

基于数据增强的自监督飞行航迹预测

王鹏宇, 台文鑫, 刘芳, 钟婷, 罗绪成, 周帆

引用本文

王鹏宇, 台文鑫, 刘芳, 钟婷, 罗绪成, 周帆. [基于数据增强的自监督飞行航迹预测](#) [J]. 计算机科学, 2023, 50(2): 130-137.

WANG Pengyu, TAI Wenxin, LIU Fang, ZHONG Ting, LUO Xucheng, ZHOU Fan. [Self-supervised Flight Trajectory Prediction Based on Data Augmentation](#) [J]. Computer Science, 2023, 50(2): 130-137.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[融合循环划分的张量指令生成优化](#)

Tensor Instruction Generation Optimization Fusing with Loop Partitioning
计算机科学, 2023, 50(2): 374-383. <https://doi.org/10.11896/jsjcx.220300147>

[基于人脸部件掩膜的自监督三维人脸重建](#)

Self-supervised 3D Face Reconstruction Based on Detailed Face Mask
计算机科学, 2023, 50(2): 214-220. <https://doi.org/10.11896/jsjcx.220600035>

[基于特征融合的小样本目标检测](#)

Few-shot Object Detection Based on Feature Fusion
计算机科学, 2023, 50(2): 209-213. <https://doi.org/10.11896/jsjcx.220500153>

[基于改进区域候选网络的场景文本检测](#)

Scene Text Detection with Improved Region Proposal Network
计算机科学, 2023, 50(2): 201-208. <https://doi.org/10.11896/jsjcx.211000191>

[基于深度学习的刚体位姿估计方法综述](#)

Survey of Rigid Object Pose Estimation Algorithms Based on Deep Learning
计算机科学, 2023, 50(2): 178-189. <https://doi.org/10.11896/jsjcx.211200164>

基于数据增强的自监督飞行航迹预测

王鹏宇¹ 台文鑫¹ 刘芳² 钟婷¹ 罗绪成¹ 周帆¹

¹ 电子科技大学信息与软件工程学院 成都 610054

² 中国民用航空飞行学院 四川 广汉 618307

(p. y. wang@std. uestc. edu. cn)

摘要 准确的飞行航迹预测可以帮助空中交通管理系统对潜在的危险提出预警,并有效地为安全出行提供指导。飞机飞行所处的大气情况复杂多变,飞行航迹受大气扰动、空中云层等外部因素的影响很大,使得飞行航迹预测问题十分复杂和困难。另外,由于某些飞行区域所在的地面环境恶劣,无法部署足够的信号基站,而某些飞行区域的飞行信号由多个信号基站采集组合而成,造成最终得到的飞行航迹数据存在稀疏和含噪等问题,进一步增加了飞行航迹预测的难度。文中提出了一种基于数据增强的自监督飞行航迹学习方法。此方法采用基于正则化的数据增强方式,扩充了稀疏的航迹数据集并处理了数据中包含的异常值,利用最大化互信息的方式进行自监督预训练,以挖掘飞行航迹中蕴含的运动模式和航行意图,采用一种带有蒸馏机制的多头自注意力模型作为基础模型,解除了循环神经网络长期依赖和无法并行计算的限制,并利用注意力蒸馏机制和生成式解码方式降低了模型的复杂度,加快了其训练和预测的速度。在飞行航迹数据集上的评测结果显示,此方法较目前预测表现最优的方法在纬度、经度和高度上的预测结果的均方根误差各减少了 20.8%,26.4%和 25.6%,极大地提高了预测准确性。

关键词: 飞行航迹预测;自监督学习;自注意力机制;深度学习

中图分类号 TP183

Self-supervised Flight Trajectory Prediction Based on Data Augmentation

WANG Pengyu¹, TAI Wenxin¹, LIU Fang², ZHONG Ting¹, LUO Xucheng¹ and ZHOU Fan¹

¹ School of Information and Software Engineering, University of Electronic Science and Technology of China, Chengdu 610054, China

² Civil Aviation Flight University of China, Guanghan, Sichuan 618307, China

Abstract Accurate flight trajectory predictions can help air traffic management systems make warnings for potential hazards and effectively provide guidance for safe travel. However, the atmospheric situation in which the planes flying is complicated and changeable. The flight track is affected by external factors such as atmospheric disturbance, the air cloud, making prediction difficult. In addition, due to the harsh ground environment where some flight areas are located, it is impossible to deploy enough signal base stations, while the flight signals in some flight areas are collected and combined by multiple signal base stations, resulting in sparse and noisy aircraft track data, which further increases the difficulty of flight track prediction. This paper proposes a technically enhanced self-supervision flight trajectory learning method. This method uses a regularization-based data enhancement mode to extend the sparse track data and process the abnormal values included in the dataset. It provides a self-supervised learning diagram by maximizing mutual information to dig the mobility pattern contained in the flight trajectory. The method employs a multi-head self-attention model with a distillation mechanism as a fundamental model to solve the long-term dependence problem of the recurrent neural network. In addition, the approach uses the distillation mechanism to reduce the complexity of the model and utilizes the generating decoding method to accelerate the speed of its training and prediction. The evaluation results on the flight trajectory dataset show that our method has a significant increase in the results of trajectory prediction compared with the state-of-the-art method that our approach reduces the root mean square error of the prediction results in latitude, longitude, and altitude by 20.8%, 26.4%, and 25.6%, respectively.

Keywords Flight trajectory prediction, Self-supervised learning, Self-attention, Deep learning

到稿日期:2021-12-01 返修日期:2022-08-03

基金项目:四川省自然科学基金(2022NSFSC0505, 2022NSFSC0956);四川省青年软件创新工程资助项目(2021023);四川省科技计划(2022YFSY0006, 2020YFG0053);国家自然科学基金(62176043, 62072077)

This work was supported by the Natural Science Foundation of Sichuan Province(2022NSFSC0505, 2022NSFSC0956), Sichuan Youth Software Innovation Project Funding Project(2021023), Sichuan Science and Technology Program(2022YFSY0006, 2020YFG0053) and National Natural Science Foundation of China(62176043, 62072077).

