

基于生成对抗网络的三维空间民航轨迹预测模型

曹建制 佟强 陈玉立 刘秀磊*

(北京信息科技大学数据科学与情报分析实验室 北京 100101)

摘要 民航轨迹数据存在采样时间不均匀、空间维度量纲不一致的问题,并且现有轨迹预测方法主要面向行人、车辆等地面交通轨迹,适用于三维空间中的民航轨迹预测方法较少。针对上述问题,提出一种基于生成式对抗网络的三维空间民航轨迹预测模型。该模型对民航轨迹数据重采样以统一采样间隔,消除不同量纲影响;使用数据中的时序特征和不同目标之间的交互信息生成预测轨迹。实验表明,与传统轨迹预测方法相比,该模型在ADE指标上降低了29%以上,验证了模型在三维空间民航轨迹预测中的有效性。

关键词 轨迹预测 民航轨迹 长短时记忆网络 生成对抗网络

中图分类号 TP18

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.07.011

3D FLIGHT TRAJECTORY PREDICTION MODEL BASED ON GENERATIVE ADVERSARIAL NETWORK

Cao Jianzhi Tong Qiang Chen Yuli Liu Xiulei*

(Laboratory of Data Science and Information Studies, Beijing Information Science and Technology University, Beijing 100101, China)

Abstract Flight trajectory data has the problems of uneven sampling time and inconsistent spatial dimension. Moreover, the existing trajectory prediction methods are mainly oriented to ground traffic trajectory such as pedestrians and vehicles, and there are few flight trajectory prediction methods applicable to three-dimensional space. To address the above problems, this paper proposes a prediction model for 3D flight trajectory based on generative adversarial network. The model resampled the flight trajectory data to unify the sampling time interval and eliminate the influence of extreme variation between different spatial dimension. The time series characteristics in the data and the interaction information between different targets were used to generate the predicted trajectory. Experiments show that compared with traditional trajectory prediction methods, the proposed model reduces the ADE by more than 29%, which verifies the effectiveness of the model in the prediction of flight trajectory in 3D space.

Keywords Trajectory prediction Flight trajectory LSTM Generative adversarial network

0 引言

随着经济水平的不断提高,航空业得到了迅速发展。以民航客运为例,据中国民用航空局的统计数据,2019年12月份民航所完成的旅客运输量达到了5276万人次^[1]。民航轨迹预测作为航空交通管理的关键技术^[2],能够有效地提高空域资源的利用率,加

强空中交通的安全性。

轨迹预测问题是基于已经发生过的轨迹,预测接下来的轨迹走向,问题的本质是对时间序列数据的回归预测。现有研究主要围绕行人或车辆等地面交通参与者,使用基于长短时记忆网络(Long Short-Term Memory, LSTM)的深度学习模型,对发生在地面平面上的轨迹进行预测。民航轨迹由于其位于三维空间中,各个维度的变化幅度差异较大,且具有时间维度上的采样不

收稿日期:2020-12-25。国家重点研发计划项目(2017YFB1400402,2018YFC0830202);网络文化与数字传播北京市重点实验室开放课题项目(ICDDXN006);北京信息科技大学勤信人才项目(2020);面向边缘计算的创新科研平台建设项目(2020KYNH105)。

曹建制,硕士生,主研领域:机器学习,数据挖掘。佟强,讲师。陈玉立,硕士生。刘秀磊,副教授。

均匀性,无法直接使用针对地面轨迹的预测模型进行民航轨迹预测。

本文提出一种面向三维空间坐标的民航轨迹预测模型,该模型基于生成式对抗网络结构,通过学习前序轨迹的数据分布生成预测轨迹,利用池化机制提取不同飞机之间的交互特征,使用判别器来判断生成的轨迹是否符合数据分布。并提出一种民航轨迹数据重采样方法,将原有的非均匀时间采样重新插值为均匀时间采样,并统一各个空间维度的数据量纲,实验表明该方法有效提高了模型的训练鲁棒性。本文还根据民航轨迹中的不同高度将民航轨迹划分为不同的飞行阶段,针对各个飞行阶段的轨迹数据进行了实验对比分析,以进一步揭示民航轨迹的数据分布特点,从而帮助建立更准确的民航轨迹预测模型。

1 国内外研究现状

针对轨迹预测问题的早期工作主要使用基于统计学的方法,通过数理统计的方式对序列数据信息进行处理,并以此预测未来一定时间内的轨迹位置。主要方法包括时间序列模型^[3]、马尔可夫模型^[4]、卡尔曼滤波器^[5]等。基于统计的方法虽然能够在一定程度上对轨迹进行预测,但这些方法缺少对轨迹中各个点之间联系的有效分析^[6],其预测结果倾向于区域而非精确轨迹。

