \tag{4}$$

式中: N 为通过滑动窗口滑窗得到的样本数量; $\boldsymbol{X}_t$ 和 $\boldsymbol{Y}_t$ 分别为第 t 个样本的输入和标签数据 ($t=1,2,\cdots,N$); 每个输入航迹点 $\boldsymbol{x}_t$ 又包含多维特征。

模型输入的是长度为 p 的历史航迹数据 $\boldsymbol{X}_t=\left[\boldsymbol{x}_t,\boldsymbol{x}_{t+1},\cdots,\boldsymbol{x}_{t+p-1}\right]$, 模型的目标是可以输出未来 s 个时间步的航迹信息 $\hat{\boldsymbol{Y}}_t=\left[\hat{\boldsymbol{y}}_{t+p}^{(t)},\hat{\boldsymbol{y}}_{t+p+1}^{(t)},\cdots,\hat{\boldsymbol{y}}_{t+p+s-1}^{(t)}\right]$, 其中, $\hat{\boldsymbol{y}}_{t+p}^{(t)}$ 为使用前 p 个历史数据作为输入样本, 预测第 p+1 个时间步得到的航迹数据。上标 "(t)" 表示预测模型的输入是第 t 个样本数据 $\boldsymbol{x}_t$。

1.2　模型框架构建

航迹预测是具有时空特征的多维时间序列预

测任务。每个特征都有长短期的时间变化模式，航迹点随时间变化能够呈现出飞机整体的运动变化规律。通过学习这些规律，模型能更准确地预测飞机未来的轨迹。同时，每个特征之间也存在着相互依赖的空间信息，例如，在巡航阶段，输入数据中的纬度变化对高度变化影响不大，因此，获取不同特征之间的空间信息有助于捕捉飞机在不同飞行状态下的移动规律，从而使预测模型能更准确地预测飞机未来的轨迹。轨迹数据中的空间位置信息与时间变化趋势相关，表明了空间与时间维度的紧密联系，因此，本文提出一种能充分提取航迹数据之间时空特征并实现高精度航迹预测的方法。本文航迹预测模型如图 1 所示，该模型包含提取空间特征和提取时间特征 2 个模块组成的编码器部分及由 GRU 神经网络和全连接层 (fully connected layer, FC) 构成的解码器部分。

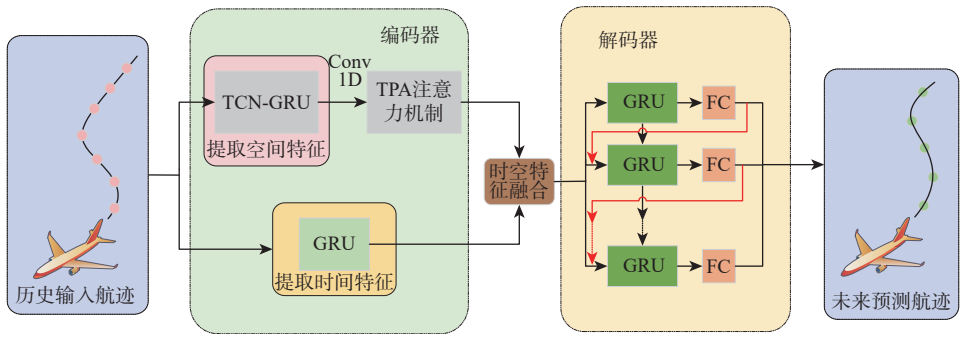

图 1 GTA-Seq2Seq 航迹预测模型总体结构

Fig. 1 GTA-Seq2Seq overall structure of trajectory prediction model

模型输入是长度为 p 的航迹点，包含经度、纬度、高度和时间。模型结构包含 4 个部分：①时间特征提取模块，将 $\boldsymbol{X}$ 输入 GRU 中提取每个航迹点之间的时间依赖性；②空间特征提取模块，由于 TCN 能有效挖掘航迹数据之间的变量关系，因此，选定 TCN 作为提取历史空间信息的主要神经网络之一，将历史航迹数据 $\boldsymbol{X}$ 输入 TCN-GRU 模型中，以便建模并提取空间隐藏信息；③在提取出空间隐藏信息后，搭建 TPA 注意力机制以确定哪些过去的隐藏信息对当前预测影响更大；④编码器中提取时间特征模块和空间特征模块的输出进行拼接融合，生成编码器输出的语义向量，解码器使用 GRU 网络递归输出未来 s 步的航迹点。GTA-Seq2Seq 模型结构如图 2 所示。

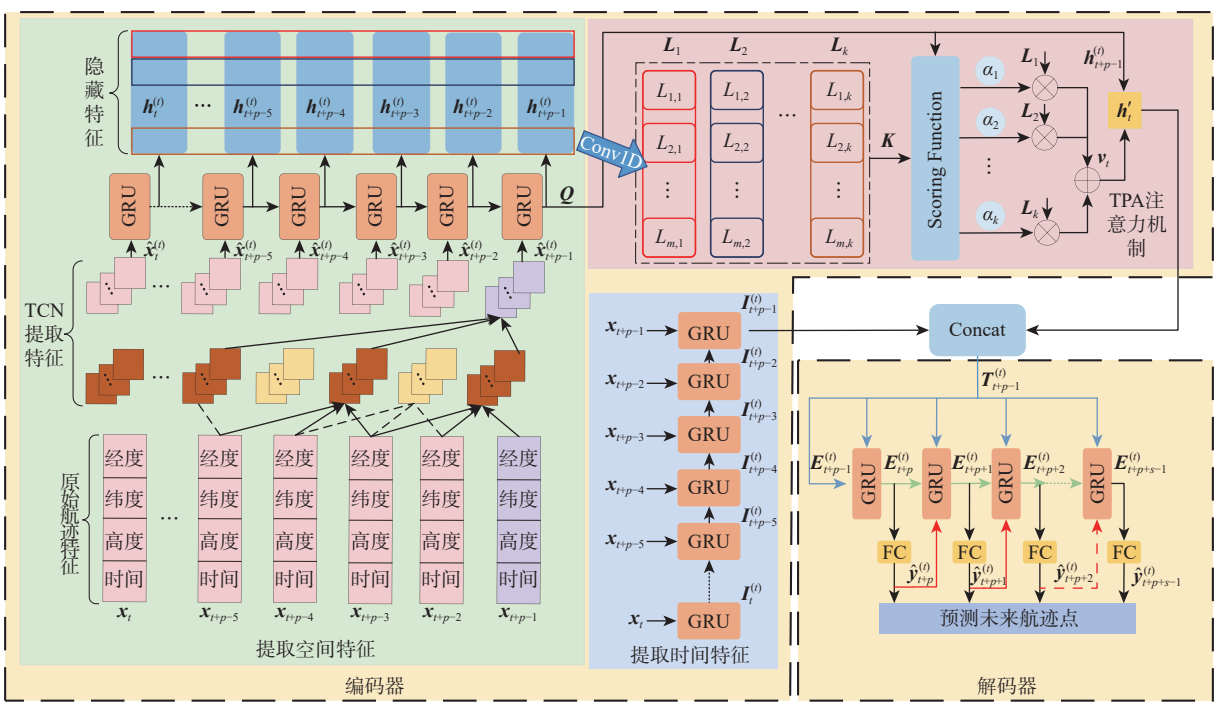

图 2 GTA-Seq2Seq 航迹预测模型结构

Fig. 2 Structure of GTA-Seq2Seq trajectory prediction model

1.3　GTA-Seq2Seq 模型编码器

1.3.1　提取时间特征

编码器中提取时间特征部分是用 GRU 提取航迹序列中的时间依赖性。航迹序列中包含了在不同时间收集到的数据, 这些数据呈现飞机随时间变化的规律。RNN 是早期用于处理时间序列数据的网络, 但由于其结构问题, 训练慢, 容易出现梯度消失或爆炸。LSTM[23] 是改进的 RNN 模型, 通过引入输入门、输出门和遗忘门来解决梯度消失问题, 但其参数多且训练效率低。GRU[24] 是更简单的 RNN 变种, 其通过更新门和重置门来处理时间序列中时间间隔较大的依赖关系, 且具有更少的参数和更快的训练速度。更新门控制着上一步隐藏状态信息在当前隐藏状态中的保留程度, 重置门控制着上一步隐藏状态信息在当前隐藏状态中的遗忘程度。GRU 的具体结构如图 3 所示, 相关计算式如下:

$$\boldsymbol{z}_t=\sigma(\boldsymbol{W}_z\cdot[\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_z) \tag{5}$$

$$\boldsymbol{r}_t=\sigma(\boldsymbol{W}_r\cdot[\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_r) \tag{6}$$

$$\hat{\boldsymbol{h}}_t=\tanh(\boldsymbol{W}_h\cdot[\boldsymbol{r}_t*\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_h) \tag{7}$$

$$\boldsymbol{h}_t=(1-\boldsymbol{z}_t)*\boldsymbol{h}_{t-1}+\boldsymbol{z}_t*\hat{\boldsymbol{h}}_t \tag{8}$$