通信作者:钟婷(zhongting@uestc.edu.cn)

1 引言

近年来,随着航空技术的不断发展,各类飞行器得到了日渐广泛的应用,民用航空飞机作为现代人交通出行的重要手段,规模快速发展。此外,低空无人机、直升机等也在低空空域日益活跃,这些都使得空中的飞行环境更加复杂,给空中交通管理(Air Traffic Management, ATM)系统带来了巨大的负担。安排和调控不同飞机的飞行路线是一个复杂且困难的工程,其中包含许多子问题,如侦测和解决飞行器之间的路线冲突,安排不同航班的起降,监视飞行器异常行为(如低空飞行预警和航线偏离预警等),这些问题的有效解决都依赖于可靠准确的飞行航迹预测。

飞行航迹数据看似繁杂且随机,但这些数据含有其内在固有的规律,但难以描述和表达,尤其是飞机在爬升和下降阶段呈现出很强的非线性,使得这些规律无法用常见函数进行拟合与推算,而神经网络具有强大的学习能力,可以对复杂的飞行过程进行拟合,发掘其中蕴含的航行意图和转移模式,从而有效辅助空中交通管制员制定合理的飞机调配方案,减轻其工作负担,同时有利于保障空中交通安全,提高空中交通管理系统的能力。

预测已被广泛应用于交通管理,如飞行航迹预测、海上交通预测、车辆交通预测、交通流预测和行人轨迹预测。陆地交通或行人的轨迹预测方法受到已知的静态道路和兴趣点(Point-of-Interest, POI)的严格约束。而在飞行航迹预测中,飞行路线受地理因素、恶劣天气或人工操作等外部因素的影响很大,这使得已经得到广泛应用的陆地交通预测方法在复杂多变的空中交通背景下并不适用。

研究人员对飞行航迹预测问题进行了深入的研究,现有的飞行航迹预测方法可以分为状态估计方法、基于空气动力学模型的方法以及数据驱动方法。状态估计方法将飞行航迹预测问题视为一种追踪问题,使用卡尔曼滤波器等方法预测未来的飞行航迹^[1-3];基于空气动力学模型的方法可被视为一种模拟飞机可能的运动轨迹的物理模型^[4-5],由于所依赖的运动学参数大多未知或部分可知,因此预测效果大多不太理想。

随着各类信号传感器和地面基地的普及,越来越多的飞行航迹数据可以被人们采集,这些飞行航迹数据多为广播式自动相关监视系统(Automatic Dependent Surveillance-broadcast, ADS-B)数据,其中每个航迹点包含经度、纬度、高度和方位角等属性。先进且分布密集的传感器可以将飞行航迹表征为时间序列,使得数据驱动的航迹预测方法变得可行。但由于基站部署不均、外部通信干扰等问题,采集到的数据存在部分片段稀疏和包含异常值的现象,这些数据问题限制了数据驱动的深度学习方法进一步提高航迹预测效果。研究人员提出了许多针对短程、中程的数据驱动的轨迹预测技术。基于马尔可夫模型及其变体^[6-8]的方法按顺序对航迹进行建模,然而这些方法利用独热编码表示航迹点,对数据的表示能力有限。由于循环神经网络(Recurrent Neural Network, RNN)在处理序列数据上的优异表现,研究人员开始使用 RNN 及其变体来解决飞行航迹预测问题^[9-11],这些方法利用嵌入向量表示航迹点,能够更好地表示航迹点所包含的多种属性特征,但 RNN 存在的长期依赖问题,使得它们无法有效处理较长

的飞行航迹,同时 RNN 难以训练和无法并行计算的特点,使得这些方法都十分耗时。

为了解决上述问题,本文将近期在计算机视觉^[12]和自然语言处理^[13]领域取得重大成功的自监督方法应用于飞行航迹预测问题,提出了一种基于互信息最大化的自监督飞行航迹预测训练方式,并设计了一种带有蒸馏机制的多头自注意力^[14]模型。本文的主要贡献如下:

(1)设计了一种飞行航迹数据增强方式,可以对飞行航迹数据进行有效的增强,解决了其部分片段稀疏和包含异常值的问题。

(2)将自监督学习范式和飞行航迹预测相结合,设计了一种基于互信息最大化的自监督飞行航迹预测训练方式,有效地挖掘了历史航迹中蕴含的航行意图和转移模式。

(3)针对航迹预测问题,设计了一种带有蒸馏机制的多头注意力模型,解决了基于 RNN 的飞行航迹预测模型的长期依赖问题。使用自注意力蒸馏机制减小模型的时间和空间复杂度,并采用生成式解码方式加快了训练和预测的速度。

(4)将所提模型与多个性能出色的航迹预测模型在真实的飞行航迹数据集上进行实验对比,证明了本文模型优于几种先进的飞行航迹预测方法,并通过消融实验验证了所设计的自监督方法在提升预测性能上的重要作用。

2 相关工作

2.1 飞行航迹预测

随着各类信号传感器和地面基地的普及,越来越多的飞行航迹数据被人们采集,使得数据驱动的航迹预测方法变得可行。这些方法利用大量的历史航迹数据训练飞行航迹预测器,而不再使用飞机的空气动力学参数。作为最早使用神经网络解决飞行航迹预测的工作,Le 等^[15]使用历史航迹数据训练反向传播神经网络,利用训练好的神经网络进行航迹预测。然而,因为所采用的神经网络层数过浅(只含有一个中间层),以及所采用的航迹数据集太小,此方法的效果并不令人满意。Tastambekov 等^[16]提出了局部线性泛函回归方法来利用历史雷达航迹数据进行短程到中程的飞机航迹预测。Wang 等^[17]使用航迹聚类技术结合神经网络来解决短程的航迹预测问题,但由于神经网络结构仍过于简单,无法捕获各类航班的复杂的移动模式。Hernandez 等^[18]将航迹预测问题定义为回归问题,并尝试利用集成机器学习方法解决此问题。Barratt 等^[19]使用聚类方法从基于雷达测量的历史航迹数据集中挖掘飞行模式,并利用两种概率生成模型分别对飞机的起飞和降落过程进行预测。Shi 等^[9]提出了基于长短期记忆网络(Long Short-Term Memory network, LSTM)的飞行航迹预测方法,解决了基于 RNN 的方法中出现的梯度消失问题,并使用滑动窗口保持航迹序列的连续性,挖掘窗口内相邻航迹点的动态依赖性。Zeng 等^[10]提出了一种序列到序列的深度长短期记忆网络模型,由编码器将历史航迹数据编码,解码器将编码器的输出做解码处理,得到预测的航迹。Ma 等^[11]将卷积神经网络与长短期记忆网络相结合,使用一维卷积提取飞行航迹中蕴含的空间信息。