之后研究人员将神经网络应用到轨迹的预测中,Payeur 等^[7]将神经网络(Artificial Neural Networks, ANN)引入到轨迹预测当中,使用最近的六个坐标观测值作为神经网络的输入,通过若干神经元计算预测未来轨迹。神经网络虽然能够学习到数据之间复杂的非线性关系,但是容易出现过拟合现象。随着深度学习的兴起,也有研究人员将深度信念网络、堆叠自编码器应用到轨迹预测上^[8-9],都取得了一定的效果。近年来,循环神经网络^[10]特别是长短时记忆网络凭借其时间序列数据上较强的特征提取能力,在轨迹预测研究领域得到了广泛关注。Shi 等^[11]提出了一种基于 LSTM 的飞机轨迹预测模型,在 LSTM 网络中应用滑动窗口来保持输入数据的精度,避免了长期序列中相邻状态的动态依赖性,提高了预测的精度。Liu 等^[12]提出了基于编码器-解码器架构的民航轨迹预测模型,编码器通过 LSTM 网络从最近飞行计划中学习隐藏特征,并反馈给解码器网络,解码器网络通过 LSTM 网络输入这些隐藏特征、历史飞行轨迹、天气特征来完成对轨迹的预测。Alahi 等^[13]提出了社交长短

时记忆网络(Social-LSTM)模型用于行人轨迹预测,对于每一位行人使用一个单独的 LSTM 网络表征当前状态,在 LSTM 网络中添加池化层获取附近其他行人的潜在特征。但是在 Social-LSTM 中基于空间位置的远近来判断交互程度的假设并不符合实际,因为两个人的空间位置接近,并不代表他们接下来的行为具有更高的相关性。Gupta 等^[14]在 Social-LSTM 的基础上提出了社交生成式对抗网络(Social Generative Adversarial Network, Social-GAN)模型,相较于 LSTM 编码解码模型,该模型使用一种新的池化机制对同一场景下所有人的潜在特征进行编码,学习全局池化特征,并借助生成对抗的思想,通过生成器和判别器的大量对抗学习,提高了在数据集上的表现。

在轨迹预测的研究当中,车辆的轨迹预测也一直是研究的热点,其中一些思路也被借鉴到飞行轨迹预测中。Xin 等^[15]提出了一种用于车辆轨迹预测的 LSTMs 模型,通过环绕车辆等分坐标来获取当前车辆的驾驶意图,以此提高最终预测的效果。Zyner 等^[16]提出了基于多层 LSTM 的网络模型来获取驾驶意图,通过将车辆的相对坐标、行驶方向和速度输入到全连接网络中,然后通过三层 LSTM 网络输出可能行驶方向。季学武等^[17]提出了基于 LSTM 网络的驾驶意图识别和车辆轨迹预测模型,使用基于编码解码架构的 LSTM 网络来对驾驶意图进行预测判断,结合车辆的前序轨迹以及不同车辆之间的交互信息来对未来轨迹做出预测,显著地提高了轨迹预测的精度。

2 面向三维空间坐标的民航轨迹预测模型

2.1 民航轨迹数据重采样

2.1.1 数据描述

与地面轨迹数据相比,民航轨迹数据具有一些明显的区别。最显著的差异是民航轨迹数据是包含了时间维度与三个空间维度的四维时空数据,而非地面轨迹数据的三维时空数据。在实际应用中,地面轨迹数据通常来自视频,这意味着数据中的两个空间维度具有相似的变化幅度。而民航轨迹的三个空间维度通常为经纬度和高度,三个维度的变化幅度差异很大。另外,对地面轨迹数据的采样往往取决于视频采样率,表现为每个视频帧对应一个轨迹点,在时间维度上具有均匀性。民航轨迹的采样由于依赖于硬件设备的通信质量,在时间维度上表现为非均匀采样,而本文所使用模型需要提取同一场景下不同飞行轨迹之间的交

互特征来提高预测效果,这需要将输入数据置于统一的时间基准下才能用于现有的轨迹预测网络,因此需要进行必要的轨迹数据重采样,以满足训练网络的需求。

本文以目前具有较大影响力的 ADS-B 数据集为例,提出一种民航轨迹数据的重采样方法。ADS-B (Automatic Dependent Surveillance Broadcast) 即广播式自动相关监视系统,由机载设备和地面监视设备组成。地面监视设备通过以固定的频率向一定范围内的机载设备发送请求获取其飞行状态来收集民航轨迹数据。对于民航轨迹来说,每条轨迹包含若干轨迹点,每个轨迹点描述了当前飞机注册号、经度、纬度、高度、时间等识别信息与时空信息。表 1 所示为其中一条轨迹的部分数据示例,其中:Reg 为飞机的注册编号;Alt 为当前飞机高度;Lat 为轨迹点纬度;Long 为轨迹点经度;Time 为轨迹点采集时间;Time Interval 为轨迹点采集的时间间隔,通过计算相邻轨迹点采集时间的差值来得出。

