

DOI:10.19651/j.cnki.emt.2208843

一种基于 C-GRU 的飞行轨迹预测方法^{*}

钱来王伟

(西安工程大学计算机科学学院 西安 710048)

摘要: 飞行轨迹是由大量时间序列数据组成,遵循一定的运动规则。对敌方巡逻机飞行轨迹进行预测,能有效的提高战斗机生存率。针对现有单一预测模型对飞行轨迹预测精度不高,提出一种基于复合门控循环单元飞行轨迹预测方法。使用飞行仿真模拟获取多组飞行轨迹坐标点数据,用于复合门控循环单元网络模型参数训练,实现飞行轨迹预测。通过仿真结果分析,复合门控循环单元网络模型在X、Y、Z轴上的多组预测数据平均绝对误差在4.5 m内,且网络模型预测平均时间开销约为4.1 ms;使用平均绝对误差变化较大与较小的轨迹数据进行对比,其Y与Z轴的两组均方根误差相近。同时与门控循环单元、长短期记忆网络模型对比,其误差最小,在平均耗时接近的情况下预测的结果更加准确。所以本文提出的模型适用于不同的飞行轨迹,而且预测结果具有较高的可信度。

关键词: 飞行轨迹预测;门控循环单元;长短期记忆;时序性;飞行仿真

中图分类号: TP301.6 文献标识码: A 国家标准学科分类代码: 510.4030

A C-GRU based flight trajectory prediction method

Qian Lai Wang Wei

(School of Computer Science, Xi'an Polytechnic University, Xi'an 710048, China)

Abstract: The flight trajectory is composed of a large amount of time series data and follows certain motion rules. Predicting the flight trajectory of enemy patrol aircraft can effectively improve the survival rate of fighter jets. This paper proposes a flight trajectory prediction method based on C-GRU, aiming at the low accuracy of flight trajectory prediction by the existing single prediction model. Use flight simulation to obtain multiple sets of flight trajectory coordinate point data for C-GRU network model parameter training to achieve flight trajectory prediction. Through the analysis of simulation results, the average absolute error of multiple sets of prediction data on the X, Y, and Z axes of the C-GRU network model is within 4.5 m, and the average time overhead of network model prediction is about 4.1 ms; Compared with the smaller trajectory data, the two sets of root mean square errors of the Y and Z axes are similar. At the same time, compared with the GRU and LSTM network models, the error is the smallest, and the predicted results are more accurate when the average time-consuming is close. Therefore, the model proposed in this paper is suitable for different flight trajectories, and the prediction results have high reliability.

Keywords: flight trajectory prediction; GRU; LSTM; time series; flight simulation

0 引言

飞行轨迹预测是空中作战躲避威胁的关键点,随着无人机的快速发展,其在军事作战侦察领域的应用日益增加^[1]。在执行侦察任务前,需要规划一条最优的任务轨迹,但作战环境是复杂多变的,当面对敌方巡逻机,需要预测出它在未来一段时间内的飞行轨迹,为无人机任务规划提供数据,避免与敌方巡逻机相遇^[2]。如何通过已知的信息,实时、准确的预测出敌方巡逻机在未来一段时间内飞行轨迹,从而实

主动的躲避,减少任务中的损失,是飞行轨迹预测的研究重点。轨迹预测问题的实质是对具有长时间序列的数据进行预测,这类数据具有非线性和时变性的特点^[3]。关于飞行轨迹预测,目前主要有数据化和模型化这两类方法^[4]。

关于数据化方法的研究,谭伟等^[5]对BP神经网络的权值使用遗传算法进行优化,创建移动目标轨迹预测模型,实现较高的预测准确度;杨任农等^[6]在BP神经网络的基础上进行改进,实现NARX神经网络的预测模型,其可以

收稿日期:2022-01-13

* 基金项目:2021年中国高校产学研创新基金(2021ALA02002)、2021年“纺织之光”中国纺织工业联合会高等教育教学改革研究项目(2021BKJGLX004)、西安工程大学2020年高等教育研究项目(20GJ05)资助

快速收敛且预测结果更好;张涛等^[7]基于动态递归神经网络的战斗机作战轨迹预测模型,测试的数据集为空战测量仪(ACMI)飞行过程中采集的数据,数据更加具有真实性,此预测模型比基于粒子滤波算法预测模型更加准确。这类方法的优点是不需要建立飞行模型,只是从数据出发,运用机器学习去计算数据背后的规律。缺点是数据比较单一,没有考虑到各种复杂的飞行姿态。