式中: $\boldsymbol{z}_t$为更新门; $\boldsymbol{r}_t$为重置门; “[]”表示 2 个向量连接; “·”表示 2 个矩阵相乘; “ * ”表示 2 个矩阵中的对应元素相乘; σ和 tanh 分别为 sigmoid 和 tanh 激活函数; $\boldsymbol{W}$ 和 $\boldsymbol{b}$ 分别为可训练的权重矩阵和偏置项; $\boldsymbol{h}_t$和$\boldsymbol{h}_{t-1}$分别为当前时间步和上一时间步隐藏状态向量; $\hat{\boldsymbol{h}}_t$为候选隐藏状态向量。

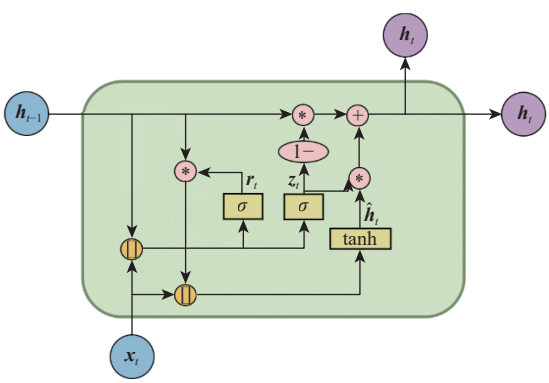

图 3　GRU 单元结构

Fig. 3　GRU unit structure

如图 2 中提取时间特征时, 每个时间步的经度、纬度、高度、时间数据同时输入到 GRU 中, 且每个 GRU 单元都会根据当前输入和上一隐藏状态来计算新的隐藏状态。新状态包含到当前时间步为止的历史信息, 并可以用作下一个时间步的输入状态或最终输出。GRU 通过逐步学习各个时间步的时序模式, 输出最后一个时间步的隐藏状态信息 $\boldsymbol{I}_{t+p-1}^{(t)}$, 可表示为

$$\boldsymbol{I}_{t+p-1}^{(t)}=\mathrm{GRU}\left(\boldsymbol{I}_{t+p-2}^{(t)},\boldsymbol{X}_{t+p-1}\right) \tag{9}$$

式中: $\boldsymbol{I}_{t+p-2}^{(t)}$为在 t+p−2 时间步 GRU 输出的包含前面所有时间步的隐藏向量; $\boldsymbol{X}_{t+p-1}$为第 t+p−1 个航迹点。

1.3.2　提取空间特征

TCN 是由 Bai 等在 2018 年提出的, 是一种基于 CNN 的模型, 专门用于处理时序数据, TCN 结构如图 4 所示。其主要由堆叠的残差模块构成, 如图 4(a) 所示。为避免梯度消失问题, TCN 中的残差模块包括扩张因果卷积、空间 Dropout 和权值归一化, 残差块的输出还通过 1×1 卷积增强, 保持输入和输出维度的一致性, 如图 4(b) 所示。扩张因果卷积输出只依赖于当前和之前的数据, 适合预测任务, 另外, 还能通过扩张因子提高模型的记忆能力, 并获取长期依赖信息, 如图 4(c) 所示。扩张卷积的计算式为

$$F_d(t)=\sum_{i=0}^{k-1}f_i*\boldsymbol{x}_{t-d\cdot i} \tag{10}$$

式中: $\boldsymbol{F}_d(t)$为扩张因子为 d 时, t 时刻的扩张因果卷积的输出结果; $\boldsymbol{x}_{t-d\cdot i}$为当前和过去的输入数据; $t-d\cdot i$表示以扩张的方式选取输入序列中的元素进行卷积运算; k 为卷积核大小; f_i为滤波器在 i 位置上的权重。

TCN-GRU 模型对输入长度为 p 的历史航迹信息进行空间隐藏特征的提取, TCN 通过两层堆叠, 每层具有不同数量的卷积核, 以增强模型提取空间特征能力, 且采用了多个不同扩张率的卷积核来进行卷积。GRU 则用于进一步提取隐藏特征矩阵中更复杂的时序关系。每个 GRU 输出当前时间步的隐藏状态向量, 所有 GRU 输出的向量构成隐藏特征矩阵 $\boldsymbol{H}^{(t)}=\left[\boldsymbol{h}_t^{(t)},\boldsymbol{h}_{t+1}^{(t)},\cdots,\boldsymbol{h}_{t+p-1}^{(t)}\right]\in\mathbf{R}^{m\times p}$, m 为隐藏特征个数。矩阵的每行是相同的隐藏特征在各个时间步的信息表达, 每列为 GRU 输出的当前时间步所有隐藏特征组成的向量。

1.3.3　TPA 注意力机制

引入注意力机制能对 TCN-GRU 所提取到的隐藏特征进行动态权重分配, 从而将注意力集中到重要的隐藏特征, 忽略次要特征, 以提高预测精度。

TPA 注意力机制通过一阶 CNN 提取隐藏特征矩阵 $\boldsymbol{H}^{(t)}$中每个特征的高阶隐藏信息。卷积核 $\boldsymbol{C}_u\in\mathbf{R}^{1\times p}$沿着隐藏特征矩阵 $\boldsymbol{H}^{(t)}$的列向量进行遍历, 可以融合每个特征在不同时间步的高级信息。由于 CNN 可以从特征向量中提取许多不同的模式, 因此, 不同的卷积核在提取特征时从多个角度获取到单个隐藏特征的变化趋势。最终生成高级

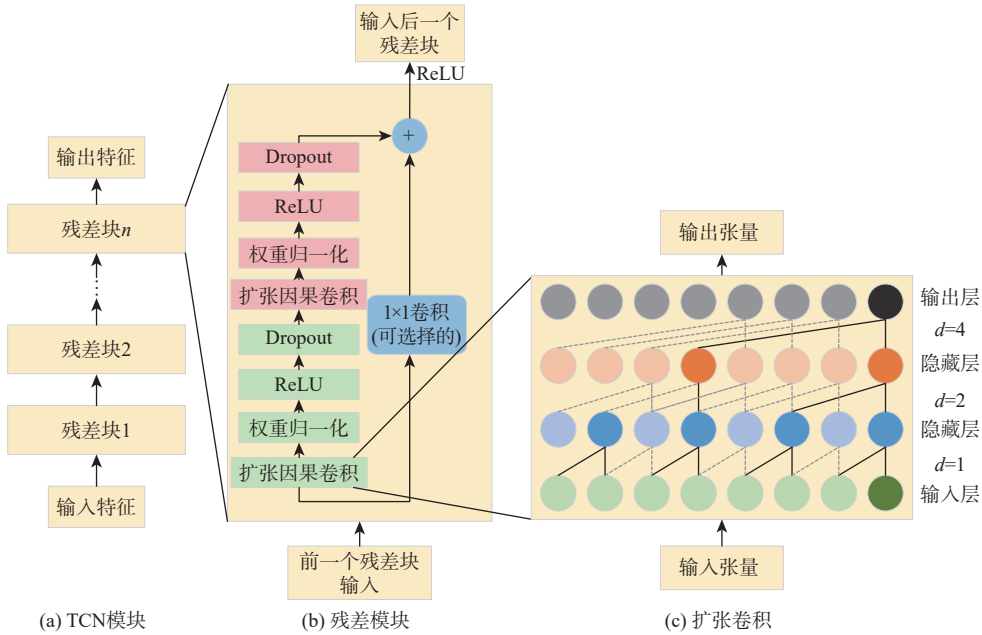

图 4 TCN 及其内部结构

Fig. 4 TCN and its internal structure

特征矩阵$\boldsymbol{L}\in\mathbf{R}^{m\times k}$。卷积过程可表示为

$$\boldsymbol{L}_{a,u}=\boldsymbol{H}_a^{(t)}\boldsymbol{C}_u^{\mathrm{T}} \tag{11}$$