表 1 民航轨迹原始数据部分样例

Reg	Alt/m	Lat	Long	Time	Time Interval
JA613A	30 000.0	42.914 001	134.720 001	2016-07-01 11:34:26.709	00:01:02.923
JA613A	30 000.0	42.985 298	134.568 695	2016-07-01 11:35:30.584	00:01:03.875
JA613A	30 000.0	43.001 099	134.425 201	2016-07-01 11:36:25.053	00:00:54.469
JA613A	30 000.0	43.015 301	134.258 606	2016-07-01 11:37:28.272	00:01:03.219
JA613A	30 025.0	43.028 599	134.100 998	2016-07-01 11:38:23.444	00:00:55.172
JA613A	30 000.0	43.042 900	133.929 703	2016-07-01 11:39:25.882	00:01:02.438
JA613A	30 000.0	43.057 400	133.755 096	2016-07-01 11:40:30.444	00:01:04.562

通过对表 1 中轨迹数据的观察可以发现,不同轨迹点采集的时间间隔各不相同,轨迹点的采集时间周期并非均匀分布,无法满足神经网络对于输入数据的要求。

2.1.2 数据重采样

民航数据中的每条轨迹由若干离散的轨迹点组成。由于采集民航轨迹的硬件设备受到多种客观条件制约,所采集数据在时间维度上表现为非均匀采样。为了使得民航轨迹点满足时间维度上的均匀分布,需要对民航轨迹数据进行重采样。在本文中重采样周

期设为 1 min,采用线性插值的方法生成各个重采样点的三维空间坐标。图 1 展示了数据集中的 2 条轨迹在重采样前后的采样点在飞行高度维度上的分布,其中空心点为民航轨迹原始采样点,实心点为重采样后的采样点。




图 1 数据重采样前后对比

由于民航轨迹数据的空间坐标是三维数据,其中的高度与经纬度的量纲差异很大,即在实际飞行过程中,高度的变化幅度远大于经纬度的变化幅度。由于本文以 L2 距离作为损失函数评估中的基准距离,过大的高度变化幅度会导致模型拟合偏向于高度特征,而忽视经纬度特征的影响,因此需要对三个空间维度进行归一化处理。经过处理之后的民航轨迹集合记为:

$$X = \{X_1, X_2, \dots, X_n\}$$

式中: X_i 表示第 i 条轨迹,每条轨迹中包含若干轨迹点,相邻轨迹点的时间距离为 1 min。图 2 展示了 5 条轨迹经过重采样之后在时间轴上的分布,其中:横坐标代表重采样之后的时间点;纵坐标代表坐标点的高度。




图 2 重采样数据展示

2.2 模型结构

为了能够对包含三维空间坐标的民航轨迹进行学习预测,本文提出一种面向三维空间坐标的民航轨迹预测模型网络。该网络中的生成器通过不断学习前序轨迹的数据分布进而生成未来的预测轨迹,并使用判别器来判断生成的轨迹是否符合原始数据的分布规律。整个模型的架构如图 3 所示。

