UAV Autonomous Sensing Algorithm Based on Multi-Source Heterogeneous Sensor Fusion*

WU Xinwei[1,2*], HU Minghua[1], CHEN Jingsong[3]
(1.School of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing Jiangsu 211106, China;
2.Key Laboratory of Civil Aviation Air Traffic Control Avionics, Chinese Aeronautical Radio Electronics Research Institute, Shanghai 200233, China;
3.AVIC ATM System & Equipment Copporation Limited, Shanghai 200241, China)

Abstract: In order to study the autonomous perception of UAVs in complex mixed airspace environment, a multi-source heterogeneous perception system architecture of UAVS based on features-level data fusion is proposed. Through multi-source heterogeneous track information fusion of airborne sensors such as TCAS/ADS-B and active phased array radar, precise perception of cooperative and non-cooperative targets is realized. A fusion perception algorithm based on LSTM-KF deep learning model is designed, the LSTM prior state model and LSTM data fusion model are constructed based on the characteristics of LSTM time series prediction and KF optimal state estimation, and the optimal state estimation is completed according to the KF algorithm process. Model simulation and test verification are carried out, the results show that compared with CNN and LSTM, the anti-jamming performance of LSTM-KF is improved by 44%, 36%, the accuracy performance is improved by 68%, 36%, and LSTM-KF has better stability under abnormal conditions such as sensor data interruption and data deterioration. In UAV perception test, target tracking is stable and continuous. It can effectively reduce the interference effect of abnormal sensor data and meet the requirements of autonomous sensing performance of UAV platform.

Key words: sensor signal processing; UAV perception; multi-source heterogeneous data fusion; LSTM; Kalman filtering
EEACC: 6140 **doi**: 10.3969/j.issn.1004-1699.2026.09.017

基于多源异构传感器融合的无人机自主感知算法*

吴鑫炜[1,2*], 胡明华[1], 陈敬松[3]
(1.南京航空航天大学民航学院, 江苏 南京 211106; 2.中国航空无线电电子研究所民航空管航电重点实验室, 上海 200233; 3.中航空管系统装备有限公司, 上海 200241)

摘 要: 为了研究复杂混合空域环境下的无人机自主感知问题, 提出了一种基于特征级数据融合的无人机多源异构感知系统架构, 通过 TCAS/ADS-B 和有源相控阵雷达等机载传感器融合, 实现对协同类和非协同目标的精确感知。设计了一种基于 LSTM-KF 深度学习模型的无人机多源异构融合感知算法, 综合 LSTM 时序预测和 KF 最优状态估计的特点, 构建了 LSTM 先验状态模型和 LSTM 数据融合模型, 并按照 KF 算法流程完成最优状态估计。模型仿真结果表明, 与 CNN、LSTM 相比, LSTM-KF 的抗干扰性能提升了 44%, 36%, 准确性能提升了 68%, 36%, 并且在传感器数据中断、数据恶化等异常情况下具有更好稳定性, 在无人机感知试验中目标跟踪稳定连续, 能够有效降低传感器数据异常的干扰影响, 满足无人机平台的自主感知性能要求。

关键词: 传感器信号处理; 无人机感知; 多源异构数据融合; 长短时记忆神经网络; 卡尔曼滤波
中图分类号: V279 **文献标识码**: A **文章编号**: 1004-1699(2026)09-2061-08

随着无人机应用场景日趋丰富, 感知能力也成为无人机安全运行、复杂任务执行的重要安全保障, 也是大中型无人机逐步融入公共空域的必备功能[1-2]。由于无人机的高机动性以及机载环境和空域环境的高复杂性, 无人机机载感知性能受到了严重挑战, 提高无人机感知的可靠性和准确性已成为无人机应用发展的关键技术, 多源数据融合通过知识推理和识别方法对传感器测量数据进行估计和判决, 提升数据的可靠性和置信度, 是无人机感知性能提升的有效技术手段[3]。传统的数据融合处理包括加权平均、贝叶斯推理、卡尔曼滤波(Kalman Filter, KF)和 D-S 证据等, 随着传感器和应用场景的日益复杂, 这些方法在处理复杂时变系统以及大规模数据时存在数据失真、畸变等缺陷。深度学习

项目来源: 国家重点研发计划(2022YFB4300900)
收稿日期: 2024-06-18 **修改日期**: 2024-09-15

技术凭借优秀的特征识别和预测能力,在大数据的融合计算上表现出其优势,国内外学者也在基于深度学习的数据融合方面开展了研究[4],Chen 等[5]研究了基于卷积神经网络的多传感器深度融合模型,Wu 等[6]提出了一种基于深度长短时记忆(Long Short-Term Memory, LSTM)网络的融合方法,Fu 等[7]设计了多尺度特征融合卷积神经网络(Convolutional Neural Networks, CNN),张立奎等[8]基于 LSTM 开展了多源数据桥梁变形重构应用研究,刘金铭等[9]提出了针对单一传感器的 LSTM-KF 预测方法,用于无人机航迹跟踪。本文面向无人机的机载传感器实际应用需求,设计多源异构感知系统架构,构建 LSTM-KF 深度学习模型,开展无人机多源异构传感器数据融合感知应用研究。

