

刘海容, 许莉, 向进, 等. 基于联邦学习的多无人机轨迹预测算法[J]. 智能计算机与应用, 2025, 15(11): 117-121. DOI: 10.20169/j. issn. 2095-2163. 251119

基于联邦学习的多无人机轨迹预测算法

刘海容¹, 许莉¹, 向进¹, 何开晟¹, 杨婷², 陈思凡³

(1 福州大学 物理与信息工程学院, 福州 350108; 2 同济大学 建筑与城市规划学院, 上海 200092;

3 福州大学 至诚学院, 福州 350002)

摘要: 近年来, 无人机技术在各个领域的应用日益广泛。但伴随着无人机的大规模应用, 如何在保障数据隐私的同时提升无人机轨迹预测的准确性, 已成为亟待解决的问题。本文在联邦平均(Federated Averaging, FedAvg)算法的基础上嵌入动态筛选模块, 提出联邦动态聚合(Federated Dynamic Aggregation, FedDA)算法, 提升多无人机轨迹预测的精度。实验证明: 当部分客户端的训练数据存在噪声干扰或样本分布偏移等情况下, FedDA算法比其它联邦学习算法预测精度提升10.4%, 对于隐私保护场景下的无人机轨迹预测具有重要的实际应用价值。

关键词: 无人机; 联邦学习; 动态筛选; FedDA算法

中图分类号: TP181

文献标志码: A

文章编号: 2095-2163(2025)11-0117-05

Multi UAV trajectory prediction algorithm based on Federated Learning

LIU Hairong¹, XU Li¹, XIANG Jin¹, HE Kaisheng¹, YANG Ting², CHEN Sifan³

(1 College of Physics and Information Engineering, Fuzhou University, Fuzhou 350108, China;

2 College of Architecture and Urban Planning, Tongji University, Shanghai 200092, China;

3 Zhicheng College, Fuzhou University, Fuzhou 350002, China)

Abstract: In recent years, drone technology has been increasingly used in various fields. However, with the large-scale application of drones, how to improve the accuracy of drone trajectory prediction while ensuring data privacy has become an urgent challenge to be solved. This paper proposes a Federated Dynamic Aggregation (FedDA) algorithm to enhance the accuracy of multi-drone trajectory prediction by embedding a dynamic screening module into the Federated Averaging (Federated Averaging, FedAvg) algorithm. Experiments show that when the training data of some clients is subject to noise interference or sample distribution shift, the FedDA algorithm improves the prediction accuracy by 10.4% compared with other federated learning algorithms. This research has important practical application value for drone trajectory prediction in privacy protection scenarios.

Key words: UAV; Federated Learning; dynamic screening; FedDA algorithm

0 引言

随着无人机技术在农业、城市巡检和军事等多个领域的广泛应用, 对其轨迹进行有效预测, 已成为实现无人机在复杂环境中高效运行的关键^[1]。目前, 针对无人机复杂环境下的路径预测, 相关研究多聚焦于技术方法的探索^[2]。深度学习凭借强大的

特征学习能力, 在训练数据充足时能很好地拟合映射关系, 特别是长短期记忆网络(Long Short-Term Memory, LSTM)针对时间序列数据展现出良好的预测性能^[3-4]。但当输入序列中存在难以确定的噪声和干扰时, 会对深度学习预测的准确性造成较大影响, 进而影响无人机执行任务的成功率^[5]。

联邦学习成为处理无人机数据的关键思路^[6]。

基金项目: “十四五”国家重点研发计划(2022YFC3800205)。

作者简介: 刘海容(1999—), 男, 硕士, 主要研究方向: 联邦学习, 智能体轨迹预测; 许莉(1998—), 女, 硕士, 主要研究方向: 多智能体路径规划, 强化学习; 向进(2000—), 男, 硕士, 主要研究方向: 路径规划, 智能算法; 何开晟(1999—), 男, 硕士, 主要研究方向: 强化学习, 加密算法; 杨婷(1983—), 女, 博士, 副研究员, 主要研究方向: 智能仿真, 城市建模。