式中：$a=1,2,\cdots,m,u=1,2,\cdots,k$；$\boldsymbol{H}_a$为隐藏特征矩阵中第 a 行的行向量。

提取空间特征中，最后一个 GRU 生成的隐藏状态向量$\boldsymbol{h}_{t+p-1}^{(t)}$不仅作为所有时间步的隐藏状态特征，而且作为注意力机制中的查询序列 $\boldsymbol{Q}$，以确定在当前时间步长下哪个隐藏特征影响更大。通过 CNN 得到的高级特征矩阵 $\boldsymbol{L}$ 被用作 TPA 注意力机制中的键向量 $\boldsymbol{K}$，以映射每个隐藏特征在特定时间步长的重要性。借助权重矩阵$\boldsymbol{W}_{\mathrm{sf}}\in\mathbf{R}^{k\times m}$，根据式 (12) 通过打分函数 Scoring Function 进行打分，使用式 (13) 中的 softmax 函数对各注意力权重系数做归一化处理，得到在特定时间步下隐藏特征注意力权重$\boldsymbol{\alpha}=[\alpha_1,\alpha_2,\cdots,\alpha_k]$。

$$e_u=\boldsymbol{L}_u^{\mathrm{T}}\boldsymbol{W}_{\mathrm{sf}}\boldsymbol{h}_{t+p-1}^{(t)} \tag{12}$$

$$\alpha_u=\mathrm{Softmax}(e_u)=\exp(e_u)\Big/\sum_{q=1}^{k}\exp(e_q) \tag{13}$$

式中：$\boldsymbol{L}_u$为生成的高级特征矩阵 $\boldsymbol{L}$ 第 u 列的列向量；α_u为第 u 个卷积核中特征在$\boldsymbol{h}_{t+p-1}^{(t)}$下的重要性权重，且$\sum_{u=1}^{k}\alpha_u=1$；$e_u$、$e_q$为注意力得分。

使用$\boldsymbol{\alpha}$对高级特征矩阵 $\boldsymbol{L}$ 的列向量重新计算为加权向量$\boldsymbol{v}_t\in\mathbf{R}^m$，得到注意力机制层的输出，表达式为

$$\boldsymbol{v}_t=\sum_{u=1}^{k}\alpha_u\boldsymbol{L}_u \tag{14}$$

将得到的注意力权重$\boldsymbol{v}_t$和隐藏向量$\boldsymbol{h}_{t+p-1}^{(t)}$通过$\boldsymbol{W}_v$和$\boldsymbol{W}_h$进行组合，获得包含当前时间步下重要特征权重的矩阵$\boldsymbol{h}_t'$：

$$\boldsymbol{h}_t'=\boldsymbol{W}_h\boldsymbol{h}_{t+p-1}^{(t)}+\boldsymbol{W}_v\boldsymbol{v}_t \tag{15}$$

式中：$\boldsymbol{W}_h\in\mathbf{R}^m$；$\boldsymbol{W}_v\in\mathbf{R}^m$；$\boldsymbol{h}_t'\in\mathbf{R}^m$。

1.4 GTA-Seq2Seq 模型解码器

GTA-Seq2Seq 模型中解码器部分采用单层 GRU 单元组成的神经网络。解码器的输入是含有时空特征的向量$\boldsymbol{T}_{t+p-1}^{(t)}$，该向量通过将向量$\boldsymbol{I}_{t+p-1}^{(t)}$与$\boldsymbol{h}_t'$拼接而得到，可记为

$$\boldsymbol{T}_{t+p-1}^{(t)}=\mathrm{Concat}\left(\boldsymbol{I}_{t+p-1}^{(t)},\boldsymbol{h}_t'\right) \tag{16}$$

设 GRU 的初始状态$\boldsymbol{T}_{t+p-1}^{(t)}$为$\boldsymbol{E}_{t+p-1}^{(t)}$，将$\boldsymbol{T}_{t+p-1}^{(t)}$输入 s 次到 GRU 单元中，在预测下一个时间步时 GRU 单元使用拼接向量$\boldsymbol{T}_{t+p-1}^{(t)}$和$\boldsymbol{E}_{t+p-1}^{(t)}$来生成预测值，此时 GRU 单元的输出是隐藏状态向量$\boldsymbol{E}_{t+p}^{(t)}$，在后面加一个 FC 生成在该时间步下的预测值$\hat{\boldsymbol{y}}_{t+p}^{(t)}$。GRU 单元的隐藏状态计算式为

$$\boldsymbol{E}_{t+p}^{(t)}=g\left(\boldsymbol{T}_{t+p-1}^{(t)},\boldsymbol{E}_{t+p-1}^{(t)}\right) \tag{17}$$

式中：g 为 GRU 单元的隐藏状态计算函数。

在预测后面的航迹点时，GRU 单元的输入是由含有时空特征向量$\boldsymbol{T}_{t+p-1}^{(t)}$、GRU 在前一时间步输出的隐藏状态和前一时间步输出的预测值组成，预测第 s 步的表达式为

$$\hat{\boldsymbol{y}}_{t+p+s-1}^{(t)}=F\left(\boldsymbol{T}_{t+p-1}^{(t)},\boldsymbol{E}_{t+p+s-1}^{(t)},\hat{\boldsymbol{y}}_{t+p+s-2}^{(t)}\right) \tag{18}$$

式中：F 为预测值输出方式函数。

1.5　总体方案设计

在 GTA-Seq2Seq 模型的基础上, 结合数据样本划分, 可以得到完整的航迹预测方案, 如图 5 所示。具体步骤如下:

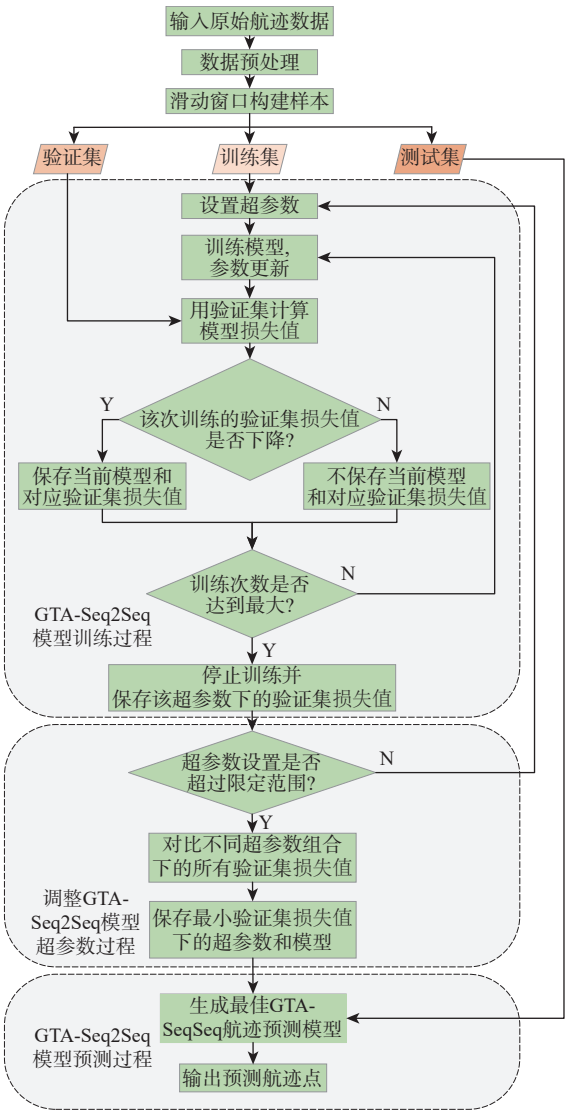

图 5　航迹预测方案流程

Fig. 5　Trajectory prediction scheme flow

1) 滑动预处理之后的航迹数据构建样本, 划分训练集、验证集和测试集;