1 无人机多源异构感知系统架构

1.1 需求分析

本文主要针对大中型无人机的有人机、无人机混合空域运行场景开展需求分析,无人机飞行环境感知包括对周围环境的探测识别,以及飞行器自身的状态估计,实现对潜在冲突的障碍物避让,确保无人机与有人机协调运行,能够安全、稳定、高效地执行飞行任务。混合空域中可能存在潜在冲突的障碍物,如表 1 所示,分为协同类目标和非协同类目标。针对有人机、无人机等协同类目标,主要的感知传感器是机载防撞系统(Traffic Collision Avoidance System,TCAS)、广播式自动相关监视系统(Automatic Dependent Surveillance-Broadcast,ADS-B)等,通过视距通信建立询问应答机制的空管协同数据链,以秒为周期获取应答信号,并通过卡尔曼滤波算法更新目标航迹信息。R3 公司研制了基于 ADS-B 技术的无人机感知与规避系统,林肯实验室完成了无人机机载 TCAS 的感知与规避测试,由于无人机的大幅度机动性和机载天线的接收方向图波束限制等原因,TCAS 存在感知精度不高、跟踪容易中断、抗干扰性较差等缺陷[10]。针对鸟群、建筑物等非协同类目标,主要的探测手段包括主动探测雷达、激光雷达、光电和红外等,Accardo 等[11]设计了一种基于雷达探测的目标状态估计方法,Owen 等[12]采用信号特征和误差精度分析了雷达的空域感知能力,Lai 等[13]提出了一种机载视觉碰撞检测系统,Zarandy 等[14]建立了基于多相机阵列的空中目标感知系统,GA-ASI 公司完成了一项基于多源信息融合的感知与规避系统,这些技术能够在特定条件实现机载感知功能,但也存在虚警率高、感知性能不足、机载载荷大等不足。

因此,面向无人机日趋丰富的运行场景需求,无人机多源异构感知能力需要满足准确性、抗干扰性和实时性等要求。同时,由于无人机机载平台的限制,无人机多源异构感知算法还需要兼顾轻量化限制。

表 1 障碍物类型

分类	障碍物	感知传感器
协同类	有人机、无人机	TCAS、ADS-B
非协同类	鸟团、建筑物、复杂地形、恶劣气象	探测雷达、光电激光雷达、红外

1.2 系统架构

根据需求分析结果,开展无人机多源异构感知系统架构设计,如图 1 所示。从探测距离、探测精度、抗干扰性、重量功耗等因素分析各类型感知传感器特性,选用 TCAS/ADS-B 和有源相控阵雷达作为机载传感器源,可实现对主要的协同类和非协同的障碍物探测,支持其他传感器的数据接入。首先开展传感器探测数据预处理,完成相对方位、相对距离、相对速度、相对高度等探测信息的时空同步、校

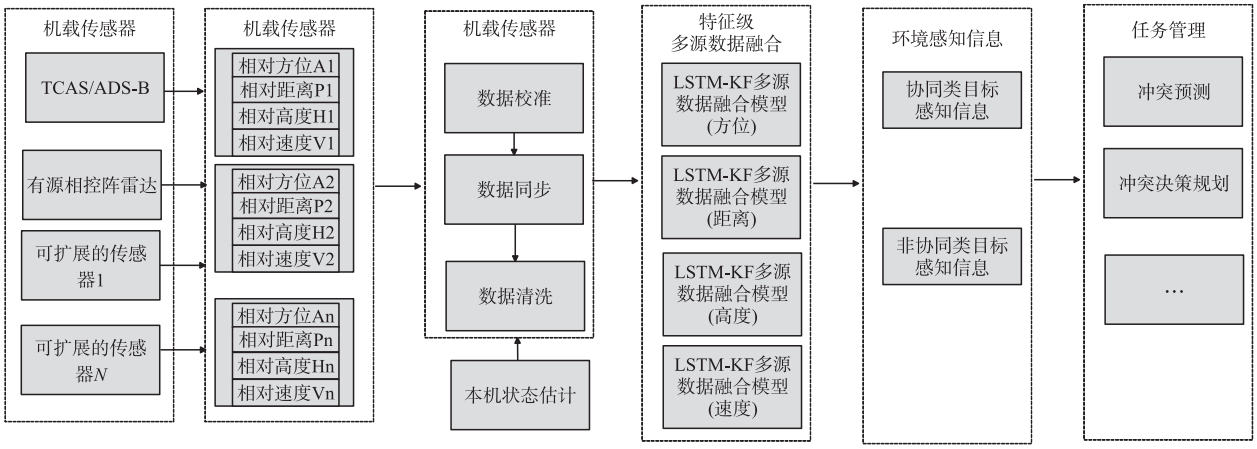

图 1 无人机多源异构感知系统架构

准和数据清洗;然后进行多源数据融合,采取 LSTM-KF 多源异构传感器融合模型分别对方位、距离、高度和速度等特征级航迹数据进行融合处理,生成包括协同类目标和非协同类目标的环境感知信息;最后将环境感知数据输出给任务管理单元,用于冲突预测、冲突决策规划等。

TCAS、ADS-B 和有源相控阵雷达等机载传感器可以满足无人机平台探测距离以及轻量化的装机要求,同时,特征级数据融合相比像素级数据融合降低了计算资源和时间开销。LSTM 模型擅长时间序列数据的预测[15-16],KF 算法在处理时变系统的滤波跟踪方面具备实时性高和内存占用小等优势[17],无人机多源异构感知系统架构结合两者的优势,通过设计 LSTM-KF 数据融合模型,提升数据预测能力和数据融合精度,有效提高无人机感知的准确性和抗干扰性。