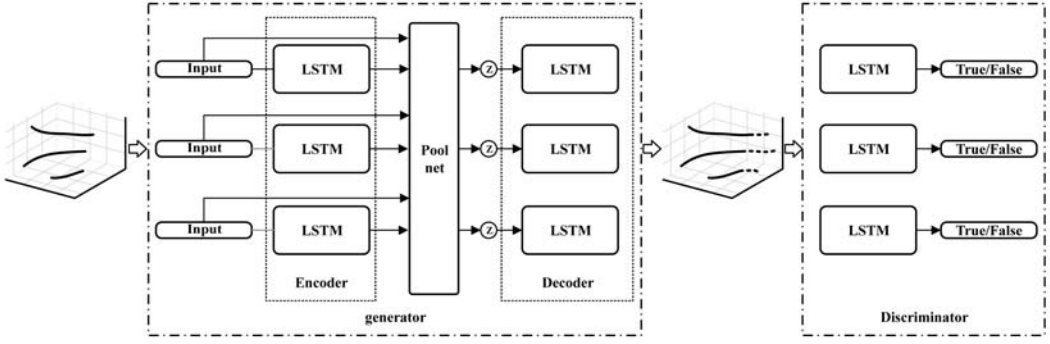


图3 模型架构

该模型中的生成器模块包含编码器、池化层和解码器。在编码器中,每一条输入轨迹由一个独立 LSTM 网络负责提取时序特征,然后通过池化层对输入轨迹与其时序特征进行汇集,捕获不同轨迹之间的交互特征,最后通过解码器中的 LSTM 网络解码生成预测轨迹结果。判别器模块使用 LSTM 网络提取待判别轨迹的时序特征,并通过 MLP 网络对其是否有效进行判断。本文随后将对各个模块进行详细介绍。

2.2.1 编码器

编码器同时接受同一时间段内的多条输入轨迹 $X = \{X_1, X_2, \dots, X_n\}$, 每个时刻通过 location embedding 将输入的数据压缩得到一个固定长度向量 I_{ei}^t , 然后连同上一时刻的隐藏特征 h_{ei}^{t-1} 一起输入到 LSTM 网络中进行编码。

$$I_{ei}^t = \text{MLP}(X_i^t; W_{ee}) \quad (1)$$

$$h_{ei}^t = \text{LSTM}(h_{ei}^{t-1}, I_{ei}^t; W_{el}) \quad (2)$$

式中: X_i^t 为第 i 条轨迹在 t 时刻的数据, 长度为 τ_{obs} , 包含经度、纬度和高度的信息; h_{ei}^t 为第 i 条轨迹 t 时刻 LSTM 网络的隐藏层特征; W_{ee} 为 embedding 层的参数; W_{el} 为 LSTM 网络的参数。

编码器将轨迹信息压缩成固定长度的向量, 通过 LSTM 网络提取其中的时序特征。这些时序特征包含了飞行轨迹中不同点之间前后的关联关系。

2.2.2 池化层

池化层的输入来自两部分, 第一部分是汇集了同一时间段内不同轨迹 LSTM 网络最后输出的隐藏特征 h^t , 另一部分是不同飞机之间的相对位置 $p_{\text{os,rel}}$, 不同于二维空间坐标, $p_{\text{os,rel}}$ 中还包含了飞机高度上的差异。先通过对 $p_{\text{os,rel}}$ 进行 embedding 操作, 将它与 h^t 的维度对齐。然后两者一起输入到 MLP 网络中, 最后通过最大池化来提取交互特征。

$$r_e^t = \text{MLP}(p_{\text{os,rel}}; W_{pe}) \quad (3)$$

$$P_i = \max(\text{MLP}(h_{ei}^t, r_e^t; W_{MLP})) \quad (4)$$

式中: $p_{\text{os,rel}}$ 为不同飞机之间的相对位置, 通过多层感知

机 MLP 网络中之后得到一个 $n \times n \times e_{\text{embedding_dim}}$ 的向量, 其中 $e_{\text{embedding_dim}}$ 为 embedding 层的维度, 通过池化后重新得到一个 $n \times e_{\text{embedding_dim}}$ 的交互特征; W_{pe} 为相对位置 embedding 的参数; W_{MLP} 为 MLP 层的参数。

2.2.3 解码器

解码器的输入来自三部分, 第一部分是将编码器最后输出的隐藏特征 h_{ei}^{obs} , 第二部分是 $t-1$ 时刻的位置, 最后是池化输出的交互特征。

首先将 t_{obs} 时刻的隐藏特征 h_{ei}^{obs} 和交互特征 P_i 输入到 MLP 网络中, 通过加入高斯噪声, 获得解码器 LSTM 网络的初始化隐藏特征 h_{di}^t 。

$$c_i^t = \text{MLP}(P_i, h_{ei}^{\text{obs}}; W_c) \quad (5)$$

$$h_{di}^t = [c_i^t, z] \quad (6)$$

然后对 $t-1$ 时刻位置数据进行 embedding, 将结果与之前计算出来的 LSTM 网络的初始隐藏状态一起输入到 LSTM 网络中。最后对 LSTM 网络输出的结果输入到多层感知机中生成预测的轨迹。