还有一些研究者将不同类型的预测方法进行组合,使用混合方法进行航迹预测。Alligier 等^[20-21]从历史的航迹信息

中学习飞机的质量、推力等参数,提高了飞机爬升阶段的飞机航迹预测准确性,并研究了 11 种常用的飞机类型和一个相当大的 ADS-B 数据集。Guan 等^[22]首先利用机器学习方法在历史航迹数据集上训练一个初始的预测模型,然后将当前的状态信息和初始预测模型的输出与一个物理模型整合,最终输出航迹预测结果。

由于通信技术的限制,现阶段所采集到的 ADS-B 数据往往含噪和过于稀疏,并且当前的飞行航迹预测方法不能很好地捕捉这些飞行航迹数据中蕴含的航行意图和转移模式,为此本文设计了一种飞行航迹增强方法,对采集到的飞行航迹数据进行去噪和扩充,并提出了一种基于互信息最大化的自监督航迹学习方式,从而挖掘历史航迹中蕴含的航行意图和转移模式。

2.2 互信息最大化与自监督学习

互信息(Mutual Information, MI)是一种基于香农交叉熵的衡量随机变量之间相关性的方法^[23]。给定两个随机变量 X 和 Y ,它们之间的互信息可以理解为知道 X 可以减少多少 Y 的不确定性,反之亦然。

$$I(X, Y) = H(X) - H(X|Y) = H(Y) - H(Y|X) \quad (1)$$

从概率的角度来看,互信息是由一个联合分布和两个随机变量的边缘分布的乘积得到的,可以被定义为:

$$I(X, Y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \log \left(\frac{p(x, y)}{p(x)p(y)} \right) \quad (2)$$

近年来,基于对比的自监督学习在学术界和工业界受到了广泛关注,其核心思想是在大规模数据上构造辅助任务,并对模型进行预训练,通过度量正负样本之间的距离,在没有标签监督的情况下实现自我监督。一般的自监督学习框架是直接根据原始数据中蕴含的相关关系构造训练标签,并利用这些关系和标签训练模型。通过自监督学习获得的相关信息可以方便有效地帮助下游任务。这种自监督范式免除了人工标注标签的麻烦,同时增强了模型的泛化性和鲁棒性。

在计算机视觉领域,自监督学习方式已经被广泛应用并取得了喜人的效果^[12, 24]。在自然语言处理领域,模型通过自监督方式预先学习有效的单词表示,从而有效提高下游任务(如机器阅读理解^[25]和自然语言理解^[26])的表现。

本文采用基于对比的自监督学习方法^[27],通常这种基于对比的方法由锚数据、正样本和负样本这 3 个主要元素构成。在所学习到的表示所处的隐式空间中,锚数据 x 和正样本 x^+ 之间的距离应该远远小于锚数据 x 与负样本 x^- 之间的距离。

$$f_{\theta}(x, x^+) \gg f_{\theta}(x, x^-) \quad (3)$$

其中, $f_{\theta}(\cdot, \cdot)$ 表示某种相似度函数,例如点乘或余弦相似度。

对于单个负样本的情况,目标是最大化下面的表达式:

$$\max \left[\frac{f_{\theta}(x, x^+)}{f_{\theta}(x, x^+) + f_{\theta}(x, x^-)} \right] \quad (4)$$

大多数情况下,负样本都不止一个, Ma 等^[28]将优化目标推广到多个负样本的情况,相应的损失函数如下:

$$\mathcal{L} = -E_{(x, x^+)} [f_{\theta}(x, x^+) - \log \sum_{x_i \in N_{\text{neg}}} \exp(f_{\theta}(x, x_i))] \quad (5)$$

其中, N_{neg} 表示负样本集合。

3 飞行航迹预测的基本概念

本文的目标是学习一个给定飞机先前飞行状态信息,来

预测未来飞行航迹的数据驱动的深度神经网络模型。具体地,假设飞机的状态包括 K 种属性, $f^{(t)} = (A_1^{(t)}, A_2^{(t)}, \dots, A_K^{(t)}) \in \mathbb{R}^K$ 表示 t 时刻的飞行状态向量,使用 $Y^{(t)} = (y_1^{(t)}, y_2^{(t)}, y_3^{(t)}) \in \mathbb{R}^3$ 表示 t 时刻飞机的三维位置向量(经度、纬度、高度)。本文模型学习一个函数 $G(\cdot)$,将长度为 T 的历史航迹状态序列隐射到一个长度为 S 的未来三维位置序列: $[f^{(1)}, \dots, f^{(T)}] \xrightarrow{G(\cdot)} [Y^{(T+1)}, \dots, Y^{(T+S)}]$ 。为了简化表示,本文在后续的符号描述中省略了时间上标。

本文方法首先对原始飞行航迹数据进行数据增强,之后利用航迹数据增强得到的数据进行自监督航迹预训练。预训练过程中通过航迹数据内部的上下文关联构造不依赖于外部标签的辅助任务,并利用互信息最大化的方式学习隐藏在航迹内部的转移模式和航行意图。预训练过程学习到的含有飞行移动模式信息的模型参数值将作为模型微调阶段的参数初始值。模型微调阶段在未经过数据增强的原始航迹数据上进行参数的更新,得到最终的飞行航迹预测模型。预训练与微调阶段均采用蒸馏多头注意力模型。