2　LSTM-KF 多源异构传感器融合模型

长短时记忆网络是一种特殊结构的循环神经网络,能够学习序列数据的长期性规律。卡尔曼滤波器的基本原理是利用当前时刻的观测值和前一时刻的最优状态估计来估计当前时刻的最优状态估计。本文针对无人机感知的准确性、抗干扰性、轻量化和实时性的需求,将 LSTM 和 KF 相结合,通过历史数据统计序列特征和最优状态估计建立 LSTM-KF 数据融合模型,模型原理框图见图 2。

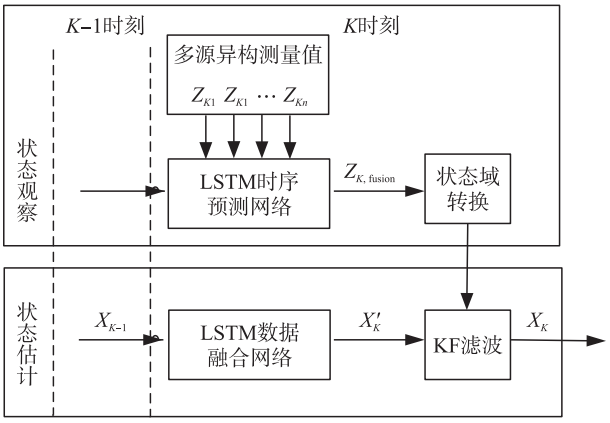

图 2　LSTM-KF 多源异构传感器数据融合模型

LSTM-KF 多源异构传感器数据融合模型的处理流程:

步骤 1　通过 LSTM 时序预测神经网络完成先验状态估计,利用 LSTM 进行时间序列数据预测,取代 KF 传统的外推预测方法。LSTM 为了避免原始循环神经网络的长期依赖性问题等缺陷,将隐藏层单元更换成存储单元,通过存储单元保存经过长时间后剧烈衰减的信息,能够学习序列数据的长期性规律。LSTM 的核心是细胞状态,通过遗忘门、输入门和输出门的运算,实现细胞状态的保护和控制。LSTM 通过历史数据统计进行模型训练,学习时间序列特征,预测 K 时刻的先验状态估计 X'。

步骤 2　通过 LSTM 多源数据融合神经网络完成观测状态多源数据融合,利用 LSTM 进行数据融合,取代加权平均的数据统计融合方法。通过历史数据统计进行模型训练,学习多源异构数据的融合特征,根据 K 时刻的多源异构传感器的测量值进行数据融合,得到融合后的测量值 $Z_{K,\text{fusion}}$;

步骤 3　通过 KF 滤波算法完成最优状态估计,通过修正加权卡尔曼增益,进行 KF 滤波,得到最优状态估计结果 X_K。

3　无人机多源异构融合感知算法

无人机多源异构融合感知算法面向协同类目标和非协同类目标等障碍物感知需求,采用 TCAS/ADS-B 和有源相控阵雷达等传感器探测数据,按照 LSTM-KF 数据融合模型,分别对先验状态估计、数据融合和最优状态估计等步骤进行优化算法设计。

3.1　先验状态估计

参考卡尔曼滤波算法原理,已知前一时刻最优状态估计 X_{K-1},则根据状态转移矩阵计算当前时刻先验状态估计及其协方差矩阵 $P_{K/K-1}$:

$$X_{K/K-1}=\boldsymbol{A}\times X_{K-1}+\boldsymbol{B}\mu_k \tag{1}$$

$$\boldsymbol{P}_{K/K-1}=\boldsymbol{A}\times\boldsymbol{P}_{K-1}\times\boldsymbol{A}^{\mathrm{T}}+\boldsymbol{Q} \tag{2}$$

式中:$\boldsymbol{A}$ 为状态转移矩阵,$\boldsymbol{B}$ 为控制矩阵,$\boldsymbol{Q}$ 为过程噪声方差,将先验状态估计 $X_{K/K-1}$ 通过量测矩阵 $\boldsymbol{H}$ 转换到量测域,并由观测值 $\boldsymbol{Z}_K$ 得到先验量测估计 $\boldsymbol{H}\times X_{K/K-1}$ 以及协方差矩阵 $\boldsymbol{H}\boldsymbol{P}_{K/K-1}\boldsymbol{H}^{\mathrm{T}}$,并建立后验状态估计方程:

$$\boldsymbol{H}\times X_K=\boldsymbol{H}\times X_{K/K-1}+k(\boldsymbol{Z}_K-\boldsymbol{H}\times X_{K/K-1}) \tag{3}$$

针对无人机感知的准确性要求,充分利用 LSTM 时序预测的优势,按照 LSTM-KF 多源异构数据融合模型,通过无人机历史航迹数据对 LSTM 先验状态模型进行离线训练,即根据连续多个周期的数据值,学习时间序列特征,设置模型的输入层为 1,输出层为 1,隐藏层为 200。得到离线网络模型 $\text{LSTM}_{\text{net1}}$:

$$\text{LSTM}_{\text{net1}}=\{X_1,X_2,X_3\cdots X_i,X_{i+1}\cdots X_{k-1}\} \tag{4}$$

X 为时间序列数据,并对 $\text{LSTM}_{\text{net1}}$ 进行初始化,通过离线网络模型和时刻 K 之前一定时长的时序数据,在线预测时刻 K 的状态信息。