$$I_{di}^{t-1} = \text{MLP}(X_i^{t-1}; W_{de}) \quad (7)$$

$$h_{di}^t = \text{LSTM}(h_{di}^{t-1}, I_{di}^{t-1}; W_{dl}) \quad (8)$$

$$\hat{Y}_i = \text{MLP}(h_{di}^t; W_{fm}) \quad (9)$$

解码器融合了编码器中提取出来的时序特征与池化层提取的交互特征作为输入, 通过 LSTM 网络来解码生成符合飞行规律的预测结果。

2.2.4 损失函数

生成器的损失函数分为两个部分, 一部分是预测的位置偏移损失 $L2_{\text{loss}}$, 另一部分是判别器对生成结果的对抗损失。

$$L = L_{\text{GAN}} + \lambda \times L_{L2} \quad (10)$$

$$L_{\text{GAN}}(G, D) = E_{Y_i}[\log D(Y_i)] + E_z[\log(1 - D(G(X_i, z)))] \quad (11)$$

$$L_{L2} = \min_k \|Y_i - G(X_i, z)^{(k)}\|_2 \quad (12)$$

式中: λ 是超参数, 用来平衡对抗损失与位置偏移损失; k 是生成器的采样次数, 每次从 k 个生成结果中取其中最好的结果。

3 实验与分析

为了验证本文模型的效果,将该模型在处理好的数据集上进行实验,并与传统方法进行比较。实验所采用的开发环境为 Manjaro 18.0.2 64 位操作系统,选用的深度学习框架为 PyTorch 1.5.0。计算机配置为 Intel(R) Core(TM) i7-7700HQ, 16 GB 内存, NVIDIA GeForce GTX1060 6 GB 显卡。

具体的实验流程如图4所示。首先在准备好的数据集上进行数据重采样;然后将数据集划分为包含所有处理完成数据的整体数据集,以及依照规则划分好的平飞数据集和起飞下降数据集;最后在相应的数据集上完成各类模型的预测效果比较实验和不同飞行阶段数据的比较实验。

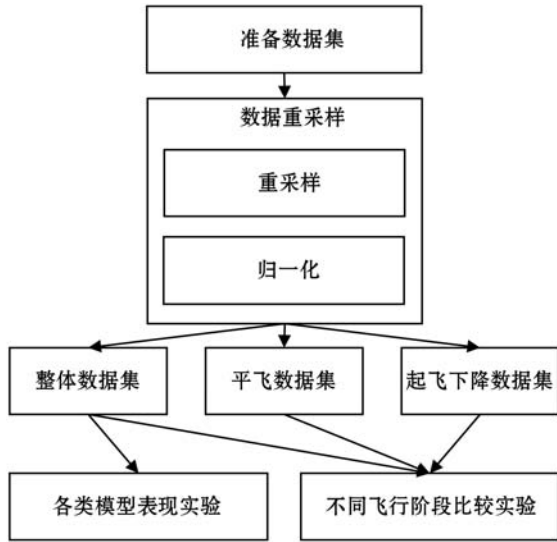


图4 实验流程

3.1 数据集设置

在本文中使用 ADS-B 数据集进行实验,选择其中 2017 年 6 月 1 日的东经 70 度到东经 140 度、北纬 0 度到北纬 60 度的全球民航飞机轨迹数据共 1 675 条。为了解决部分飞行轨迹存在原始采样点不连续的问题,若两个相邻采样点的时间间隔大于 1 min,则将其拆分为不同的飞行轨迹。然后使用本文中提出的轨迹数据重采样方法对各条飞行轨迹进行了重采样,并将重采样后的轨迹长度设定为不超过 32 个连续采样点,共得到 9 030 条连续的飞行轨迹数据。最后采用线性归一化的方法对整体数据进行归一化处理,将三个空间维度的范围都归一化至[0,1]。按照 8:1:1 的比例,将全部飞行轨迹数据划分为训练集、验证集与测试集。

3.2 模型参数设置和训练过程

本文实验采用小批量梯度下降(Mini-batch Gradient

Descent)的方式进行训练,根据机器的性能和实际训练的效果,设置的批量大小为 8。采用固定步长衰减的学习率衰减方式,每隔固定的步长,学习率乘以一个衰减系数,其衰减公式为:

$$l_{\text{learning_rate}} = l_{\text{learning_rate_base}} \times g_{\text{amma}}^{\frac{s_{\text{tep_size}}}{s_{\text{tep}}}} \quad (13)$$

式中: $l_{\text{learning_rate}}$ 为当前的学习率; $l_{\text{learning_rate_base}}$ 为初始学习率; g_{amma} 为学习率衰减系数; $s_{\text{tep_size}}$ 为固定步长大小; s_{tep} 是从开始训练到当前的步数。在本实验中设置初始学习率为 2×10^{-3} ,学习率衰减系数为 0.5,固定步长为 1 000,以 epoch 为周期来记录步数。