2) 将训练集输入 GTA-Seq2Seq 模型中训练, 设定 epoch 迭代轮次, 基于训练集的损失函数使用 Adam 优化器更新模型参数, 同时, 引入验证集来评估模型的性能, 根据模型在验证集上由损失函数计算得到的损失值来判断模型的泛化能力并调整超参数, 迭代完成后停止训练, 保存最佳模型;

3) 保存最佳模型后, 使用测试集进行测试, 预测未来航迹点位置, 完成航迹预测。

2　数据构建

航迹数据是不连续的, 由一系列离散轨迹点组成, 但有一些信息缺失或重复的航迹点。信息不全的航迹点排除在数据集中, 重复的点被删除。经过数据清洗后的航迹数据更加平滑, 为后续的模型训练提供质量较好的数据样本, 提升模型的预测精度。

将航迹数据输入模型训练之前, 需要将航迹数据划分为样本数据和标签数据。使用滑动窗口的方法对每条航迹进行分割, 生成第 1 个样本时, 从第 1 个航迹点开始, 选取 p 个航迹点作为输入到模型中的历史输入数据, 后面要预测的 s 步真实航迹点作为标签数据。生成第 2 个样本时, 从第 2 个航迹点继续滑窗, 重复上述操作。滑窗处理过程如图 6 所示。

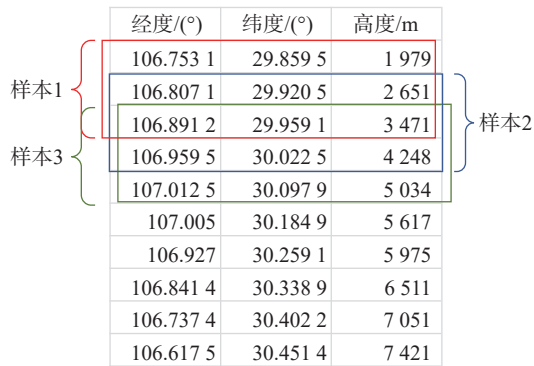

(a) 样本数据(p=3)

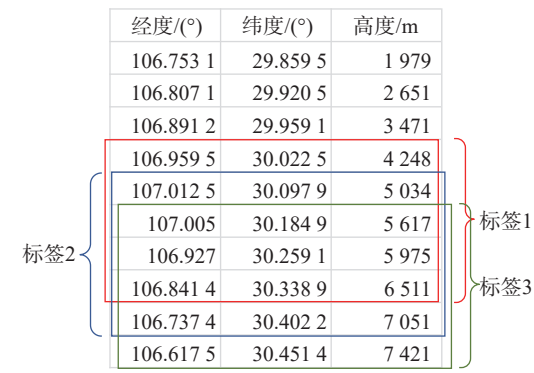

(b) 标签数据(s=5)

图 6　滑窗处理过程示意图

Fig. 6　Schematic diagram of sliding window processing

航迹数据是由不同特征组成的, 为去除度量单位和类型不同而导致不同数据取值范围差异较大所带来的影响, 需要将滑窗后的航迹数据进行归一化。本文采用最大最小归一化对航迹数据进行处理, 使输入模型的数据大小在 [0,1] 之间, 其归一化表达式为

$$\tilde{\boldsymbol{X}} = (\boldsymbol{X} - \boldsymbol{X}_{\min})/(\boldsymbol{X}_{\max} - \boldsymbol{X}_{\min}) \tag{19}$$

式中: $\boldsymbol{X}_{\max}$ 和 $\boldsymbol{X}_{\min}$ 分别为航迹数据中某个特征的最大和最小值; $\tilde{\boldsymbol{X}}$ 为归一化后的特征值。

3　仿真实验与结果分析

3.1　数据准备及超参数选择

为验证 GTA-Seq2Seq 模型的预测效果, 本文选

取重庆飞往乌鲁木齐的 CCA4155 航班的 28 条航迹数据，每条轨迹在预处理后包含大约 200 个多维航迹点，数据间隔约为 60 s。所使用的航迹数据由航班号、飞机 ID、接收时间、经度、纬度、高度、地速、俯仰角、横滚角、航向角组成。所有实验均采用 Keras 深度学习框架进行模型的训练和验证，实验设备的硬件环境是 IntelCorei7-10700 CPU 2.9 GHz 和 16 GB 内存的计算机。

合理的超参数设置在模型训练中起到了至关重要的作用，直接影响模型在训练集和测试集上的表现。本文设置预测步数 s 为 5，也就是预测约 5 min 之后的飞机位置，因为这段时间足够长，能够为潜在的空中冲突提供预警，并留出充足的反应时间，以便采取相应的规避措施。根据模型训练过程中验证集损失值是否减小来调整模型的各项参数，包括输入历史航迹点个数、CNN 卷积核数量、TCN 卷积核数量、GRU 隐藏层神经元数量、批尺寸及学习率等，取训练时最优的结果并保存模型，进行测试。在实验中，编码器和解码器中都使用单层 GRU，设置 CNN 卷积核个数为 64，TCN 的第 1、第 2 层的卷积核个数设置为 16 和 32，卷积核大小设置为 3，扩张因子 d 选取为 1 和 2。由于这些参数对实验结果的影响较小，故不需要进行大规模寻优。因为输入不同的历史航迹点 p 在模型训练时有不同的效果，合适的 GRU 隐藏层神经元个数 m 能更好地提取输入数据的隐藏特征，所以对关键超参数 p 和 m 进行网格化搜索，设定 2 个超参数的搜索范围分别为 p={5,6,7,8,9,10}，m={16,32,64}，得到 18 种超参数组合模型下的验证集误差，图 7 为不同超参数组合下的验证集误差。最后选定的超参数 p=7、m=32，因为 GRU 的隐藏层参数量很小，所以在训练中能提高模型的运算效率，同时，也能得到很高的精度。验证集误差越小说明模型收敛效果越好，预测值和真实值的差异越小。该模型最终的参数如表 1 所示。

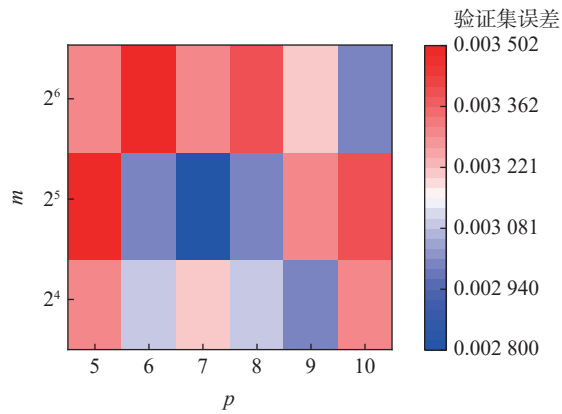

图 7 不同超参数组合下的验证集误差

Fig. 7 Verification set error under different combinations of hyperparameters

表 1 模型超参数优选结果

Table 1 Optimization results of model hyperparameter

TCN第1、第2层卷积核个数	TCN卷积核尺寸	TCN的膨胀系数	CNN卷积核个数	批尺寸	学习率	输入历史航迹点个数p	GRU隐藏层神经元个数	预测航迹点个数s
16、32	3	[1,2]	64	128	0.001	7	32	5