从而对式(1)和式(2)进行改进,计算修正后的先

验状态估计 $X_{K/K-1,\text{LSTM-KF}}$ 及其协方差矩阵 $\boldsymbol{P}_{K/K-1,\text{LSTM-KF}}$：

$$X_{K/K-1,\text{LSTM-KF}}=\text{LSTM}_{\text{net1}}(X_1,X_2,\cdots X_{K-1}) \tag{5}$$

$$\boldsymbol{P}_{K/K-1,\text{LSTM-KF}}=\boldsymbol{A}\times\boldsymbol{P}_{K-1,\text{LSTM-KF}}\times\boldsymbol{A}^{\text{T}}+Q \tag{6}$$

$$\boldsymbol{P}_{K-1,\text{LSTM-KF}}=\sqrt{\frac{1}{K-1}\sum_{i=1}^{K-1}(X_{K/K-1,\text{LSTM-KF}}-X_K)^2} \tag{7}$$

3.2 多源数据融合

多源数据融合即根据当前状态的 TCAS/ADS-B 和有源相控阵雷达等传感器探测数据，计算得到用于最优状态估计的融合观测值。首先进行 LSTM 数据融合模型的离线训练，通过历史航迹目标的两种传感器特征级数据特征进行学习训练，如相对距离、相对高度、相对方位等特征信息，得到离线网络模型 $\text{LSTM}_{\text{net2}}$，并结合周期数据进行网络初始化；然后根据当前时刻的传感器状态进行数据融合预测。设置模型的输入层为 2，输出层为 1，隐藏层为 200。

$$\text{LSTM}_{\text{net2}}=\{Z_{11},Z_{11},Z_1;\cdots Z_{k1},Z_{k2}\cdots Z_k\} \tag{8}$$

参考长短时记忆网络算法原理，对遗忘门、输入门和输出门等进行设计，遗忘门表征从上一时刻到当前时刻的单元状态转移函数，即决定从细胞状态中丢弃什么信息。

$$f_t=\sigma(W_f\times[h_{t-1},x_t]+b_f) \tag{9}$$

输入门表征当前时刻的输入到单元状态的转换函数，包含两个部分，第一部分为 Sigmoid 层，该层决定要更新什么值，第二部分为 tanh 层，该层创建了一个新的细胞状态向量，把有效信息更新到细胞状态里。

$$i_t=\sigma(W_i\times[h_{t-1},x_t]+b_i) \tag{10}$$

$$C'_t=\tanh(W_C\times[h_{t-1},x_t]+b_C) \tag{11}$$

根据式(9)和式(11)完成细胞状态的更新：

$$C_t=f_t\times C_{t-1}+i_t\times C'_t \tag{12}$$

输出门表征从当前时刻的单元状态到输出的转移函数，通过一个 Sigmoid 层来确定细胞状态的哪个部分将输出。

$$o_t=\sigma(W_o\times[h_{t-1},x_t]+b_o) \tag{13}$$

$$h_t=o_t\times\tanh(C_t) \tag{14}$$

由此，得到 LSTM 网络的单元状态结构，如图 3 所示，其算法训练首先是前向计算每个神经元的输出，然后确定优化目标函数，在训练早期输出值和预期值差异较大，通过计算每个神经元的误差项值，构造损失函数；最后根据损失函数的梯度指引，更新网络权值参数。

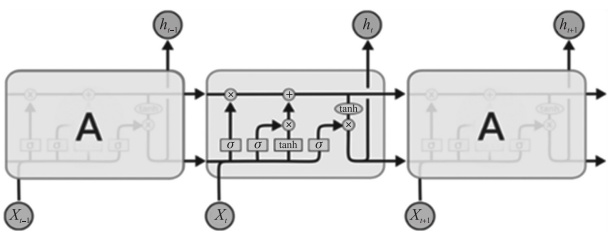

图 3 LSTM 网络的单元状态结构

在无人机实际运行环境下，机载传感器还存在测量数据偏离、中断等异常情况，针对实际应用需求，在多源数据融合处理时，增加对传感器数据的有效性判决。即当 TCAS/ADS-B 和有源相控阵雷达均有效时，按照离线网络模型 $\text{LSTM}_{\text{net2}}$ 进行数据融合，当只有某一个传感器数据有效时，则直接采信该数据。

$$Z_{K,\text{fusion}}=\begin{cases}\text{LSTM}_{\text{net2}}(Z_{K2},Z_{K1}) & \text{当 } Z_{K1}\text{、}Z_{K2}\text{均有效}\\ Z_{K2} & \text{当仅 } Z_{K2}\text{有效}\\ Z_{K1} & \text{当仅 } Z_{K1}\text{有效}\\ 0 & \text{当 } Z_{K1}\text{、}Z_{K2}\text{均无效}\end{cases} \tag{15}$$

3.3 最优状态估计

针对无人机感知的抗干扰性需求，充分利用卡尔曼滤波的特点，根据卡尔曼滤波算法，卡尔曼增益 K，以及更新方程的最优状态估计 X_K 和协方差 P_K，其中 R 为量测噪声方差。

$$K=\frac{\boldsymbol{P}_{K/K-1}\times\boldsymbol{H}^{\text{T}}}{\boldsymbol{H}\times\boldsymbol{P}_{K/K-1}\times\boldsymbol{H}^{\text{T}}+R} \tag{16}$$

$$X_K=X_{K/K-1}+K(Z_K-\boldsymbol{H}\times X_{K/K-1}) \tag{17}$$

$$\boldsymbol{P}_K=(\boldsymbol{I}-K\boldsymbol{H})\times\boldsymbol{P}_{K/K-1} \tag{18}$$