实验模型采取的优化算法为 Adam,训练迭代的次数为 20 000,神经网络的激活函数选择的是 ReLU,相对应的网络参数初始化的方法为 Kaiming Initialization。训练时输入每条轨迹的观察长度 $t_{\text{obs}} = 8$,预测长度 $t_{\text{pred}} = 8$ 。本文采用文献[14]所设置的平均偏移误差(Average Displacement Error, ADE)、最终偏移误差(Final Displacement Error, FDE)作为描述模型预测准确性的评价指标。

平均偏移误差是指最终的预测结果与真实轨迹每个坐标点之间 L2 距离的平均值,其公式如下:

$$E_{\text{AD}} = \frac{1}{n} \sum_{i=1}^n \frac{1}{t_{\text{pred}}} \sum_{t=t_{\text{obs}}+1}^{t_{\text{obs}}+t_{\text{pred}}} \sqrt{(x_i^t - \hat{x}_i^t)^2 + (y_i^t - \hat{y}_i^t)^2 + (z_i^t - \hat{z}_i^t)^2} \quad (14)$$

式中: x_i^t, y_i^t 和 z_i^t 为第 i 条轨迹 t 时刻预测的经纬度以及高度; \hat{x}_i^t, \hat{y}_i^t 和 \hat{z}_i^t 为第 i 条轨迹 t 时刻的真实轨迹点。

最终偏移误差是指预测的最后一个点与真实轨迹最后一个点之间的 L2 距离,其公式如下:

$$t_{\text{total}} = t_{\text{obs}} + t_{\text{pred}} \quad (15)$$

$$E_{\text{FD}} = \frac{1}{n} \sum_{i=1}^n \sqrt{(x_i^{t_{\text{total}}} - \hat{x}_i^{t_{\text{total}}})^2 + (y_i^{t_{\text{total}}} - \hat{y}_i^{t_{\text{total}}})^2 + (z_i^{t_{\text{total}}} - \hat{z}_i^{t_{\text{total}}})^2} \quad (16)$$

在同样的实验条件下,FDE 与 ADE 的数值越低,代表模型的拟合效果越好,预测精度更高。

3.3 实验分析

本文对比了本文所提出模型与现有的其他民航轨迹预测模型的预测准确度。其中,Linear 模型与 LSTM 模型均采用文献[14]中所提及的实现方式,Linear 模型通过一个单层线性回归模型进行轨迹预测;LSTM 模型则使用不带池化机制的简单 LSTM 网络来进行预测。Shi-LSTM 模型^[11]将飞行轨迹与飞行计划作为输入特征同时输入到双层的 LSTM 网络进行训练预测,由于 ADS-B 数据集中并不包含飞行计划信息,所以在本文的实验中去除了该模型对飞行计划信息的处理。各种轨迹预测模型在测试集上的评价结果如表 2 所示。

表2 各种轨迹预测模型的结果表现

模型	FDE	ADE
Linear ^[14]	0.036 657	0.037 163
LSTM ^[14]	0.007 869	0.011 780
Shi-LSTM ^[11]	0.007 153	0.005 552
本文模型	0.007 312	0.003 904

结果表明本文所提出模型在 ADE 指标上明显优于其他模型,在 FDE 指标上与 Shi-LSTM 相当。这是由于本文所提出模型使用了生成对抗网络来训练模型,能够最大化学习到数据的分布规律,提高模型的拟合效果,并且在编码与解码的过程中,通过池化模块来提取了不同飞机之间的交互特征,提升了在多机交互的场景下,对数据特征的提取能力。而通过增加模型的复杂度,提高对于时序特征的提取能力,也可以一定程度上获得更强的复杂数据表征能力。

由于民航轨迹中包含三个维度的空间数据,其中的高度与经纬度具有明显不同的量纲和变化范围,因此当高度存在较大变化时,可能会影响到轨迹预测精度。为了更好地对飞机在不同飞行阶段的轨迹预测准确度进行评价,探究不同阶段数据对于模型拟合的影响,本文对飞机处于起飞、平飞、下降等不同阶段的轨迹预测准确度也进行了比较。

若轨迹 i 的第 j 轨迹点高度 $h_{i,j} < \alpha \times \max(h_i)$, 其中 $\max(h_i)$ 为轨迹 i 的最大高度,则认为飞机在该轨迹点处于起飞或下降阶段,否则为平飞阶段。在本文的实验过程中取 $\alpha = 0.7$,可以得到飞机在不同飞行阶段的轨迹预测评价结果如表 3 所示。