本文方法的整体流程如图 1 所示。

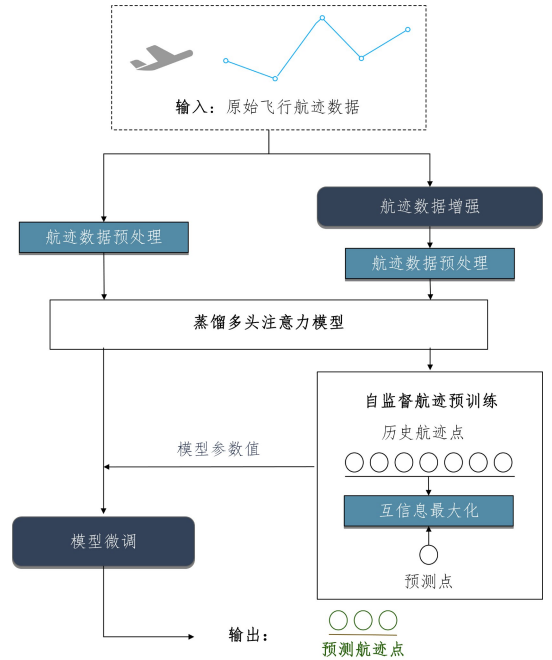


图 1 自监督航迹学习模型总览

Fig. 1 Overview of self-supervised flight trajectory learning model

4 数据处理

4.1 数据准备

本文使用 VariFlight 公司提供的 ADS-B 数据¹⁾,采集了中国成都双流机场(CTU)2020 年 12 月 1 日到 2021 年 3 月 31 日所有起降飞机的监控数据,共 4 837 条。数据包含飞行航迹点的时间戳、经度、纬度、高度、速度、方位角 6 种属性(即 $K=6$)。

4.2 航迹数据增强

为了扩大飞行信号的监控范围,同一区域内往往建立了多个 ADS-B 地面基站来采集信号,这导致了信号数据的冲突

¹⁾ <http://flightadsb.variflight.com/tracker>

和冗余,同时信号在传播过程中不可避免地会受到干扰,从而导致直接得到的 ADS-B 航迹数据存在各种问题,如包含异常值(噪声)、航迹点的时间间隔长度不相等。同时,由于 ADS-B 地面基站的个数和分布受到各个区域的实地环境的限制,很多地理环境相对恶劣的区域的 ADS-B 信号无法有效采集,使得部分航迹数据缺失航行片段和航迹数据过于稀疏。

为了进行更加有效的模型训练,需要高质量的航迹数据,因此有必要进行航迹数据增强操作。增强后的航迹数据应具备如下特征:1)具有等长的时间间隔;2)拥有更高的时间分辨率;3)剔除异常的离群点。由于飞机空间位置和速度随时间非线性变化,无法用简单的线性公式表征,本文使用了一种正则化方法进行航迹数据增强,来满足以上的增强目标。

$F_0 \in \mathbb{R}^{D \times K}$ 表示含有 D 个时间间隔不等的航迹点的原始航迹, $F \in \mathbb{R}^{N \times K}$ 表示该原始航迹经过航迹增强操作后得到的包含有 N 个等时间间隔的航迹点的新航迹。航迹数据增强的目标就是通过下面的线性方程将原始航迹进行转化。

$$F_0 = \mathbf{B}F + \mathbf{N}_e \quad (6)$$

其中, $\mathbf{B} \in \mathbb{R}^{D \times N}$ 表示一个采样矩阵, \mathbf{N}_e 表示随机噪声矩阵。

但是这是一个不适定问题,无法通过式(6)直接求解。为此,本文将已经在信号处理领域成功应用的正则化方法加以改进,将其应用于航迹数据增强任务中。该方法的主要思想

是在增强的数据中引入先验知识,求解下面的最优化问题。

$$F^* = \text{Arg Min}_F (\| \mathbf{B}F - F_0 \|_F^2 + \lambda \rho(F)) \quad (7)$$

其中, $\| \cdot \|_F$ 表示矩阵的弗罗贝尼乌斯范数, $\| \mathbf{B}F - F_0 \|_F^2$ 表示合适度, $\rho(\cdot)$ 和 λ 分别表示正则化代价函数和正则化参数。式(7)右边的第一项鼓励增强后的航迹点接近原始航迹点;第二项鼓励得到平滑的航迹点,有助于降噪, λ 用于平衡这两项。对于代价函数 $\rho(\cdot)$,为了简单起见,本文选择了在信号处理领域被广泛使用的吉洪诺夫代价函数构成正则项:

$$\rho(F) = \| \mathbf{I}F \|_F^2 \quad (8)$$

其中, \mathbf{I} 代表吉洪诺夫矩阵。噪声点往往含有高频率的能量,通过正则化过程可以将它们消除,得到最终不包含离群点的飞行航迹。将式(8)中的正则项代入式(7),得到航迹数据增强过程的优化函数,即最小化如下函数:

$$h(F) = \| \mathbf{B}F - F_0 \|_F^2 + \lambda \| \mathbf{I}F \|_F^2 \quad (9)$$

该函数为凸二次函数,可以求得其解析解,从而得到等时间间隔的新航迹 F 。

通过上述过程,得到了经过增强的飞行航迹数据,这些数据将被应用在之后的自监督航迹预训练过程中。图 2 三维可视化了原始航迹与相应的增强航迹,清楚地展现了航迹增强的效果。