那么，改进后的先验状态估计和数据融合算法进行最优状态估计，KF 算法的更新如式(16)、式(17)、式(18)所示：

$$K=\frac{\boldsymbol{P}_{K/K-1,\text{LSTM-KF}}\times\boldsymbol{H}^{\text{T}}}{\boldsymbol{H}\times\boldsymbol{P}_{K/K-1,\text{LSTM-KF}}\times\boldsymbol{H}^{\text{T}}+R} \tag{19}$$

$$X_{K,\text{LSTM-KF}}=X_{K/K-1,\text{LSTM-KF}}+K(Z_{K,\text{fusion}}-\boldsymbol{H}X_{K/K-1,\text{LSTM-KF}}) \tag{20}$$

$$\boldsymbol{P}_{K,\text{LSTM-KF}}=(\boldsymbol{I}-K\boldsymbol{H})\times\boldsymbol{P}_{K/K-1,\text{LSTM-KF}} \tag{21}$$

由此，得到无人机多源异构感知算法流程，如图 4 所示，算法包括离线运算处理和在线运行处理，离线运算处理主要完成 LSTM 数据融合模型和 LSTM 先验状态模型的训练。在线运算处理阶段，首先进行传感器数据的预处理和有效性判断，通过数据筛选完成异常数据剔除，以及多源传感器之间的数据同步；然后采用数据融合模型和先验状态模式进行数据融合和数据预测，并根据有效传感器个数决定下一步处理流程：如果有效传感器个数为 0，则直接则预测值作为最终估计值，如果有效传感器数量为 1，则适用测量值作为观察值，如果有效传感器数量大于 1，则将数据融合模型输出作为观察值；

最后通过预测数据和观察数据完成基于卡尔曼滤波的最优状态估计,得到最终的感知信息。

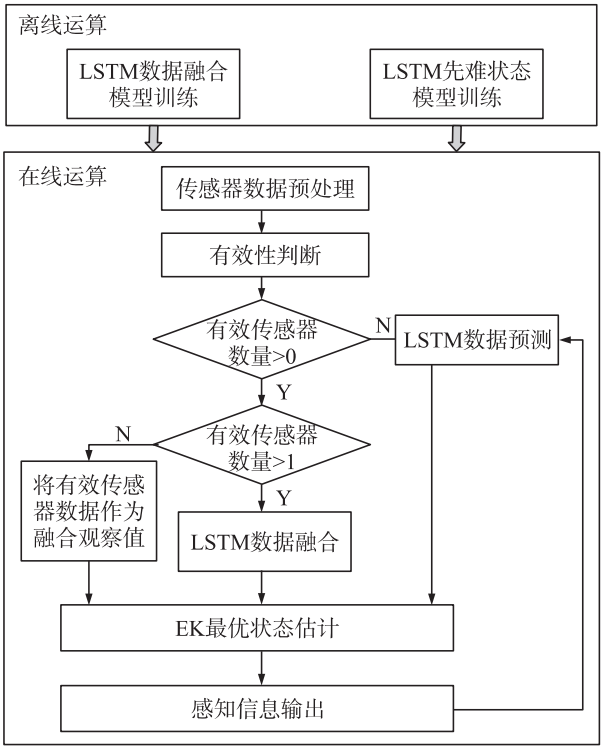

图 4　算法流程图

本算法在线运算处理的计算量较小,计算速度快,占用无人机机载系统资源少,能够满足感知实时性和轻量化要求。

4　仿真与实验

开展 LSTM-KF 模型仿真和无人机多源异构感知试验,验证系统架构和融合算法的合理性。选取 TCAS 设备搭载某航空器开展飞行试验,如图 5 所示,并结合机上已有的有源相控阵雷达,采集两种传感器的障碍物测量数据,并对数据进行同步、筛选,获取实际飞行环境下的历史航迹像素级数据集,以障碍物相对本机的距离值为例进行算法仿真,并根据机载 GPS 系统得到真值数据,对比仿真数据和真值数据,从准确性、抗干扰性和实时性等方面进行性能分析,并对比 LSTM-KF 模型、LSTM 模型和 CNN 算法的性能差异,仿真试验平台为 MATLAB2018。

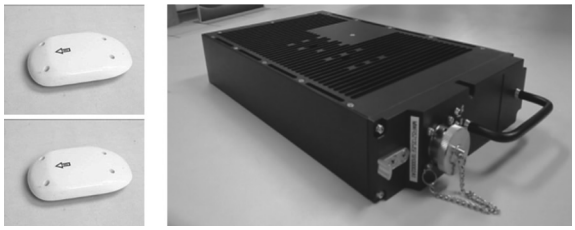

图 5　机载防撞系统

4.1　LSTM-KF 模型仿真

4.1.1　抗干扰性能

试验一:采用航迹目标的相对距离作为训练数据,分别采用 LSTM、CNN、LSTM-KF 等算法进行数据估计,共连续计算 100 个周期,通过统计估计值与真实值的均方根误差(Root Mean Squared Error,RMSE)对算法进行评价分析。试验结果如图 6 和表 2 所示,LSTM-KF 的估计精度相比 LSTM 提高了 36%,相比 CNN 算法提高了 44%,表现出更好的抗干扰性能。