表3 模型在不同飞行阶段的预测效果

训练集		测试集		
		起飞下降	平飞	整体
起飞下降	ADE	0.035 913	—	0.043 900
	FDE	0.059 074	—	0.083 495
平飞	ADE	—	0.015 899	0.016 354
	FDE	—	0.045 612	0.043 635
整体	ADE	0.076 205	0.045 610	0.026 940
	FDE	0.156 737	0.091 657	0.056 104

观察表 3 中数据可以发现,当使用部分飞行阶段的轨迹作为测试集时,使用相同阶段的轨迹数据训练出来的模型表现效果最好,这表明相同阶段的轨迹数据具有相似的分布,而不同阶段的轨迹数据的分布则存在较大差异。在不同飞行阶段中,起飞下降阶段的

轨迹数据具有最复杂的变化模式,平飞阶段的轨迹数据变化较为简单。当使用飞机的完整轨迹作为测试集时,对起飞下降阶段和平飞阶段都进行了充分学习的模型,能够取得更好的预测结果。

图 5 给出了本文所提出模型在数据集上预测的实际效果。图 5(a)到图 5(d)是表现效果较好的情况,图 5(e)和图 5(f)预测的结果与真实结果之间存在一定差距。可以看出,无论飞机是处于起飞下降阶段还是平飞阶段,当飞机的飞行轨迹变化较为简单时,模型能够取得精准的预测效果,但是在轨迹趋势变化频繁的情况下,模型难以准确地描述轨迹的特征,说明该模型仍然缺少在复杂场景下对于轨迹的建模能力。

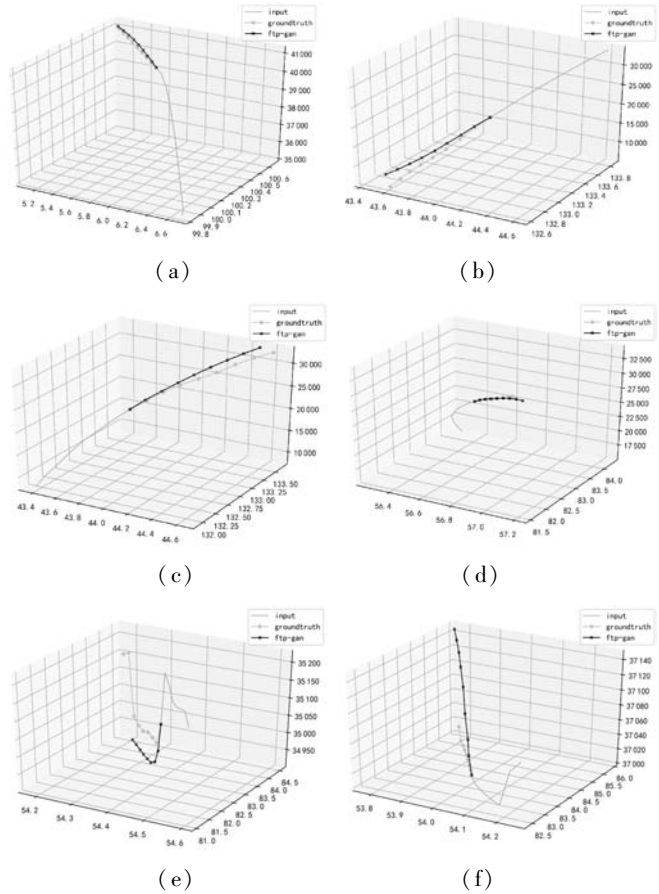


图5 轨迹预测效果

4 结 语

本文提出一种面向三维空间坐标的民航轨迹预测模型,实现对于三维空间中的民航轨迹预测。并针对民航轨迹数据所具有的时间采样不均匀、各个空间维度量纲不一致等问题,提出一种民航轨迹数据重采样方法。通过与现有的其他方法进行对比,实验表明,本文模型具有很好的准确性和鲁棒性。为了进一步提高民航轨迹预测方法的可用性,本文针对民航在飞行中

的不同阶段进行了实验对比分析,以揭示民航轨迹的数据分布特点。

后续工作会将空域结构、天气因素等其他对于飞行轨迹有重要影响的因素加入到模型中,进一步地提高预测的准确性,并且针对民航轨迹在各个飞行阶段的特点,研究具有自适应性的预测模型,从而提高模型对民航各个飞行阶段数据分布特征的学习能力。