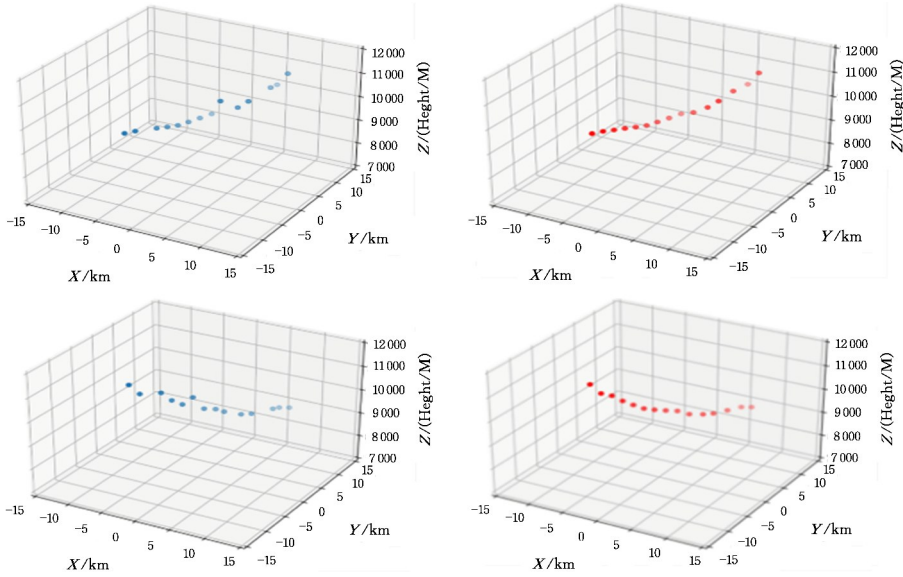


图 2 航迹数据增强效果示意图

Fig. 2 Illustration of flight data augmentation

4.3 航迹数据预处理

4.3.1 航迹数据归一化

飞行航迹数据点中所包含的 6 种属性特征虽然都用数值表示,但存在范围乃至量级的差距,在送入神经网络前需要进行归一化。本文采用最大最小归一化对每种特征进行处理。最大最小归一化是一种线性转化方法,假设原始特征为 a ,数据集中 a 的候选集合为 C^a ,经过归一化后的特征表示为 A ,则:

$$A = (a - C_{\min}^a) / (C_{\max}^a - C_{\min}^a) \quad (10)$$

其中, C_{\max}^a 和 C_{\min}^a 分别代表 C^a 中的最大值和最小值。归一化后的特征值都被放缩到 $[0, 1]$ 。

4.3.2 航迹时间编码

不同于循环神经网络的自身结构蕴含时序信息,自注意力机制需要在输入的向量表示中显式地提供时序信息。因此,本文在航迹表示上加入了时间编码,以使模型能辨别不同时刻的输入。为了更好地对飞行航迹数据进行表示,本文使用了正余弦函数处理的方式,让时间编码含有相对位置关系,对于一个归一化处理后的航迹序列 $F = (f_1, f_2, \dots, f_{L_x}) \in \mathbb{R}^{L_x \times K}$,其每个航迹点的时间编码通过如下方式得到:

$$\begin{aligned} PE(i, 2j) &= \sin\left(\frac{i}{(2L_x)^{2j/d}}\right) \\ PE(i, 2j+1) &= \cos\left(\frac{i}{(2L_x)^{2j/d}}\right) \end{aligned} \quad (11)$$

其中, d 表示输入模型的序列表示的嵌入维度, L_x 表示输入序列的长度, i 表示当前输入航迹点在输入航迹序列中的位置, $i \in \{1, \dots, L_x\}$, $j \in \{1, \dots, \lfloor d/2 \rfloor\}$ 。如式(11)所示, 每个航迹点分别用正余弦函数对时间编码矩阵第二维的偶数和奇数位置做处理后, 得到包含相对位置关系的时间编码 $PE_i \in \mathbb{R}^{K \times d}$ 。

具体地, 对于单个航迹点, 最终输入模型的表示向量如下:

$$\mathbf{x} = \mathbf{u}_i + PE_i \quad (12)$$

其中, \mathbf{u}_i 表示为了对齐向量维度而经过一维卷积处理的 f_i , $\mathbf{x} \in \mathbb{R}^{K \times d}$, 整个航迹序列 F 的输入表示为 $X \in \mathbb{R}^{L_x \times K \times d}$ 。

5 自监督航迹预训练

本节将具体介绍所采用的蒸馏多头注意力模型结构和自监督预训练方法。

5.1 蒸馏多头注意力模型

本文摒弃了先前航迹预测方法经常采用的循环神经网络, 设计了一种新颖的端到端蒸馏多头自注意力模型, 利用自注意力机制提取航迹上下文中蕴含的移动模式信息, 并加入蒸馏操作以捕捉自注意力中关键的部分, 减小模型参数。在模型的输出阶段, 不同于以往方法所采用的逐步动态解码生成的方式, 采用生成式解码器一次性输出多步预测结果, 提高了模型的预测速度。模型的基本结构如图3所示, 主要由编码器与解码器两大部分组成。编码器由多头自注意力模块和蒸馏模块交替堆叠而成; 解码器由多头掩码注意力模块和多头自注意力模块组成。下面将分别介绍基础模型的编码和解码以及自监督航迹预训练的过程。

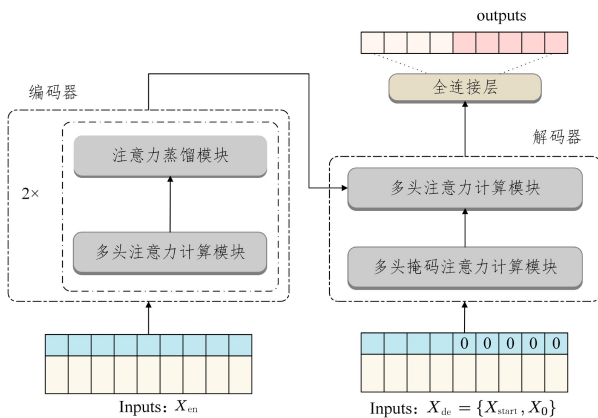


图3 蒸馏多头注意力模型结构

Fig. 3 Architecture of multi-head attention model with distillation mechanism

5.1.1 编码过程

编码过程将处理好的航迹表示送入带有蒸馏操作的多头处理模块进行多次迭代处理, 即编码器的输入 $X_{en} = X$, 以产生供解码器使用的中间向量。

多头注意力计算模块由多个自注意力模块组合而成。注意力模块首先将输入的航迹序列表示 X 与 3 个权值矩阵相乘得到自注意力计算中关键的 3 个部分: 查询 Q 、键 K 以及值 V 。对于第 i 个自注意力模块:

$$Q_i = Q_i^Q X \quad (13)$$

$$K_i = W_i^K X, V_i = W_i^V X \quad (13)$$

自注意力模块中注意力分数的计算采用经典的放缩点积计算方式:

$$Attention(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (14)$$

其中, d_k 为缩放因子。因此, 可以得到第 i 个自注意力模块的注意力分布向量 \mathbf{a}_i :

$$\mathbf{a}_i = Attention(Q_i, K_i, V_i) \quad (15)$$

多头注意力计算模块的注意力分布向量 \mathbf{a} 由其中每个自注意力计算模块的注意力分布向量拼接而成:

$$\mathbf{a} = Concat(\mathbf{a}_1, \dots, \mathbf{a}_n) \quad (16)$$

其中, n 表示多头注意力计算模块中包含的自注意力计算模块的个数, 在本文模型中 $n=6$ 。再将得到的多头注意力分布向量与一个参数 W 矩阵相乘, 就得到多头注意力模块输出的特征矩阵 Z :

$$Z = aW \quad (17)$$

利用多头注意力, 本文模型可以同时从多个航迹表示子空间中提取航迹中所蕴涵的航行意图和转移模式。但多头注意力中包含了多个自注意力模块, 引入了更多的参数, 模型的空间复杂度和时间复杂度都将大大提高, 这将导致模型占用的内存过大和训练变慢。为此, 本文引入了蒸馏机制来提取关键的自注意力参数, 以降低模型复杂度。第 j 层到第 $j+1$ 层的蒸馏操作如下:

$$X_{j+1} = MaxPool(RELU(Conv1d([X_j]))) \quad (18)$$

其中, X_j 表示自注意力计算中第 j 层的输入, $[\cdot]$ 表示自注意力模块的处理, $Conv1d$ 表示一维卷积操作(卷积核宽度为 4), $MaxPool$ 代表最大池化下采样操作(池化窗口大小为 2)。经过蒸馏操作处理后, 编码过程的时间和空间复杂度由原来的 $O(L^2)$ 减小为 $O(L \log L)$ 。

5.1.2 解码过程

解码过程采用经典的解码器结构^[14]: 一个多头掩码注意力模块紧接一个多头注意力模块。与编码器不同, 为了避免自回归造成的信息左流, 解码器解码时需要将目标序列的信息用掩码掩盖, 并在进行注意力计算时需要将目标序列的点积计算结果设置为负无穷。在进行解码过程前选择一段目标序列之前的已知序列作为起始令牌 X_{token} , 并将其与掩码向量 X_0 拼接得到解码器的输入 X_{de} 。解码器的输入形式如下:

$$X_{de} = Concat(X_{token}, X_0) \in \mathbb{R}^{(L_{token} + L_y) \times K \times d} \quad (19)$$

其中, $X_{token} \in \mathbb{R}^{L_{token} \times K \times d}$ 表示起始标识(由目标序列的之前 M 个航迹点的输入表示拼接而成), $X_0 \in \mathbb{R}^{L_y \times K \times d}$ 是目标序列的占位符(即表示待预测的位置), 设置为 0, L_{token} 和 L_y 分别表示起始标识和目标序列的长度。

特别地, 在输出最后的预测结果时, 本文模型没有使用传统编码器-解码器结构中采用的动态解码方式, 而是采用了生成式的解码方式, 一次性输出多步预测结果, 这样大大提高了模型的预测速度。

另外, 由于航迹预测要同时预测飞机的经度、纬度和高度, 为一种多变量预测问题, 因此本文模型在解码器后紧跟

一个全连接层,将解码结果转化为3个变量的预测结果。

5.2 互信息最大化航迹自监督学习

对于一段历史航迹 $F_{\leq t} = \{f_1, f_2, \dots, f_t\}$, 输入本文模型, 经过编码器编码后得到的中间隐状态为 h_t , h_t 蕴含了编码器学习到的飞行航迹转移模式和航行意图信息, 经过解码器处理后可以预测未来 M 步的飞机航迹 $F_{> t} = \{f_{t+1}, f_{t+2}, \dots, f_{t+M}\}$ 。为了得到更好的预测结果, 本文最大化 h_t 和 $F_{> t}$ 之间的互信息, 从概率角度可形式化为:

$$I(h_t, F_{> t}) = \sum p(h_t, F_{> t}) \log(p(F_{> t} | h_t) - p(F_{> t})) \quad (20)$$

对于每个预测的航迹点 \hat{f}_{t+i} , 本文将该位置对应的真实航迹点 f_{t+i} 作为正样本, 从该航迹的其他航迹点中随机选取 J 个航迹点 \tilde{f}_{t+i} 作为负样本。具体地, 在对比过程中选用的损失函数为 InfoNCE 损失函数。

$$\mathcal{L}_{\text{CL}} = - \sum_{i=1}^M \frac{S(\hat{f}_{t+i}, f_{t+i})}{S(\hat{f}_{t+i}, f_{t+i}) + \sum_{j=1}^J S(\hat{f}_{t+i}, \tilde{f}_{t+i})} \quad (21)$$

其中, $S(\cdot, \cdot)$ 表示相似度衡量函数, 本文采用 sigmoid 函数作为相似度衡量函数。在具体实现中利用式(21)分别在经度、纬度和高度3个变量上进行处理。

6 模型微调

在经过自监督航迹预训练后, 本文模型将所得到的模型参数作为初始值, 在原始的飞行航迹数据集上进行模型微调, 使所得模型能够更好地解决原问题。微调阶段的损失函数通过计算预测结果与真实值的均方根误差得到。假设待预测的飞行航迹 F 包含 n 个航迹点, 其微调阶段的损失函数如下:

$$\mathcal{L}_{\text{fine-tune}} = \left[\frac{1}{n} \sum_{i=1}^n (|f_i - \hat{f}_i|^2) \right]^{\frac{1}{2}} \quad (22)$$