3.2 模型比较与分析

为检验 GTA-Seq2Seq 模型的有效性，将该模型与较为先进的航迹预测模型 GRU 模型[25]、Bi-GRU 模型[26]、CNN-LSTM 模型[15]、LSTM-ED 模型[20]、STED 模型[22]进行比较。为保证公平性，所有模型均采用了相同的训练集、验证集、测试集，将不同模型的最佳参数结果与该模型进行比较。为定量分析预测结果，本文采用均方根误差 (root mean square error, RMSE) 和平均绝对误差 (mean absolute error, MAE) 作为误差评价指标来判断航迹预测的准确性。RMSE 和 MAE 计算式分别为

$$\eta_{\mathrm{RMSE}}=\sqrt{\sum_{t=1}^{N}\left(\left|\hat{\boldsymbol{Y}}_t\right|-\left|\boldsymbol{Y}_t\right|\right)^2/N} \tag{20}$$

$$\eta_{\mathrm{MAE}}=\sum_{t=1}^{N}\left|\left|\hat{\boldsymbol{Y}}_t\right|-\left|\boldsymbol{Y}_t\right|\right|/N \tag{21}$$

RMSE 和 MAE 越小，预测效果越好。

测试集的对比结果如表 2 所示，在预测步数 s 为 5 的情况下每个航迹点的经度、纬度、高度的预测误差如图 8 所示。

从表 2 可以看出，本文模型在测试集上达到很好的精度(见表 2 中加粗部分)。经典模型 GRU 预测精度较低。Bi-GRU 模型是基于 GRU 模型的双向 RNN，使信息可以在时间序列的正反 2 个方向上进行传播，从而提高了模型对序列全局特征的捕捉能力，精度高于 GRU 模型。CNN-LSTM 模型和 LSTM-ED 模型都是基于 LSTM 的混合模型，其中，CNN-LSTM 模型使用 CNN 提取空间特征，LSTM 提取时间特征，LSTM-ED 模型结合了 LSTM 和编码器-解码器架构，而 STED 模型以编码器-解码器架构为基础提取时空特征，都具有较高的预测精度，但都低于 GTA-Seq2Seq 模型。GTA-Seq2Seq 模

表 2　各模型预测误差比较

Table 2　Comparison of prediction errors of each model

模型	预测步数	经度RMSE/(°)	经度MAE/(°)	纬度RMSE/(°)	纬度MAE/(°)	高度RMSE/m	高度MAE/m	时间RMSE/s	时间MAE/s
GRU[25]	1	0.018 6	0.013 8	0.023 1	0.018 1	92.1	34.5	6.7	5.2
	2	0.037 0	0.027 2	0.046 3	0.036 3	202.1	76.6	11.2	8.3
	3	0.544 0	0.039 8	0.067 4	0.053 0	325.1	127.5	14.7	10.4
	4	0.071 4	0.052 8	0.087 1	0.068 9	435.3	179.9	18.1	12.5
	5	0.088 1	0.065 8	0.105 7	0.084 1	535.5	229.4	21.5	14.5
Bi-GRU[26]	1	0.015 7	0.012 6	0.015 1	0.011 8	91.1	33.9	5.6	4.4
	2	0.031 5	0.024 7	0.031 5	0.025 0	196.3	71.7	8.9	7.0
	3	0.048 3	0.037 2	0.049 0	0.039 1	306.8	118.2	11.5	8.9
	4	0.067 0	0.050 1	0.067 3	0.053 2	396.8	162.0	13.8	10.6
	5	0.087 2	0.063 4	0.086 6	0.067 2	467.3	201.7	15.7	12.3
CNN-LSTM[15]	1	0.013 2	0.009 8	0.016 5	0.012 7	96.8	47.7	6.7	5.5
	2	0.019 8	0.015 6	0.017 0	0.012 1	151.5	70.9	7.2	5.6
	3	0.027 1	0.020 8	0.022 6	0.016 8	206.4	94.1	8.1	5.8
	4	0.033 4	0.026 0	0.026 0	0.016 9	229.1	110.5	8.8	6.7
	5	0.041 7	0.032 7	0.033 8	0.022 8	243.7	119.2	9.7	7.7
LSTM-ED[20]	1	0.022 3	0.017 1	0.022 0	0.018 4	100.3	43.5	9.6	6.6
	2	0.031 2	0.022 7	0.028 3	0.018 1	186.1	74.8	14.9	10.2
	3	0.047 0	0.035 3	0.034 4	0.021 8	250.8	98.5	15.4	10.8
	4	0.062 6	0.047 9	0.037 8	0.024 8	277.1	115.6	16.7	11.0
	5	0.078 3	0.060 1	0.041 4	0.028 1	274.5	126.1	17.2	12.0
STED[22]	1	0.013 4	0.009 4	0.009 0	0.007 3	86.1	38.2	0.8	0.7
	2	0.018 2	0.011 7	0.015 5	0.010 6	123.6	50.9	1.2	0.9
	3	0.025 0	0.012 8	0.019 0	0.013 1	187.1	75.2	1.3	1.0
	4	0.033 0	0.016 4	0.022 4	0.015 3	224.2	90.2	1.4	1.1
	5	0.035 9	0.019 9	0.026 0	0.016 7	254.0	105.9	1.6	1.2
GTA-Seq2Seq	1	**0.007 7**	**0.005 7**	**0.005 6**	**0.003 6**	**65.8**	**28.5**	**0.7**	**0.5**
	2	**0.013 9**	**0.008 9**	**0.009 7**	**0.005 8**	**96.2**	**38.3**	**0.9**	**0.7**
	3	**0.017 5**	**0.011 5**	**0.013 3**	**0.007 7**	**119.3**	**47.5**	**1.0**	**0.7**
	4	**0.021 2**	**0.014 2**	**0.016 5**	**0.009 7**	**131.1**	**55.3**	**1.1**	**0.8**
	5	**0.025 9**	**0.017 5**	**0.019 7**	**0.011 7**	**136.6**	**58.3**	**1.4**	**1.1**

型第 5 步预测相较于 STED 模型的 RMSE 减小了 27.70%, MAE 减小了 23.82%, 且在训练过程中所需的参数量相较于 STED 模型减少了 67.42%。由图 8 可以看出, GTA-Seq2Seq 模型相较于其他对比模型, 在不同空间维度均取得了较小的误差, 进一步验证了 GTA-Seq2Seq 模型具有较好的性能。

此外, 由于在多步预测任务中误差积累不能完全避免, 表 2 中 5 个对比模型展现出预测误差随预测步数增加而逐渐累积的趋势, 但 GTA-Seq2Seq 模型在避免误差累积任务中取得更显著的优势, 因为在解码阶段进行预测时, GRU 模型是基于前一个时间步的输出、当前的隐藏状态和编码器生成的语义向量来生成当前时间步的输出, 改善了预测结果的误差累积。

为进一步验证本文方法的性能, 使用从西安飞往北京的 33 条航班数据来进行航迹预测实验。图 9 和图 10 展示了不同时间步长下各模型的预测误差, 可以看出 GTA-Seq2Seq 模型具有较好性能。

3.3　不同飞行状态下预测结果分析

本文通过对复杂飞行状态下的航班数据进行分析, 检验了 GTA-Seq2Seq 模型在不同飞行状态下的预测性能, 验证了其广泛适用性。图 11 为各模型在输入 7 个航迹点的历史轨迹后, 预测输出未来 5 个航迹点轨迹, 并在不同飞行状态下对比各模型预测航迹的三维曲线。

图 11 (a) 为飞机在下降转弯过程中预测曲线与真实曲线对比, 由于飞机在转弯处变换飞机姿态, GRU 模型、Bi-GRU 模型、CNN-LSTM 模型、LSTM-ED 模型、STED 模型这 5 个模型在预测时不能捕捉到飞机的转弯姿态, 尤其是 GRU 模型严重偏离真实航迹, 因为第 1 个航迹点偏差较大, 所以后面产生错误的航迹, 而 GTA-Seq2Seq 模型的预测曲线相