参 考 文 献

- [1] 中华人民共和国交通运输部. 中国民航2019年12月份主要运输生产指标统计[EB/OL]. (2020-02-29)[2020-12-25]. <https://www.mot.gov.cn/tongjishuju/minhang/202003/P020200702602066548318.pdf>.
- [2] 郭运韬,朱衍波,黄智刚. 民用飞机航迹预测关键技术研究[J]. 中国民航大学学报,2007(1):20-24.
- [3] Tao Y, Faloutsos C, Papadias D, et al. Prediction and indexing of moving objects with unknown motion patterns[C]//2004 ACM SIGMOD International Conference on Management of Data,2004:611-622.
- [4] Mathew W, Raposo R, Martins B. Predicting future locations with hidden Markov models[C]//2012 ACM Conference on Ubiquitous Computing,2012:911-918.
- [5] Prevost C, Desbiens A, Gagnon E. Extended Kalman filter for state estimation and trajectory prediction of a moving object detected by an unmanned aerial vehicle[C]//2007 American Control Conference,2007:1805-1810.
- [6] Lecun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015,521:436-444.
- [7] Payeur P, Le-Huy H, Gosselin C. Trajectory prediction for moving objects using artificial neural networks[J]. IEEE Transactions on Industrial Electronics,1995,42(2):147-158.
- [8] Huang W, Song G, Hong H, et al. Deep architecture for traffic flow prediction: Deep belief networks with multitask learning[J]. IEEE Transactions on Intelligent Transportation Systems,2014,15(5):2191-2201.
- [9] Leelavathi M, Sahana D. An architecture of deep learning method to predict traffic flow in big data[J]. International Journal of Research in Engineering and Technology,2016,5(4):461-468.
- [10] Zaremba W, Sutskever I, Vinyals O. Recurrent neural network regularization[EB]. arXiv:1409.2329,2014.
- [11] Shi Z, Xu M, Pan Q, et al. LSTM-based flight trajectory prediction[C]//2018 International Joint Conference on Neural Networks,2018:1-8.
- [12] Liu Y, Hansen M. Predicting aircraft trajectories: A deep generative convolutional recurrent neural networks approach [EB]. arXiv:1812.11670,2018.
- [13] Alahi A, Goel K, Ramanathan V, et al. Social LSTM: Human trajectory prediction in crowded spaces[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition,2016:961-971.
- [14] Gupta A, Johnson J, Li F, et al. Social GAN: Socially acceptable trajectories with generative adversarial networks[C]//2018 IEEE Conference on Computer Vision and Pattern Recognition,2018:2255-2264.
- [15] Xin L, Wang P, Chan C, et al. Intention-aware long horizon trajectory prediction of surrounding vehicles using dual LSTM networks[C]//2018 21st International Conference on Intelligent Transportation Systems,2018:1441-1446.
- [16] Zyner A, Worrall S, Nebot E. A recurrent neural network solution for predicting driver intention at unsignalized intersections[J]. IEEE Robotics and Automation Letters,2018,3(3):1759-1764.
- [17] 季学武,费聪,何祥坤,等. 基于LSTM网络的驾驶意图识别及车辆轨迹预测[J]. 中国公路学报,2019,32(6):34-42.

(上接第24页)

- [6] Shiravi H, Shiravi A, Ghorbani A A. A survey of visualization systems for network security[J]. IEEE Transactions on Visualization & Computer Graphics, 2012,18(8):1313-1329.
- [7] 宋爱波,万雨桐,贡欢,等. 海量多维数据的存储与查询研究[J]. 计算机工程与应用,2016,52(13):25-31.
- [8] 冯贵兰,李正楠,周文刚. 大数据分析技术在网络领域中的研究综述[J]. 计算机科学,2019,46(6):1-20.
- [9] 周莹. 基于云计算的海量网络流量数据分析处理研究[J]. 电子测试,2017(19):128-129.
- [10] 徐承俊,朱国宾. 一种适应大数据处理要求的深度学习模型[J]. 计算机应用与软件,2021,38(1):33-40.
- [11] 陈锴. 基于多源异构传感器的网络安全态势感知系统设计[J]. 现代电子技术,2020,43(20):74-78.
- [12] 常利伟,田晓雄,张宇青,等. 基于多源异构数据融合的网络网络安全态势评估体系[J]. 智能系统学报,2021,16(1):38-47.
- [13] 孙卫喜. 用于网络安全态势预测的粒子群与支持向量机算法研究[J]. 计算机应用与软件,2019,36(6):308-316.
- [14] 杨宏宇,曾仁韵. 一种深度学习的网络安全态势评估方法[J]. 西安电子科技大学学报,2021,48(1):183-190.
- [15] 张志华. 基于渗透测试的网络安全漏洞实时侦测技术[J]. 科学技术与工程,2018,18(20):297-302.
- [16] 魏晴,吕良双,姚珊,等. 网络安全风险动态分析方法[J]. 华中科技大学学报(自然科学版),2012,40(S1):202-206.