通信作者: 陈思凡(1997—), 男, 硕士, 助教, 主要研究方向: 无人机智能规划, 机器学习。Email: csf_fuzc@163.com。

收稿日期: 2024-02-21

联邦学习通过将数据分散在各个无人机上进行训练,并在全局模型中聚合各无人机的模型参数,避免暴露无人机采集到的敏感感知信息,可以在保护数据安全的前提下,共享个体模型性能^[7-8]。联邦学习作为“连接”工具,使得联邦成员的数据资产得以利用^[9]。范文等^[10]综合考虑数据新鲜程度和通信代价等多个因素,利用联邦学习对无人机之间的协同工作方式综合优化;Zhang等^[11]制定了通信和计算模型,以最小化通信成本实现分布式的深度学习;Liu等^[12]使用基于部分模型聚合策略的框架,提出了一种动态等待策略,确定每轮的聚合数;Ghosh等^[13]构建了集群联邦学习的高效框架,交替估计用户的聚类身份并通过梯度下降优化用户聚类的模型参数;Mammen等^[14]详细介绍了优化客户端训练与服务器端聚合的方法,正逐步成为联邦学习研究的重要方向。Wang等^[15]提出根据损失与样本数量的乘积所占的比重来决定聚合权重的联邦学习LS算法,实现对电力负荷的准确预测,但是此方法对权重的计算方法相对固定。

本文针对多无人机轨迹预测问题,构建泛化性能更强的联邦学习框架。该框架不仅仅关注客户端的损失值和样本数量的权重分配,还设计了自适应的动态取舍机制。通过动态分组和基于评价指标的筛选,系统可以自动调整对不同客户端的关注度,从而有效地缓解低质量客户端对整体模型的负面影响,进一步提高了算法的鲁棒性和适应性。通过评估改进后的联邦学习算法在预测无人机轨迹的精度变化,探讨融入动态筛选模块对模型预测精度的影响。

1 算法理论与模型设计

1.1 多任务学习长短期记忆网络模型

联邦学习的无人机客户端使用的是多任务学习长短期记忆网络模型(Multi-Task Learning Long Short-Term Memory, MTL-LSTM),相对于传统的循环神经网络,LSTM模型能够更好地解决长序列的依赖关系问题,并且能够通过学习历史数据的长期变化趋势,结合实时观测值来完成预测^[16]。

LSTM的组成:输入 X_t 、隐藏状态 h_t 、遗忘门 G_f 、输入门 G_i 、候选细胞状态 $G_{\tilde{c}_t}$ 、输出门 G_o ,具体结构如图1所示。

LSTM的计算主要包括遗忘门、输入门、输出门3个核心计算^[17]。遗忘门作为信息过滤的首道关卡,通过Sigmoid激活函数计算上一时刻隐藏状态

与当前输入的线性组合,输出值在(0,1)区间内,计算公式如下:

$$G_f = \sigma[W_f(h_{t-1}, X_t) + b_i] \quad (1)$$

其中,与各个门带相同下标的矩阵 W 和 b 表示对应门神经元的权重和偏置, $\sigma(\cdot)$ 表示Sigmoid激活函数。

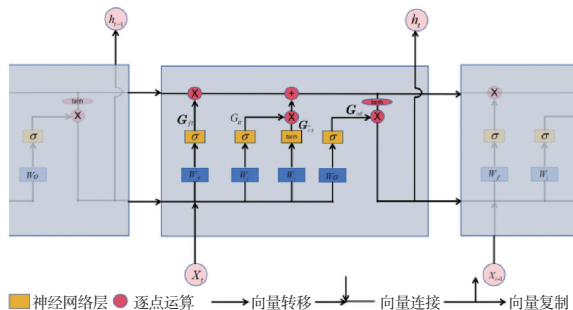


图1 LSTM网络结构图

Fig. 1 LSTM network architecture diagram

输入门负责筛选当前输入的有效信息,同样采用Sigmoid激活函数生成输入信息的保留比例,计算公式如下:

$$G_i = \sigma[W_i(h_{t-1}, X_t) + b_i] \quad (2)$$

同时,通过tanh激活函数生成候选记忆单元,计算公式如下:

$$G_{\tilde{c}_t} = \tanh[W_c(h_{t-1}, X_t) + b_c] \quad (3)$$

其中, $\tanh(\cdot)$ 为tanh激活函数,将输出限制在(-1,1)之间, \odot 表示元素乘积。

细胞状态更新,结合遗忘门和输入门的结果,计算公式如下:

$$C_t = G_f \odot C_{t-1} + G_i \odot G_{\tilde{c}_t} \quad (4)$$

输出门则控制当前细胞状态的输出比例,通过Sigmoid激活函数决定输出信息的比例,再与经过tanh激活的细胞状态相乘得到最终输出,计算公式如下:

$$G_o = \sigma[W_o(h_{t-1}, X_t) + b_o] \quad (5)$$

$$h_t = G_o \odot \tanh(C_t) \quad (6)$$

LSTM通过几个门的控制,使得细胞状态记住需要长时间记住的重要信息,忘记不重要的信息,并将最终产生当前时刻的输出 h_t 。

在此基础上构建的MTL-LSTM预测模型,通过共享层机制进一步提升了多任务学习的效率。首先,利用共享层提取跨任务的共性特征表示;其次,将共享层的输出分别传递至3个独立的输出层,用于预测无人机的三维坐标 x, y, z 。这种架构设计使得不同任务能够通过共享底层特征表示,有效降低模型的过拟合风险^[18]。MTL-LSTM网络框架如图

2 所示。

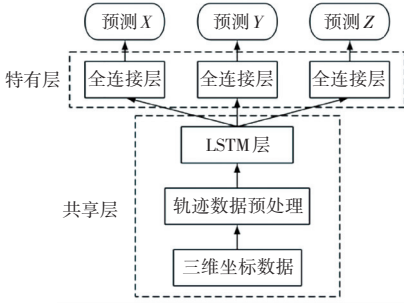


图 2 MTL-LSTM 网络框架

Fig. 2 MTL-LSTM network framework

1.2 联邦学习框架

在 MTL-LSTM 基础上构建的联邦学习系统是由一个服务器端和 K 个客户端 (无人机) 两个部分组成。

联邦学习过程:

(1) 客户端基于本地数据集训练模型: 每台无人机客户端基于 MTL-LSTM 使用区域的路径数据来训练模型, 客户端 k 的优化问题可以表示为:

$$\theta^* = \operatorname{argmin}_{\theta_k} L_k(\theta_k) \quad (7)$$

其中, θ_k 为第 k 个客户端的本地模型参数; l_k 为损失值; $L_k(\theta_k)$ 为损失函数。

通过梯度下降优化算法更新本地模型参数 θ_k 。

(2) 客户端向服务器端上传本地模型参数: 完成本地模型训练后, 客户端将本地模型参数 θ_k 上传至服务器端。

(3) 服务器端利用本地模型计算全局模型: 服务器端收到来自所有客户端的本地模型参数 θ_k , 利用不同的聚合算法将这些参数聚合为全局模型参数 θ' , FedAvg 算法的参数聚合公式为:

$$\theta' = \sum_{k \in K} \frac{m_k}{m} \theta_k \quad (8)$$

其中, m 为被选中的所有客户端的数据样本总数, m_k 为第 k 个客户端的数据样本数。

(4) 客户端更新全局模型: 服务器端将计算得到的全局模型参数 θ' 发送回每个客户端, 客户端使用该全局模型参数来更新自己的本地模型 $\theta_k \leftarrow \theta'$ 。

联邦学习的训练流程将重复上述 4 个步骤, 直至满足收敛条件^[19]。收敛的条件取决于中心端配置, 例如使用迭代次数 r 作为收敛条件或全局模型的收敛误差小于某一阈值。

1.3 动态筛选 FedDA 联邦学习算法

针对部分无人机客户端因数据质量不佳而影响整体模型精度下降的问题, 本文提出 FedDA 算法,

通过动态取舍机制优化聚合过程, 实现模型鲁棒性的提升。

FedDA 算法的详细步骤:

首先, 在客户端本地的训练过程中会计算每个任务的损失并保存在验证集上获得最小损失的模型, 因此在分配权重时可以考虑损失值的大小; 其次, 归一化客户端的损失值 l_k 与样本数量 m_k , 使得 l'_k 与 m'_k 具有同等重要性, 公式为:

$$l'_k = \frac{l_k - l_{k \min}}{l_{k \max} - l_{k \min}} \quad (9)$$

m'_k 的归一化方法与 l'_k 相同, 再通过加权评价指标计算每个客户端的加权评价指标 (Weighted Eval Metrics, WEM), 公式为:

$$\text{WEM}_k = 0.7 \frac{1}{l'_k} + 0.3 m'_k \quad (10)$$

根据求出的加权评价指标定义每一轮迭代过程中的客户端加权评价指标基准 $\overline{\text{WEM}}$, 公式为:

$$\overline{\text{WEM}} = \frac{\sum_{k \in K} \text{WEM}_k}{K} \quad (11)$$

基准将无人机客户端分为高质量组和低质量组两组, 此时仅筛选出高质量组的模型参数 θ_k 参与聚合, 聚合公式为:

$$\theta' = \sum_{k \in K} \frac{\text{WEM}_k}{\sum \text{WEM}_k} \theta_k \quad (12)$$

$\sum \text{WEM}_k$ 为高质量组的加权评价指标的累加和。

FedDA 算法的聚合过程如图 3 所示。

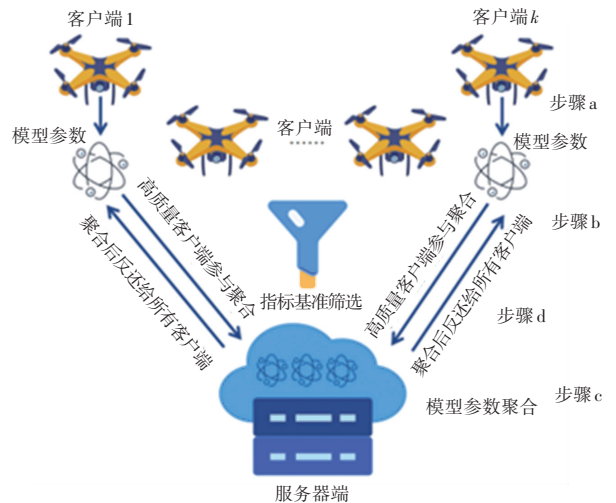


图 3 FedDA 算法的聚合过程

Fig. 3 Aggregation process of the FedDA algorithm

由于该算法在每一轮迭代中动态地选择参与聚

合的客户端,整个系统在训练过程中具有性能动态提升的潜力,使算法能够更好地适应数据分布的变化和模型性能的波动,提高了模型的鲁棒性。

2 实验环境与评价指标

2.1 数据集

本文实地采集了 20 条无人机路径数据,记录每一次运动轨迹的经度、纬度和高度数据构成路径预测数据集,用以训练和验证路径预测网络模型。本次实验设置 4 个客户端,每个客户端拥有 5 条无人机路径数据,对数据归一化处理之后,按照 3 : 1 : 1 划分原则分为训练集、验证集和测试集。

2.2 实验环境

基于 PyTorch 深度学习框架进行无人机轨迹预测实验,使用的配置 Intel Core i5-7300HQ 处理器和 NVIDIA GeForce GTX 1050 Ti 显卡的电脑,网络训练优化方法选择 Adam,学习率设为 0.001,批量大小设为 128。

2.3 评价指标

在无人机目标轨迹预测时,三维坐标 x,y,z 由独立输出层输出,因此分别取三维方向坐标的预测值与真实值相比较,最后求评价指标结果的平均值。

本实验的评价指标:

(1)均方误差 (Mean Squared Error, MSE):用于衡量预测模型的表现,计算公式为:

MSE = \frac{1}{n} \sum_{i=1}^n (y'_i - y_i)^2 \tag{13}

其中, y_i 为第 i 个样本数据的实际值; y'_i 为第 i 个样本数据的预测值; n 为样本数据的数量。

MSE 的值越小,表示预测结果与真实值之间的偏差越小,模型的预测效果越好^[20]。

(2)均方根误差 (Root Mean Square Error, RMSE):衡量预测值与真实值之间的偏差程度,是预测值与真实值之差的平方和的平方根, RMSE 值越小表示模型预测效果越好^[21],计算公式为:

RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y'_i - y_i)^2} \tag{14}

(3)平均绝对误差 (Mean Absolute Error, MAE):指各次测量值的绝对偏差绝对值的平均值,可以避免误差相互抵消的问题,因而可以准确反映实际预测误差的大小^[22]。MAE 的值越小表示模型预测效果越好,计算公式为:

MAE = \frac{1}{n} \sum_{i=1}^n |y'_i - y_i| \tag{15}

(4)决定系数 (R-squared, R^2):用于判断模型的好坏, R^2 越趋近于 1 表示模型拟合效果越好:

R^2 = 1 - \frac{\sum_{i=1}^n (y'_i - y_i)^2}{\sum_{i=1}^n (\bar{y}_i - y_i)^2} \tag{16}

其中, \bar{y}_i 表示均值。

3 实验结果与分析

分别使用 FedAvg 算法、LS 算法和本文提出的 FedDA 算法预测无人机轨迹,训练网络时设置聚合次数为 5 次,每轮聚合之前本地网络训练 5 次,结果见表 1~表 4。

表 1 客户端 1 的算法预测评估

算法	MSE	RMSE	MAE	R^2
FedAvg	8.822	2.970	2.107	0.750
LS	0.695	0.834	0.614	0.967
FedDA	0.677	0.823	0.517	0.974

表 2 客户端 2 的算法预测评估

算法	MSE	RMSE	MAE	R^2
FedAvg	6.616	2.572	1.707	0.779
LS	1.407	1.186	0.763	0.968
FedDA	1.222	1.105	0.664	0.976

表 3 客户端 3 的算法预测评估

算法	MSE	RMSE	MAE	R2
FedAvg	6.764	2.601	2.033	0.175
LS	5.883	2.425	1.809	0.401
FedDA	4.662	2.159	1.644	0.461

表 4 客户端 4 的算法预测评估

算法	MSE	RMSE	MAE	R2
FedAvg	8.849	2.907	2.027	0.549
LS	1.177	1.085	0.757	0.955
FedDA	0.867	0.931	0.641	0.959

从表 1~4 可知,在联邦学习系统中,一旦出现异常客户端,其数据会直接对整体模型的性能产生负面影响。传统的 FedAvg 算法由于缺乏针对性的异常处理机制,已难以适应这种场景;而 FedDA 算法则能够通过有效的筛选机制识别出异常客户端,从而避免异常数据对全局模型造成干扰。在所有无人机客户端的轨迹预测任务中,与 LS 算法相比,

FedDA 算法的性能指标均有显著改善: MSE 平均降低 15.7%, RMSE 平均降低 8.3%, MAE 平均降低 13.3%, R^2 平均提升 4.2%。

4 结束语

在联邦学习系统中, 传统的聚合策略会导致全局模型质量受到参与训练客户端的影响。为了提高模型精度, 本文提出具有客户端选择策略的 FedDA 联邦学习算法。利用损失值和数据量动态调整客户端的聚合条件, 经多种评价指标验证, 该算法提升了模型的预测精度和模型鲁棒性, 对保障隐私安全情况下的多无人机轨迹预测具有实际意义。未来工作将集中研究联邦学习过程中降低通信开销的方法, 以进一步提升训练效果。