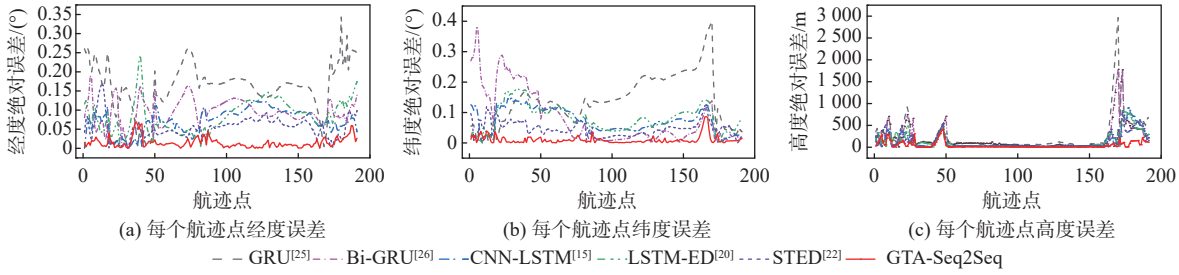

图 8 每个航迹点纬度、经度、高度的预测误差

Fig. 8 Forecast error of latitude, longitude and altitude for each trajectory point

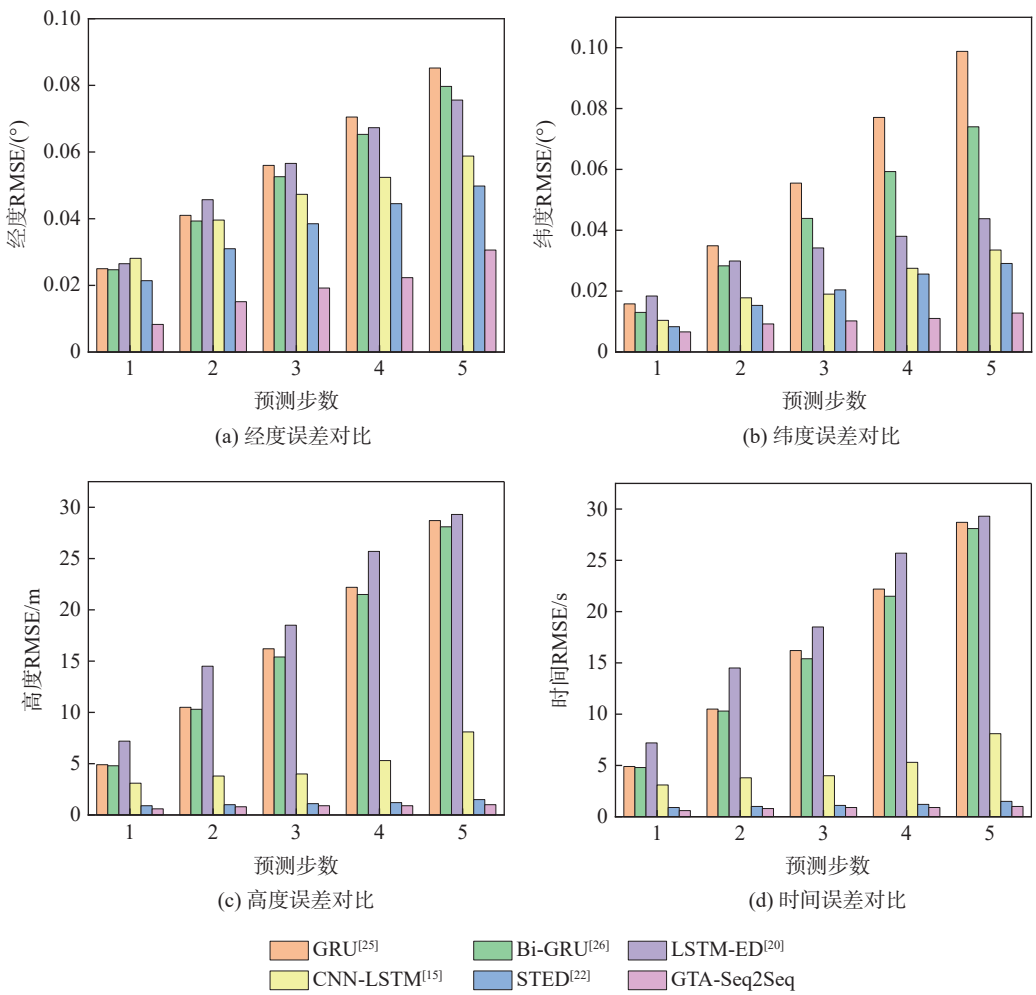

图 9 各模型 RMSE 比较(西安至北京)

Fig. 9 Comparison of RMSE of each model (Xian to Beijing)

较于其他 5 个模型,与真实曲线更加贴近,且在预测第 3、第 4 个航迹点时,该模型能很好地识别出转弯过程。图 11 (b) 展示了飞机在爬升转弯阶段的轨迹预测与真实航迹的比较。在这复杂的飞行场景中,其他 5 个模型均偏离真实航迹,尤其是 GRU 模型在预测时产生了错误的航迹点,没有识别出转弯的飞行意图,而 Bi-GRU 模型在第 4、第 5 个航迹点时预测高度快速上升,预测效果不好。因此,GTA-Seq2Seq 模型不仅能获取飞机在复杂场景中的飞行意图,而且能准确预测未来的飞行趋势,很好地完成了多步航迹预测任务。

综上所述,基于 GTA-Seq2Seq 的航迹预测模型表现出良好的性能,能准确反映未来飞行器的飞行情况,具有较低的预测误差。

3.4 消融实验

在不同模型对比实验中,已经验证了 GTA-Seq2Seq 模型的有效性。为深入探寻各个模块在整个模型中的作用,本节设计了消融实验。以编码器-解码器为基础模块,编码器中分别移除了提取基础航迹数据时序模式的 GRU 模块、TCN 模块和

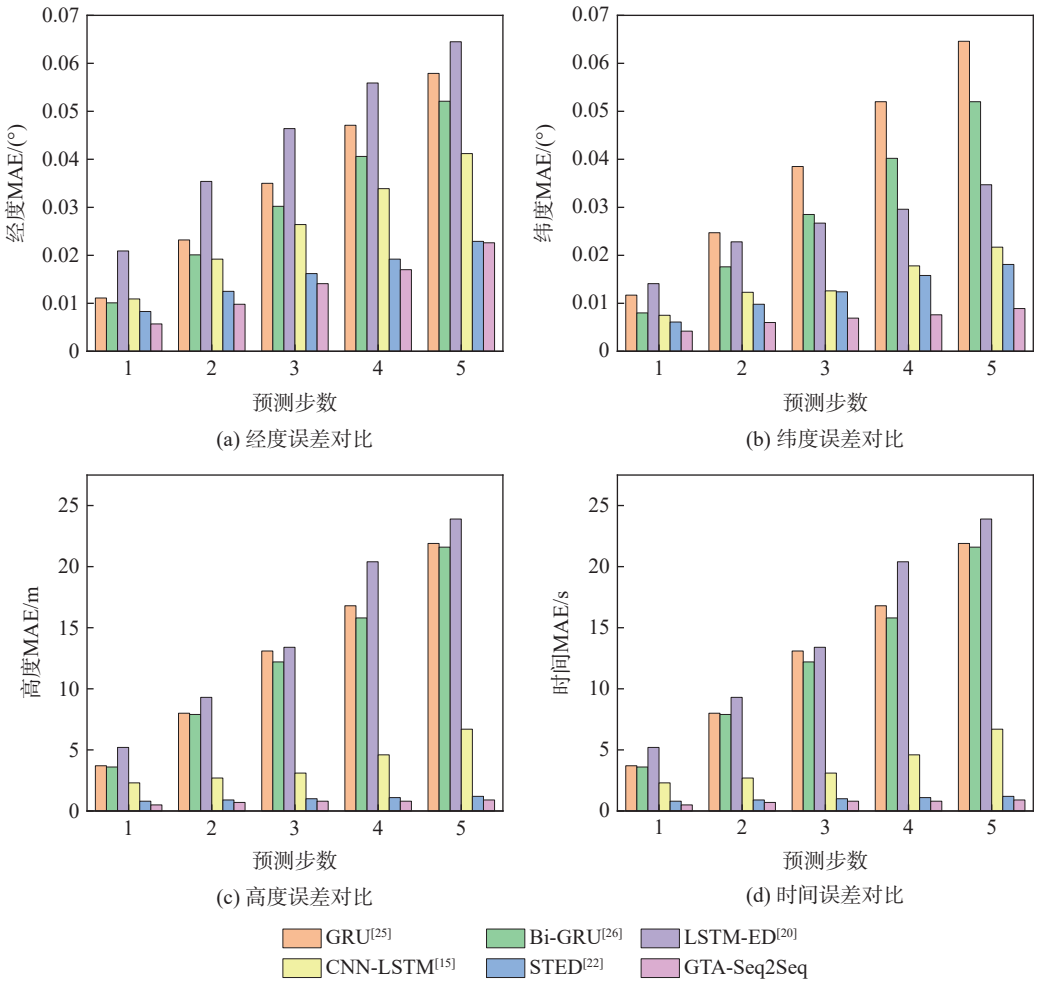

图 10　各模型 MAE 比较(西安至北京)