关于模型化方法的研究,汤新民等^[8]利用不同飞行阶段动力学模型,创建基于时变混杂系统的 4D 轨迹推测模型,可在 4D 轨迹推测方面可以做到快速准确;乔少杰等^[9]提出一种基于卡尔曼滤波算法,利用前一个时刻位置预测值和当前时刻位置观测值,对下一时刻轨迹位置进行预测的方法,其具有较高的准确度;Baklacioglu 等^[10]提出了一种采用遗传算法对运输机的飞行轨迹预测模型,做到了快速收敛。这类方法虽然提高了预测的准确性但是对模型结构要求较高,在遇到复杂的模型预测时会比较困难。

在 Hinton 利用深度学习进行图像分类取得 ImageNet 大赛冠军后,很多研究人员开始注意到深度学习,其在处理具有时间序列特点的数据有一定的优势,部分研究人员在飞行轨迹预测领域引入深度学习。Tharindu 等^[11]基于长短期记忆(long short-term memory, LSTM)神经网络预测道路上行人的行进轨迹,具有良好的预测能力;胡玉可等^[12]基于门控循环单元(gated recurrent unit, GRU)神经网络模型对轮船轨迹进行预测,作为 LSTM 神经网络的一种变体,预测效果更加准确。但是使用单一网络模型存在预测精度不足^[13]。为了进一步提高轨迹预测的准确度,本文提出将 GRU 神经网络和径向基函数(radial basis function, RBF)神经网络结合的复合门控循环单元神经网络(composite gated recurrent unit, C-GRU)飞行轨迹预测网络模型。利用 RBF 神经网络对 GRU 单元神经网络误差输出值进行修正,并且为了飞行轨迹预测的准确性要求,提出运用由自适应算法 ADAM 改进而来的 AMS 优化算法来优化整个网络模型。通过使用仿真飞行轨迹数据,与现有网络模型进行仿真实验对比。在保证网络预测时间开销跟现有模型时间开销没有太大差距的前提下,提高模型对飞行轨迹的预测精度。降低被敌方巡逻机发现的概率,提高战场生存率。

1 问题描述

在三维环境飞机轨迹预测问题中,飞机轨迹既有交互性特征,同时在周期内由大量的时间序列数据组成^[14]。在三维坐标系 O_{xyz} 中,假设飞行轨迹 l 是由众多经纬高三维航迹点组成,具体可表示为:

$$\begin{cases} l = \{l_1, l_2, l_3, l_4, \dots, l_n\} \\ l_i = \{(x_{i1}, y_{i1}, z_{i1}), (x_{i2}, y_{i2}, z_{i2}), \dots, (x_{im}, y_{im}, z_{im})\} \end{cases} \quad (1)$$

式中: l_i 为第 i 条飞行轨迹; (x_{ij}, y_{ij}, z_{ij}) 为第 i 条飞行轨迹

在 j 时间的三维航迹点, m 为一条飞行轨迹上采样的航迹点数量。

在预测中,假设飞行轨迹中的 x 、 y 、 z 轴的运动互相独立,以 x 轴为例,敌方巡逻机实际运行数据集为:

$$X = (x_1, x_2, x_3, x_4, \dots, x_n)^T \quad (2)$$

式中:第 i 条飞行轨迹 $x_i = (x_{i1}, x_{i2}, x_{i3}, x_{i4}, \dots, x_{im})$ 。设敌方巡逻机在 x 轴上的预测飞行轨迹为数据集为:

$$X' = (x'_1, x'_2, x'_3, x'_4, \dots, x'_n)^T \quad (3)$$

式中:第 i 条预测飞行轨迹为 $x'_i = (x'_{i1}, x'_{i2}, x'_{i3}, x'_{i4}, \dots, x'_{im})$ 。飞行轨迹预测问题表述为:

$$X' = f(X) \quad (4)$$

式中: f 为飞行轨迹预测模型函数关系映射。

2 基于 C-GRU 飞行轨迹预测模型

2.1 RBF 神经网络

RBF 神经网络是具有局部逼近能力的神经网络。其具有极佳的非线性函数逼近能力、可以克服局部最小值、收敛速度快和学习规则简单的特点。RBF 神经网络有输入层、隐藏层和输出层三层结构。层与层之间是单向链接,其中输入层映射到隐藏层使用的是非线性变换,而隐藏层映射到输出层使用的是线性变化。实验数据通过输入层单元传送到隐藏层,隐藏层神经单元通过径向基函数传递给输出层,然后由输出层给出结果。RBF 神经网络如图 1 所示。