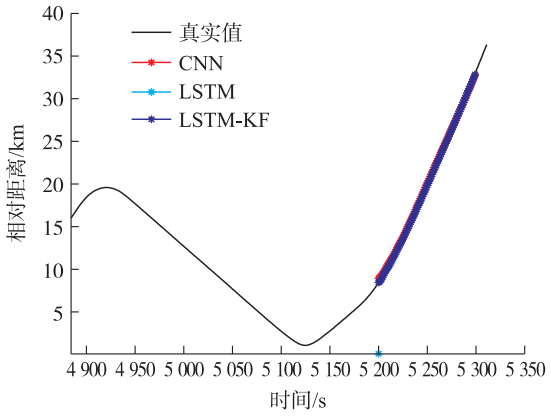

图 6　预测航迹对比

表 2　算法性能对比

算法	LSTM	CNN	LSTM-KF
RMSE	0.098 1	0.112 1	0.062 8

试验二:针对无人机实际运行环境存在传感器测量数据中断的干扰现象,进行多个周期的预测试验,按照实验一的试验方法,采用经过 500 轮训练的 LSTM-KF 模型,分别进行 1、2、4、8、14、16、20 个周期的数据预测,试验结果如图 7 和表 3 所示,随着预测周期的增大,预测的准确度呈下降趋势,但仍然表现出了更高的时序预测精度,当传感器数据中断 16 个周期,RMSE 为 0.601 5,中断 20 个周期,RMSE 为 0.747 9。

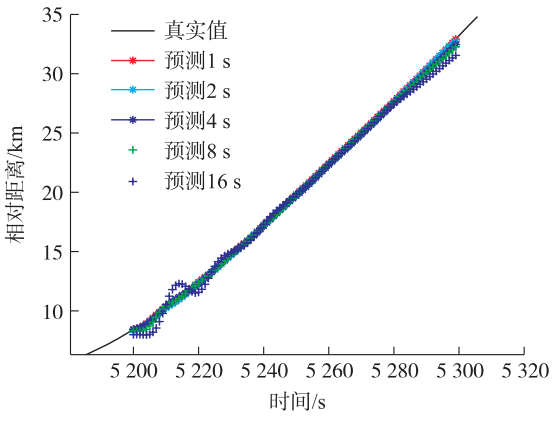

图 7　预测航迹对比

表 3 算法性能对比

算法	RMSE
预测值(1S)	0.062 8
预测值(2S)	0.113 7
预测值(4S)	0.197 7
预测值(8S)	0.254 0
预测值(14S)	0.493 9
预测值(16S)	0.601 5
预测值(20S)	0.747 9

由试验一和试验二可知,LSTM-KF 模型相比 LSTM 和 CNN 算法,数据估计精度有较大的提升,在传感器数据存在连续多个周期中断的情况下,LSTM-KF 仍然具备很好的抗干扰性能。

4.1.2 准确性

试验三:开展感知准确性的对比试验,首先采用 TCAS 测量数据集、雷达测量数据集和目标真值数据值,分别采用 LSTM、CNN、LSTM-KF 等算法进行数据估计,试验结果如图 8 和表 4 所示,其中 TCAS 传感器数据精度 RMSE 为 0.160 5,雷达传感器数据精度 RMSE 为 0.160 5,从估计数据结果分析,LSTM、CNN、LSTM-KF 的估计结果准确性相比原始传感器数据均有较大幅度的提升,其中 LSTM-KF 有更加优异的性能表现,相比 CNN 提高了 68%,相比 LSTM 提高了 36%。

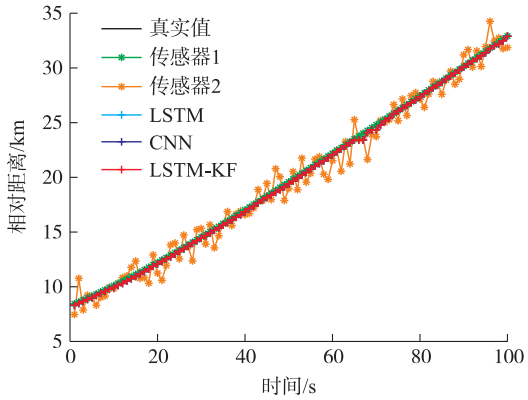

图 8 数据融合性能对比

表 4 算法性能对比

算法	TCAS	雷达	LSTM	CNN	LSTM-KF
RMSE	0.160 5	0.989 0	0.005 0	0.009 8	0.003 2

试验四:针对实际环境下的无人机机载传感器性能恶化等异常情况,开展传感器数据质量下降情况下的感知性能仿真试验。参考试验三的试验方法,并改变雷达传感器的数据质量,分别设置信噪比(Signal-to-Noise Ratio, SNR)为 -4, -2, 0, 2, 4, 6, TCAS 数据质量保持不变,试验结果如图 9 和表 5 所示,当一个传感器性能下降,而另一个传感器性能保持不变的情况下,LSTM-KF 模型感知性能的准确性保持基本稳定,没有出现明显恶化的现象。