Fig. 10　Comparison of MAE of each model (Xian to Beijing)

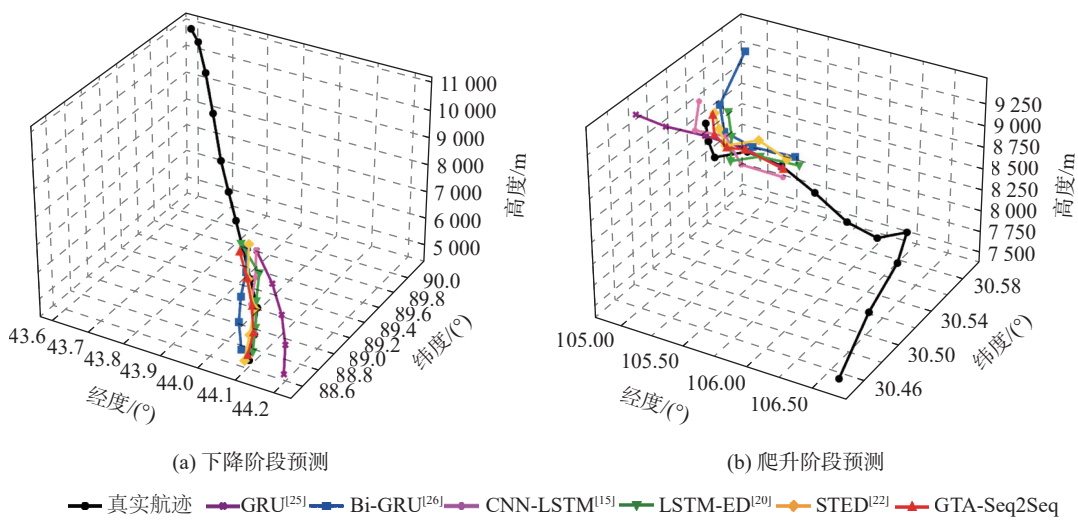

图 11　不同飞行状态下航迹误差比较

Fig. 11　Comparison of trajectory errors under different flight states

TPA 注意力机制模块, 解码器中移除了 FC 模块。所有的消融实验均在 p=7、s=5 的情况下进行, 并计算各个模型的 RMSE 和 MAE, 实验结果如表 3 所示, 加粗显示最优结果。

从表 3 可以看出, 无论移除哪个模块, 模型精度都会有一定的下降。进一步分析每个模块在整个模型中的作用。提取时间特征的 GRU 模块是为提取原始航迹数据中的时序模式。TCN 作为提取空间特征的基础模块, 能够有效地捕捉航迹数据的空间隐藏特征。在模型中引入 TPA 注意力机制, 考

表3 消融实验结果

Table 3 Results of ablation experiment

模型	预测步数	经度RMSE/(°)	经度MAE/(°)	纬度RMSE/(°)	纬度MAE/(°)	高度RMSE/m	高度MAE/m	时间RMSE/s	时间MAE/s
移除GRU模块的GTA-Seq2Seq	1	0.018 9	0.015 2	0.011 2	0.008 0	79.3	30.7	2.4	1.8
	2	0.021 4	0.016 5	0.016 3	0.010 5	120.6	43.8	2.7	2.0
	3	0.028 9	0.021 4	0.021 2	0.013 2	162.1	61.3	2.9	2.2
	4	0.034 2	0.023 9	0.025 2	0.016 0	191.5	76.9	3.0	2.3
	5	0.039 0	0.026 7	0.028 4	0.018 5	213.8	90.7	3.4	2.6
移除TCN模块的GTA-Seq2Seq	1	0.016 5	0.013 1	0.012 2	0.008 5	76.9	29.8	2.3	1.9
	2	0.023 6	0.016 6	0.017 8	0.011 5	137.7	53.4	2.4	2.0
	3	0.034 9	0.023 0	0.023 8	0.015 7	170.0	67.2	3.1	2.5
	4	0.044 8	0.028 7	0.029 4	0.020 3	182.4	76.4	3.9	3.1
	5	0.053 6	0.034 6	0.033 2	0.023 8	191.6	84.2	4.5	3.5
移除TPA模块的GTA-Seq2Seq	1	0.014 6	0.010 1	0.010 5	0.007 8	77.2	35.3	2.2	1.8
	2	0.016 1	0.011 4	0.015 5	0.011 9	117.7	45.6	2.3	1.9
	3	0.021 9	0.015 1	0.021 3	0.015 5	149.0	59.0	2.6	2.1
	4	0.027 6	0.019 2	0.025 9	0.018 4	169.9	73.3	2.9	2.3
	5	0.032 5	0.022 4	0.029 3	0.020 7	185.2	82.7	3.5	2.9
移除FC模块的GTA-Seq2Seq	1	0.015 6	0.010 7	0.011 0	0.007 5	77.5	38.6	2.5	1.9
	2	0.018 5	0.012 9	0.015 2	0.010 2	129.7	48.6	2.8	2.1
	3	0.020 5	0.014 9	0.019 0	0.012 2	147.0	64.5	3.0	2.3
	4	0.023 4	0.017 1	0.022 2	0.013 7	151.5	65.4	3.3	2.5
	5	0.028 3	0.020 2	0.024 9	0.015 1	158.6	68.5	3.5	2.7
GTA-Seq2Seq	1	**0.007 7**	**0.005 7**	**0.005 6**	**0.003 6**	**65.8**	**28.5**	**0.7**	**0.5**
	2	**0.013 9**	**0.008 9**	**0.009 7**	**0.005 8**	**96.2**	**38.3**	**0.9**	**0.7**
	3	**0.017 5**	**0.011 5**	**0.013 3**	**0.007 7**	**119.3**	**47.5**	**1.0**	**0.7**
	4	**0.021 2**	**0.014 2**	**0.016 5**	**0.009 7**	**131.1**	**55.3**	**1.1**	**0.8**
	5	**0.025 9**	**0.017 5**	**0.019 7**	**0.011 7**	**136.6**	**58.3**	**1.4**	**1.1**

虑不同特征对时间步的影响，通过对航迹数据在空间特征的全方面考虑，注意力机制能够更集中关注关键特征，忽略次要特征对模型训练过程的影响，进一步提高航迹预测性能。而解码器中FC通过线性变换将GRU提取的高维特征降维到实际的输出维度，确保模型能够生成对应于未来的航迹点具体数值。从消融实验结果看出，GTA-Seq2Seq的每个模块都在多步航迹预测中发挥着重要作用。此外，预测一个航迹点的平均耗时为0.03 s，远小于每个航迹点间隔60 s，证明GTA-Seq2Seq模型具有很好的实时性。

4 结 论

本文基于编码器-解码器架构，将GRU、TCN、TPA注意力机制多模块协同工作，提出了GTA-Seq2Seq航迹预测模型，该模型能够充分提取时空特征，实现高精度的航迹预测。通过实验验证本文模型的有效性，主要结论如下：