根据损失函数计算损失值, 并利用梯度的反向传播更新模型参数得到最终的模型。之后, 本文利用训练好的模型在测试集上检验本文模型的航迹预测结果。

7 实验与结果

7.1 实验设置

本文模型采用 python 语言实现, 具体版本为 3.8.5, 深度神经网络基于 pytorch 平台实现, 具体版本为 1.5.1。深度神经网络的学习率初始值设置为 0.1, 并采用指数衰减对学习率进行调节, 衰减系数为 0.9。数据集采用 8:1:1 的比例划分为训练集、验证集和测试集, 批尺寸设置为 128。使用 Adam 优化器对模型参数进行优化, 丢弃率设置为 0.2。所有的训练和测试过程都使用一块英伟达 GTX2070 进行。

7.2 基准方法

(1)MM^[1]:一种使用马尔可夫链模拟时序过程的预测模型。

(2)LSTM^[9]:一种基于长短期记忆网络, 并利用滑动窗口保持转移模式连续性的模型。

(3)SS-DLSTM^[10]:一种使用了轨迹重构技术的序列到序列的长短期记忆网络模型。

(4)CNN-LSTM^[11]:一种将卷积神经网络与长短期记忆网络相结合的深度学习模型。

(5)SSFL:本文提出的自监督航迹学习模型。

(6)SSFL-A:在 SSFL 的模型中去除数据增强和自监督对比学习过程, 即仅使用基本模型在原始数据集上进行监督学习。

7.3 评价指标

本文使用平均绝对误差 (Mean Absolute Error, MAE)、平均相对误差 (Mean Relative Error, MRE) 和均方根误差 (Root Mean Square Error, RMSE) 3 种评价指标来衡量模型的预测结果。具体地, 对于一条包含 n 个航迹点的飞行航迹 F 而言, 3 种评价指标的计算式如下:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |f_i - \hat{f}_i| \quad (23)$$

$$\text{MRE} = \frac{1}{n} \sum_{i=1}^n \frac{|f_i - \hat{f}_i|}{f_i} \quad (24)$$

$$\text{RMSE} = \left[\frac{1}{n} \sum_{i=1}^n (|f_i - \hat{f}_i|^2) \right]^{\frac{1}{2}} \quad (25)$$

其中, f_i 是真实值, \hat{f}_i 是预测值。

7.4 评价分析

从表 1 可以看出, 在纬度、经度和高度 3 个维度上, 3 项评价指标的趋势基本一致。融合模型 SS-DLSTM 与 CNN-LSTM 的预测效果好于 MM 和 LSTM, CNN-LSTM 的预测能力比 SS-DLSTM 略强。本文的 SSFL 模型在经度、纬度和高度 3 个维度上的预测效果都要远远优于其他基线模型, 比基线模型中预测效果最好的 CNN-LSTM 在纬度、经度和高度上的均方根误差各减少了 20.8%, 26.4% 和 25.6%, 这证明了本文提出的自监督航迹预测模型的有效性和优异性。基于长短期记忆网络的模型的预测效果优于基于马尔可夫的模型, 表明了长短期记忆网络在处理序列数据上的有效性。SSFL-A 模型的预测效果逊色于 SSFL 模型, 同时优于基于长短期记忆网络的模型, 表明了本文提出的数据增强方法和自监督航迹学习范式的有效性, 同时也说明了所设计的蒸馏多头注意力模型比长短期记忆网络在飞行航迹预测问题上更加适用。结合了卷积神经网络的长短期记忆网络模型比其他长短期记忆网络模型表现更好, 证明了卷积神经网络的特征抽取能力。

表 1 实验结果

Table 1 Experimental results

Methods	MAE			MRE			RMSE		
	Lat	Lon	Hgt	Lat	Lon	Hgt	Lat	Lon	Hgt
MM	0.1232	0.1109	176.8531	0.0079	0.0012	0.0566	0.4861	0.4961	289.4502
LSTM	0.1096	0.1025	138.5267	0.0070	0.0008	0.0479	0.4094	0.3988	251.1033
SS-DLSTM	0.0981	0.0974	114.7960	0.0063	0.0007	0.0436	0.3877	0.3679	213.3246
CNN-LSTM	0.0978	0.0953	107.8511	0.0062	0.0006	0.0434	0.3769	0.3463	210.0356
SSFL-A	0.0849	0.0735	93.0728	0.0057	0.0005	0.0417	0.3164	0.3005	189.4630
SSFL	0.0718	0.0542	68.4796	0.0049	0.0005	0.0390	0.2984	0.2547	156.1542

7.5 重要参数对模型的影响(参数敏感性分析)

为了探究批尺寸对自监督学习效果的影响^[12],本文在不同的批尺寸下,对不同长度的输入序列进行了实验,结果如图4所示。

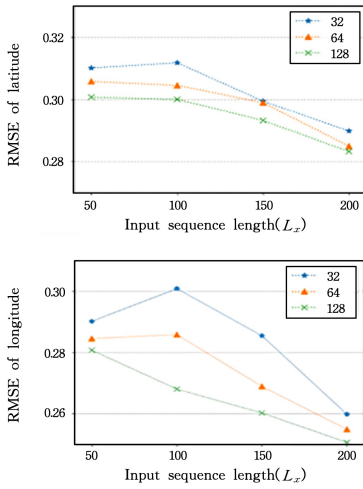


图4 批尺寸对模型的影响

Fig. 4 Influence of batchsize on model

在预测较短的航迹时,初始输入序列长度的增加会导致预测效果的退化,而在使用较大的批尺寸时这种现象会消失,可以证明增大批尺寸可以增强模型的稳定性。输入序列的长度越长,效果越好,越长的序列,其中蕴含的信息就越多,这说明本文采用的基于互信息最大化的自监督方法可以有效地提取航迹数据中隐藏的意图信息和转移模式。

7.6 时间性能比较

与传统的基于监督学习的方法相比,基于自监督学习的方法由于要针对额外设计的辅助任务进行预训练,因此往往要在模型训练上花费更多的时间。针对自监督学习这一不足,本文在基础模型中引入了蒸馏机制,缩短了模型的时间并降低了空间复杂度,并采用生成式的解码方式加快了预测速度。图5给出了本文模型与其他基线模型的时效对比。可以明显地看出,本文模型在时效上要优于其他基线模型,并且随着输入序列长度的增加,这一优势愈发明显,证明了所设计的提高时间效率的方法的有效性。