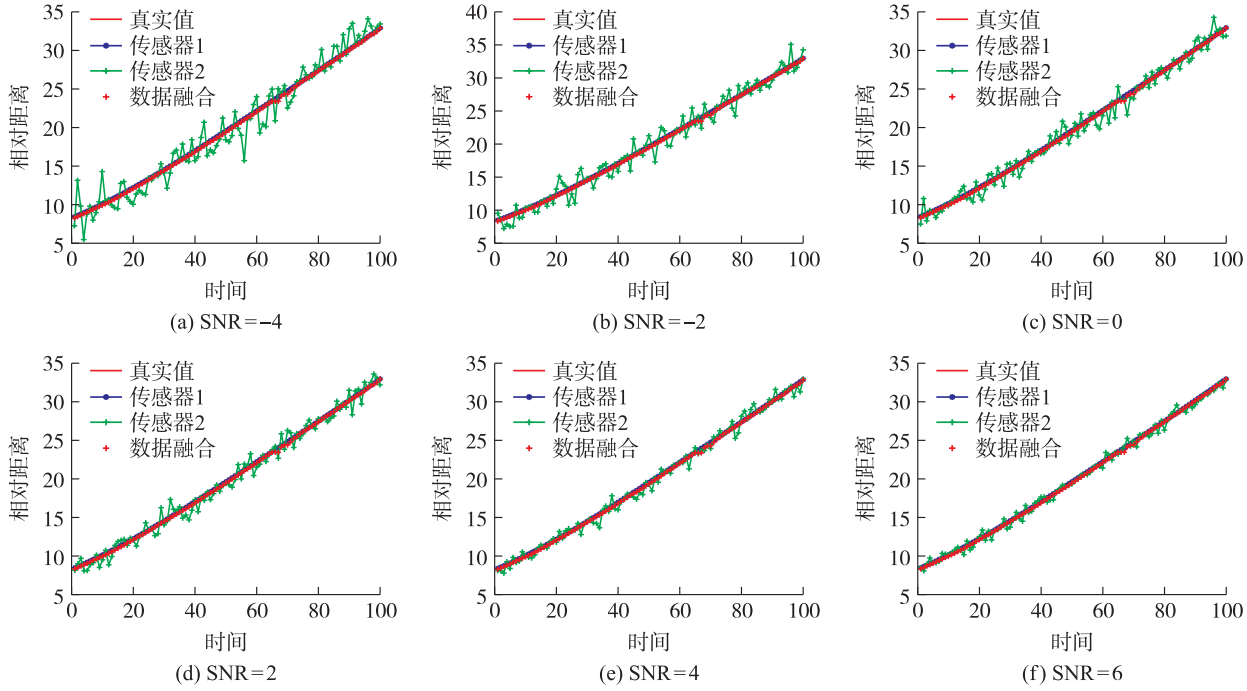

图 9 数据融合性能对比

由试验三和试验四可知,LSTM-KF 模型相比 LSTM 和 CNN 算法模型,具备更好的准确性,同时在其中一个传感器性能下降时,感知准确性没有明显下降,也具备较强的抗干扰性能。

表 5　算法性能对比

信噪比	RMSE（TCAS）	RMSE（雷达）	RMSE（LSTM-KF）
−4	0.160 5	1.626 8	0.004 6
−2	0.160 5	1.231 9	0.005 1
0	0.160 5	0.989 2	0.005 0
2	0.160 5	0.876 3	0.003 6
4	0.160 5	0.628 5	0.004 3
6	0.160 5	0.502 3	0.003 1

4.1.3　综合性能

试验五:为了充分验证算法的抗干扰性、准确性等综合性能,模拟无人机实际运行环境可能存在一路或多路传感器数据中断的情况,设计传感器数据干扰情况下的综合性能试验方案。首先完成 LSTM 先验状态模型和 LSTM 数据融合模型的离线训练,然后开展多源融合感知的模拟实时试验。设置了 4 次传感器数据中断,中断时长分别为 2、4、6、8 个周期,试验结果如图 10 所示,LSTMS 算法出现了航迹中断,LSTM-KF 算法目标航迹连续,RMSE 为 0.038 0,算法表现出良好的准确性和抗干扰性能。

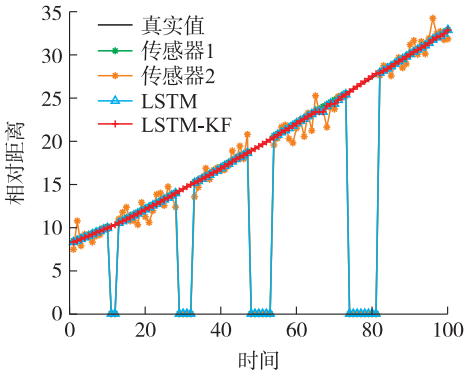

图 10　无人机感知航迹性能对比

4.2　无人机多源异构感知试验

按照图 1 所示的多源异构感知系统架构,开展无人机感知试验,首先从飞行试验采集数据中,选取 TCAS 和有源相控阵雷达的完整传感器测量数据集,得到两种传感器检测得到的相对高度、相对距离和相对方位等测量数据;然后按照图 4 所示的多源异构感知算法流程进行数据有效性判断、先验状态估计和数据融合,完成 LSTM-KF 模型的最优状态估计,最后完成目标识别和航迹融合,实现对障碍物目标的跟踪。

目标感知态势如图 11 所示,目标跟踪稳定连续,能够有效降低传感器数据异常的干扰影响,满足后端任务管理的感知数据准确度要求。

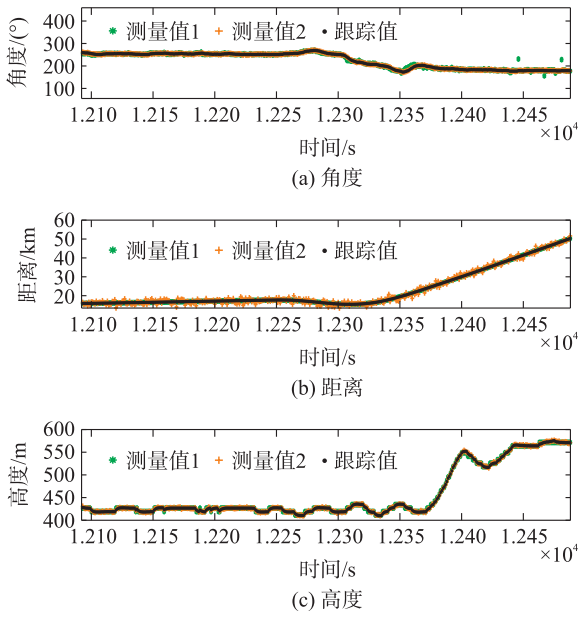

图 11　目标感知态势

5　结论

本文提出的基于 TCAS/ADS-B 和有源相控阵雷达等多源异构传感器融合的无人机自主感知系统架构,TCAS、ADS-B 和机载有源相控阵雷达均实现了低功耗小型化的产品设计实现,能够满足无人机平台轻量化的装机要求。