1）以编码器-解码器架构为基础改进的Seq2Seq结构通过GRU捕捉航迹数据中的时间依赖性。TCN-GRU提取航迹数据中的复杂空间特征，充分挖掘了航迹数据中飞机的运动规律。

2）提取空间特征时通过TPA注意力机制考虑不同特征的重要程度，可增加对关键特征的关注度，提高了模型预测的准确性。

3）在解码部分考虑了整个输入序列的信息，并通过迭代生成的方式输出序列，可缓解多步预测中误差随预测步长增加而带来的不稳定问题。

4）GTA-Seq2Seq模型与现有较为先进的航迹模型GRU模型、Bi-GRU模型、CNN-LSTM模型、LSTM-ED模型、STED模型的对比表明，GTA-Seq2Seq模型具有更好的预测能力，尤其是在复杂飞行场景中。

在未来工作中，可以加入速度、航向角、俯仰角等信息，进一步提取更多隐藏特征，同时，构建参数较少且精度更高的航迹预测模型。

参考文献（References）

[1] 中国民用航空局, 国家发展和改革委员会, 交通运输部. 中国民用航空发展第十三个五年规划[EB/OL]. (2017-04-05)[2024-08-28]. http://www.caac.gov.cn/XXGK/XXGK/FZGH/201704/t201704

05_43502.html.
Civil Aviation Administration of China, National Development and Reform Commission, Ministry of Transport. The 13th five-year plan for the development of civil aviation in China[EB/OL]. (2017-04-05)[2024-08-28]. http://www.caac.gov.cn/XXGK/XXGK/FZGH/201704/t20170405_43502.html(in Chinese).

[2] Ramasamy S, Sabatini R, Gardi A, et al. Next generation flight management system for real-time trajectory based operations[J]. Applied Mechanics and Materials, 2014, 629: 344-349.

[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] Hao S Q, Cheng S W, Zhang Y P. A multi-aircraft conflict detection and resolution method for 4-dimensional trajectory-based operation[J]. Chinese Journal of Aeronautics, 2018, 31(7): 1579-1593.

[5] 中国民用航空局空中交通管理局. 中国民航基于航迹运行(TBO)的推进进展: WP/462[EB/OL]. 2022[2026-10-18]. https://www.icao.int/sites/default/files/Meetings/a41/Documents/WP/wp_462_zh.pdf.
Air Traffic Management Bureau of Civil Aviation Administration of China. Progress of China civil aviation on trajectory-based operations(TBO): WP/462[EB/OL]. 2022[2026-10-18]. https://www.icao.int/sites/default/files/Meetings/a41/Documents/WP/wp_462_zh.pdf (in Chinese).

[6] Liu C Y, Zheng Q, Chang J C, et al. Summary and outlook of 4D track prediction methods[J]. Journal of Mechanical Engineering, Automation and Control Systems, 2020, 1(1): 46-55.

[7] 彭瑛, 胡明华, 张颖. 动态航迹推测方法[J]. 交通运输工程学报, 2005, 5(1): 61-65.
Peng Y, Hu M H, Zhang Y. Conjecture method of dynamic flying track[J]. Journal of Traffic and Transportation Engineering, 2005, 5(1): 61-65(in Chinese).

[8] 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(in Chinese).

[9] Wu Z J, Tian S, Ma L. A 4D trajectory prediction model based on the BP neural network[J]. Journal of Intelligent Systems, 2019, 29(1): 1545-1557.

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

[11] Sahadevan D, M H P, Ponnusamy P, et al. Ground-based 4d trajectory prediction using bi-directional LSTM networks[J]. Applied Intelligence, 2022, 52(14): 16417-16434.

[12] 石庆研, 岳聚财, 韩萍, 等. 基于 LSTM-ARIMA 模型的短期航班飞行轨迹预测[J]. 信号处理, 2019, 35(12): 2000-2009.
Shi Q Y, Yue J C, Han P, et al. Short-term flight trajectory prediction based on LSTM-ARIMA model[J]. Journal of Signal Processing, 2019, 35(12): 2000-2009(in Chinese).

[13] Han P, Wang W Q, Shi Q Y, et al. A combined online-learning model with K-means clustering and GRU neural networks for trajectory prediction[J]. Ad Hoc Networks, 2021, 117: 102476.

[14] 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).

[15] Ma L, Tian S. A hybrid CNN-LSTM model for aircraft 4D trajectory prediction[J]. IEEE Access, 2020, 8: 134668-134680.

[16] Bai S J, Kolter J Z, Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [EB/OL]. (2018-04-19)[2024-08-28]. https://doi.org/10.48550/arXiv.1803.01271.

[17] 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. 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).

[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 T T, Liu B, Li C Z. Aircraft trajectory prediction within terminal area based on Seq2Seq-attention model[J]. Science Technology and Engineering, 2024, 24(9): 3882-3895(in Chinese).

[19] 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.

[20] 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.

[21] 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.

[22] 石庆研, 张泽中, 韩萍. 基于时空特征融合的 Encoder-Decoder 多步 4D 短期航迹预测[J]. 信号处理, 2023, 39(11): 2037-2048.
Shi Q Y, Zhang Z Z, Han P. Multi-step 4D short-term trajectory prediction using encoder-decoder with spatio-temporal features fusion[J]. Journal of Signal Processing, 2023, 39(11): 2037-2048(in Chinese).

[23] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.

[24] Chung J, Gulcehre C, Cho K, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[EB/OL]. (2014-12-11)[2024-08-28]. https://arxiv.org/abs/1412.3555(in Chinese).

[25] 王文青. GRU 神经网络在航迹预测中的研究与应用[D]. 天津: 中国民航大学, 2021.
Wang W Q. Research and application of GRU neural network in trajectory prediction[D]. Tianjin: Civil Aviation University of China, 2021(in Chinese).

[26] Chen Z X, Wang L. Aircraft trajectory prediction model based on improved GRU structure[C]//Proceedings of the 2023 3rd International Conference on Consumer Electronics and Computer Engineering. Piscataway: IEEE Press, 2023: 225-228.

GTA-Seq2Seq multi-step 4D trajectory prediction model based on spatio-temporal feature extraction

SHI Qingyan，ZHAO Wantong，HAN Ping*

(Tianjin Key Laboratory for Advanced Signal Processing，Civil Aviation University of China，Tianjin 300300，China)

Abstract：Real-time flight path correction, conflict avoidance, and increased flight safety are all made possible by high-precision multi-step trajectory prediction. Traditional models usually face problems such as low multi-step prediction accuracy and difficulty in capturing the nonlinear relationship between spatial and temporal features in flight trajectories. Therefore, this paper proposes a multi-step 4D trajectory prediction model GTA-Seq2Seq that uses a gate recurrent unit (GRU), temporal convolutional network (TCN) and temporal pattern attention (TPA) mechanism in a sequence-to-sequence (Seq2Seq) model. The model is divided into an encoder part and a decoder part. The encoder extracts the time dependence in trajectory data by using GRU and combines the TCN-GRU network to extract the spatial features of trajectory data. To accomplish high-precision multi-step trajectory prediction, the spatial and temporal information are concatenated in the decoder section and sent into GRU. The experiment shows that the proposed model outperforms traditional models in terms of prediction accuracy. The fifth step prediction in the model reduces the root mean square error (RMSE) by 27.70% and the mean absolute error (MAE) by 23.82% compared to the optimal model—spatio-temporal encoder-decoder (STED) among the comparison models. In addition, the required number of parameters of the GTA-Seq2Seq model in the training process is reduced by 67.42% compared to STED model, improving the operational efficiency of the model.

Keywords：trajectory prediction；spatio-temporal features；temporal convolutional network；attention mechanism；encoder-decoder；sequence-to-sequence model

Received：2024-09-18；**Accepted**：2024-11-22；**Published Online**：2024-12-20 13：04

URL：link.cnki.net/urlid/11.2625.V.20241219.1708.001

Foundation item：Civil Aviation Safety Capacity Building Funds (KJZ49420210082)

* **Corresponding author**. E-mail：hanpingcauc@163.com