图5 各模型的时间性能对比

Fig. 5 Time efficiency comparison of each model

结束语 本文提出了一种基于数据增强的自监督飞行航迹学习方法。此方法采用基于正则化的数据增强方式,扩充了稀疏的航迹数据集并处理了数据中包含的异常值,利用最大化互信息的方式挖掘飞行航迹中蕴含的转移模式,采用

带有蒸馏机制的多头注意力模型作为框架,解除了神经网络长期依赖和无法并行计算的限制,并利用注意力蒸馏机制和生成式解码方式降低了模型的复杂度,加快了其训练和预测的速度。通过大量的实验证明了本文方法的可行性和有效性。

在未来的工作中,将考虑进一步细化自监督航迹学习中互信息最大化的方式,使用多层次、多粒度的互信息学习方式,如航迹序列到航迹序列、航迹点到航迹点内部属性等。

参考文献

- [1] CHATTERJI G. Short-term trajectory prediction methods[C]// Guidance, Navigation, and Control Conference and Exhibit, 1999:4233.
- [2] AVANZINI G. Frenet-based algorithm for trajectory prediction[J]. Journal of Guidance, Control, and Dynamics, 2004, 27(1): 127-135.
- [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, LECCHINI A. Model based aircraft trajectory prediction during takeoff[C]// AIAA Guidance, Navigation, and Control Conference and Exhibit, 2006.
- [5] SCHUSTER W. Trajectory prediction for future air traffic management-complex manoeuvres and taxiing[J]. The Aeronautical Journal, 2015, 119(1212): 121-143.
- [6] YUAN C, LI D, XI Y. Campus trajectory forecast based on human activity cycle and Markov method[C]// 2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems(CYBER). IEEE, 2015: 941-946.
- [7] WANG B, HU Y, SHOU G, et al. Trajectory prediction in campus based on Markov chains[C]// International Conference on Big Data Computing and Communications. Cham: Springer, 2016: 145-154.
- [8] AWAD M A, KHALIL I. Prediction of user's web-browsing behavior: Application of markov model[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 2012, 42(4): 1131-1142.
- [9] SHI Z, XU M, PAN Q, et al. LSTM-based flight trajectory prediction[C]// 2018 International Joint Conference on Neural Networks(IJCNN). IEEE, 2018: 1-8.
- [10] ZENG W, QUAN Z, ZHAO Z, et al. A deep learning approach for aircraft trajectory prediction in terminal airspace[J]. IEEE Access, 2020, 8: 151250-151266.
- [11] MA L, TIAN S. A hybrid CNN-LSTM model for aircraft 4D trajectory prediction[J]. IEEE Access, 2020, 8: 134668-134680.
- [12] CHEN T, KORNBLITH S, NOROUZI M, et al. A simple framework for contrastive learning of visual representations[C]// International Conference on Machine Learning. PMLR, 2020: 1597-1607.
- [13] WU J, WANG X, WANG W Y. Self-supervised dialogue learning[J]. arXiv:1907.00448, 2019.

- [14] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]// Advances in Neural Information Processing Systems, 2017; 5998-6008.
- [15] LE FABLEC Y, ALLIOT J M. Using Neural Networks to Predict Aircraft Trajectories[C]// IC-AI, 1999; 524-529.
- [16] TASTAMBEKOV K, PUECHMOREL S, DELAHAYE D, et al. Aircraft trajectory forecasting using local functional regression in Sobolev space[J]. Transportation Research Part C: Emerging Technologies, 2014, 39: 1-22.
- [17] WANG Z, LIANG M, DELAHAYE D. Short-term 4d trajectory prediction using machine learning methods[C]// Proceedings and Digests, 2017; 1-10.
- [18] HERNÁNDEZ A M, MAGAÑA E J C, BERNA A G. Data-driven aircraft trajectory predictions using ensemble meta-estimators[C]// 2018 IEEE/AIAA 37th Digital Avionics Systems Conference(DASC). IEEE, 2018; 1-10.
- [19] BARRATT S T, KOCHENDERFER M J, BOYD S P. Learning probabilistic trajectory models of aircraft in terminal airspace from position data[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 20(9): 3536-3545.
- [20] ALLIGIER R, GIANAZZA D, DURAND N. Learning the aircraft mass and thrust to improve the ground-based trajectory prediction of climbing flights[J]. Transportation Research Part C: Emerging Technologies, 2013, 36: 45-60.
- [21] ALLIGIER R, GIANAZZA D. Learning aircraft operational factors to improve aircraft climb prediction: A large scale multi-airport study[J]. Transportation Research Part C: Emerging Technologies, 2018, 96: 72-95.
- [22] GUAN X, LV R, SUN L, et al. A study of 4D trajectory prediction based on machine deep learning[C]// 2016 12th World Congress on Intelligent Control and Automation(WCICA). IEEE, 2016; 24-27.
- [23] BELGHAZI M I, BARATIN A, RAJESWAR S, et al. Mine: mutual information neural estimation[J]. arXiv:1801.04062, 2018.
- [24] GRILL J B, STRUB F, ALTCHÉ F, et al. Bootstrap your own latent: A new approach to self-supervised learning[J]. arXiv: 2006.07733, 2020.
- [25] DEVLIN J, CHANG M W, LEE K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding[J]. arXiv:1810.04805, 2018.
- [26] KONG L, D'AUTUME C M, LING W, et al. A mutual information maximization perspective of language representation learning[J]. arXiv:1910.08350, 2019.
- [27] OORD A, LI Y, VINYALS O. Representation learning with contrastive predictive coding[J]. arXiv:1807.03748, 2018.
- [28] MA Z, COLLINS M. Noise contrastive estimation and negative sampling for conditional models: Consistency and statistical efficiency[J]. arXiv:1809.01812, 2018.



WANG Pengyu, born in 1998, postgraduate. His main research interests include deep learning and data mining.



ZHONG Ting, born in 1977, Ph.D, associate professor, is a member of China Computer Federation. Her main research interests include machine learning and data mining.

(责任编辑:喻黎)