本文设计的 LSTM-KF 多源异构传感器数据融合模型,通过先验状态 LSTM 时序预测神经网络、观测状态 LSTM 多源数据融合神经网络的模型训练完成特征学习,通过基于卡尔曼增益优化的 KF 最优状态估计算法完成实时的最优状态估计,算法处理的主要工作在离线状态完成,在线预测的计算量较小,计算速度快,占用无人机机载系统资源少,能够满足感知实时性要求。

经过 LSTM-KF 模型仿真和无人机多源异构感知试验,试验结果表明,相比 CNN 算法和 LSTM 模型,算法在感知准确性和抗干扰性方面均有较大的性能提升。在传感器性能下降或者数据中断等异常情况下,感知性能无明显恶化,算法模型具备较强的抗干扰性,能够满足无人机在复杂混合空域环境下的感知性能需求。

本文的相关研究成果对无人机机载自主感知技术研究和应用具备一定参考价值。

参考文献:

[1]　毕红哲,张洲宇,等. 无人机感知与规避技术研究进展[J]. 电子测量与仪器学报,2016,30(5):661-668.

[2]　吴鑫炜,胡明华,毛继志,等. 基于空间谱估计的无人

机协同目标方位感知算法[J]. 西南交通大学学报,2024,59(4):898-906.
[3] 刘康,何明浩,韩俊,等. 基于多传感器的雷达对抗侦查数据融合算法[J]. 系统工程与电子技术,2023,45(1):101-107.
[4] 程传祺. 基于深度学习的数据融合方法研究[D]. 兰州:兰州理工大学,2021.
[5] Chen H, Hu N, Cheng Z, et al. A Deep Convolutional Neural Network Based Fusion Method of Two-Direction Vibration Signal Data for Health State Identification of Planetary Gearboxes[J]. Measurement, 2019, 146(11): 268-278.
[6] Wu J, Hu K, Cheng Y, et al. Data-Driven Remaining Useful Life Prediction via Multiple Sensor Signals and Deep Long Short-Term Memory Neural Network[J]. ISA Transactions, 2019, 97(6): 241-250.
[7] Fu H, Ma H, Wang G, et al. Multiscale Comprehensive Feature Fusion Convolutional Neural Network for Vehicle Color Recognition Based on Residual Learning[J]. Neurocomputing, 2020, 395(4): 178-187.
[8] 张立奎,段大猷,王佐才,等. 基于 LSTM 神经网络的多源数据融合桥梁变形重构方法[J]. 土木与环境工程学报,2022,44(3):37-43.
[9] 刘金铭,张玉艳,张碧玲. 基于 LSTM-KF 的无人机航迹跟踪算法[J]. 北京邮电大学学报,2022,45(5):121-128.
[10] Sahawneh L R, Duffield M O, Beard R W, et al. Detect and Avoid for Small Unmanned Aircraft Systems Using ADS-B [J]. Air Traffic Control Quart, 2015, 23(1): 203-240.
[11] Accardo D, Fasano G, Forlenza L, et al. Flight Test of a Radar-Based Tracking System for UAS Sense and Avoid [J]. IEEE Transactions on Aerospace Electronic Systems, 2013, 49(4): 1139-1160.
[12] Owen M P, Duffy S M, Edwards M W. Unmanned Aircraft Sense and Avoid Radar: Surrogate flight Testing Performance Evaluation[C]//2014 IEEE Radar Conference, Cincinnati, OH, USA, 2014: 548-551.
[13] Lai J, Mejias L, Ford J J. Airborne Vision-Based Collision-Detection System[J]. Field Robot, 2011, 28(1): 137-157.
[14] Newmeyer L, Wilde D, Nelson B, et al. Efficient Processing of Phased Array Radar in Sense and Avoid Application Using Heterogeneous Computing[C]//2016 26th International Conference on Field Programmable Logic and Applications(FPL), Lausanne, Switzerland, 2016: 1-8.
[15] Meng T, Jing X Y, Yang Z, et al. A Survey on Machine Learning for Data Fusion[J]. Information Fusion, 2020, 57(3): 115-129.
[16] Zhang M Y, Cai X B, Wang X K, et al. Photovoltaic Maximum Power Point Tracking Algorithm Based on LSTM-FLC [J]. Chinese Journal of Electron Devices, 2024, 47(1): 201-208.
[17] Wang S Y, Feng J C, Tan C K. Spherical Simplexradial Cubature Kalman Filter[J]. IEEE Signal Processing Letters, 2014, 21(1): 43-46.

吴鑫炜(1985—),男,博士,主要研究方向为交通运输规划、无人机智能运行。wxw8237@163.com;

胡明华(1962—),男,教授,博士生导师,主要研究方向为空中交通管理、机场运行与管理。