参考文献

- [1] PENG X, YANG X. KiteRunner: Language-driven global-local navigation for long-range autonomous UAV flight[J]. arXiv preprint arXiv, 2503. 08330, 2025.
- [2] 潘登, 郑建华, 高东. 基于二维连通图的无人机快速三维路径规划[J]. 北京航空航天大学学报, 2023, 49(12): 3419-3431.
- [3] LÄNGKVIST M, KARLSSON L, LOUTFI A. A review of unsupervised feature learning and deep learning for time-series modeling[J]. Pattern Recognition Letters, 2014, 42: 11-24.
- [4] SHU P, CHEN C, CHEN B, et al. Trajectory prediction of UAV based on LSTM[C]//Proceedings of 2021 2nd International Conference on Big Data and Artificial Intelligence and Software Engineering (ICBASE). Piscataway, NJ: IEEE, 2021: 448-451.
- [5] DONG S, WANG P, ABBAS K. A survey on Deep Learning and its applications[J]. Computer Science Review, 2021, 40(1): 100379.
- [6] ZENG T, SEMIARI O, MOZAFFARI M, et al. Federated learning in the sky: Joint power allocation and scheduling with UAV swarms[C]//Proceedings of 2020 IEEE International Conference on Communications (ICC). Piscataway, NJ: IEEE, 2020: 1-6.
- [7] FANG L, HU H, PU W, et al. Research on UAV target recognition technology based on federated learning[C]//Proceedings of 2021 2nd International Conference on Computer Engineering and Intelligent Control (ICCEIC). Piscataway, NJ: IEEE, 2021: 119-122.
- [8] CHHIKARA P, TEKCHANDANI R, KUMAR N, et al. Federated learning for air quality index prediction using UAV swarm networks[C]//Proceedings of 2021 IEEE Global Communications Conference (GLOBECOM). Piscataway, NJ: IEEE, 2021: 1-6.
- [9] LIU J, WANG J H, RONG C, et al. FedPA: An adaptively partial model aggregation strategy in Federated Learning[J]. Computer Networks, 2021, 199: 108468.
- [10] 范文, 韦茜, 周知, 等. 数据新鲜度驱动的协作式无人机联邦学习智能决策优化研究[J]. 电子与信息学报, 2022, 44(9): 2994-3003.
- [11] ZHANG T, LAM K Y, ZHAO J. Deep reinforcement learning based scheduling strategy for federated learning in sensor-cloud systems[J]. Future Generation Computer Systems, 2023, 144: 219-229.
- [12] LIU J, WANG J H, RONG C, et al. FedPA: An adaptively partial model aggregation strategy in Federated Learning[J]. Computer Networks, 2021, 199: 108468.
- [13] GHOSH A, CHUNG J, YIN D, et al. An efficient framework for clustered federated learning[C]//Proceedings of International Neural Information Processing Systems. NeurIPS, 2020: 19586-19597.
- [14] MAMMEN P M. Federated learning: Opportunities and challenges[J]. arXiv preprint arXiv, 2101. 05428, 2021.
- [15] WANG Y, BENNANI I L, LIU X, et al. Electricity consumer characteristics identification: A federated learning approach[J]. IEEE Transactions on Smart Grid, 2021, 12(4): 3637-3647.
- [16] TONG G U O, JIANG N, BIYUE L I, et al. UAV navigation in high dynamic environments: A deep reinforcement learning approach[J]. Chinese Journal of Aeronautics, 2021, 34(2): 479-489.
- [17] MERITY S, KESKAR N S, SOCHER R. Regularizing and optimizing LSTM language models[J]. arXiv preprint arXiv, 1708. 02182, 2017.
- [18] WEI J, WU X, YANG T, et al. Ultra-short-term forecasting of wind power based on multi-task learning and LSTM[J]. International Journal of Electrical Power & Energy Systems, 2023, 149: 109073.
- [19] MCMAHAN B, MOORE E, RAMAGE D, et al. Communication-efficient learning of deep networks from decentralized data[C]//Proceedings of ISHC. 2017: 1273-1282.
- [20] WADA R. RMSE: Stata module to calculate raw or adjusted RMSE (Root MSE)[J]. Statistical Software Components, 2009, 9(3): 156-168.
- [21] KARUNASINGHA D S K. Root mean square error or mean absolute error? Use their ratio as well[J]. Information Sciences: An International Journal, 2022(585): 609-629.
- [22] WILLMOTT C J, MATSUURA K. Advantages of the mean absolute error over the root mean square error in assessing average model performance[J]. Climate Research, 2005, 30(1): 79-82.