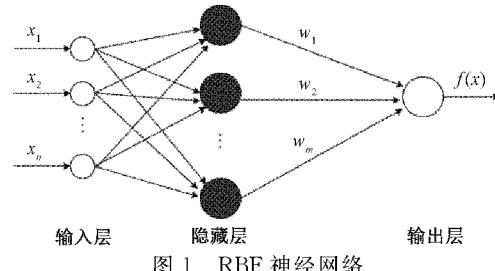


图 1 RBF 神经网络

输入层和输出层的函数关系:

$$f(x) = \sum_{i=1}^m w_{ij} \exp\left(-\frac{1}{2\sigma^2} \|x - c_i\|^2\right) \quad (5)$$

式中: c_i 为基函数的中心; w_{ij} 为权值向量; σ 为基函数扩展带宽。

2.2 门控循环单元

门控循环单元是一种循环神经网络的变种模型^[15]。梯度爆炸与梯度消失是循环神经网络所面临的问题之一,LSTM 将其改进引入输入门、遗忘门和输出门等结构对输入的数据进行挑选和过滤,提高了对长时间序列的记忆处理能力^[16]。但是 LSTM 神经网络需要计算的参数比较多,计算复杂。因此在 LSTM 基础上再进一步改进优化,将输入门、遗忘门和输出门整合为更新门和重置门得到 GRU,结构如图 2 所示。在表达方面更加简练,计算速度进一步提升。研究表明 GRU 在时间序列预测任务中表现出良好的性能。

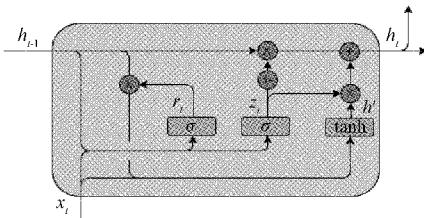


图 2 GRU 结构

在 GRU 中,通过重置门 r_t 和更新门 z_t 来更新和操控模型状态变换,重置门 r_t 用来划分需要遗忘历史状态信息的比例,达到控制信息的传递,保证重要时序信息向下面传递;更新门 z_t 用来划分 $t-1$ 时刻的状态信息去往当前时刻 t 的比例。在给定 t 时刻的输入值 x_t ,重置门状态 r_t 和更新门状态 z_t 由公式计算,有:

$$r_t = \sigma(x_t w_r + h_{t-1} W_r + b_r) \quad (6)$$

$$z_t = \sigma(x_t w_z + h_{t-1} W_z + b_z) \quad (7)$$

式中: w_r, W_r, w_z, W_z 为 r_t 和 z_t 的权重系数矩阵; b_r 和 b_z 分别为 r_t 和 z_t 的偏置量; h_{t-1} 为 $t-1$ 时刻的状态; σ 为激励函数。当重置门 r_t 关闭并接近 0, 网络会忘记历史信息, 在获取短期有用信息时效果更佳;当更新门 z_t 接近 1, 历史信息会网络中传递, 网络可以“记忆”长期信息。

获得 r_t 和 z_t 状态后, 计算临时状态 h' , 通过于 $t-1$ 时刻的状态 h_{t-1} 进行计算, 得到当前时刻 t 的输出状态, 有:

$$h' = \tanh(x_t w_h + (h_{t-1} \odot r_t) W_h + b_h) \quad (8)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot h' \quad (9)$$

式中: w_h 和 W_h 为临时状态 h' 的权重; b_h 为临时状态 h' 的偏置量; \tanh 为激励函数。

2.3 飞行轨迹预测模型

飞行轨迹的三维坐标位置随着时间的变化在不断改变, 具有非线性的特点。因此无法采用常见的线性函数对飞行轨迹进行处理和预测。但是在处理复杂的时间序列数据时神经网络可以展示出很好的性能。因此, 本文构建了基于 C-GRU 飞行轨迹预测模型, 可以根据已有的信息预测敌方的巡逻机在未来一段时间内的飞行轨迹。

为了提高轨迹预测的准确度和可靠度, 本文把航迹点数据采样定为每 0.25 s 采集一次, 取前 3 个时刻的航迹点数据去预测后 1 个时刻的航迹点^[6]。研究人员曾分别采用三维航迹点各轴关联预测和单独预测, 分析两者的预测准确度, 本文使用三维航迹点各轴单独预测的形式^[17 18]。将 X、Y、Z 轴三个数据分别输入到 C-GRU 网络模型中进行预测, 将输出的预测结果合并成飞行轨迹点坐标。飞行轨迹预测模型结构如图 3 所示。

主要步骤如下:

- 1) 获取数据集。利用飞行动力学模型对飞行进行仿真, 获取航迹点坐标。
- 2) 制作模型的训练集和测试集。
- 3) 进入 GRU 神经网络进行网络模型训练, 使用 AMS

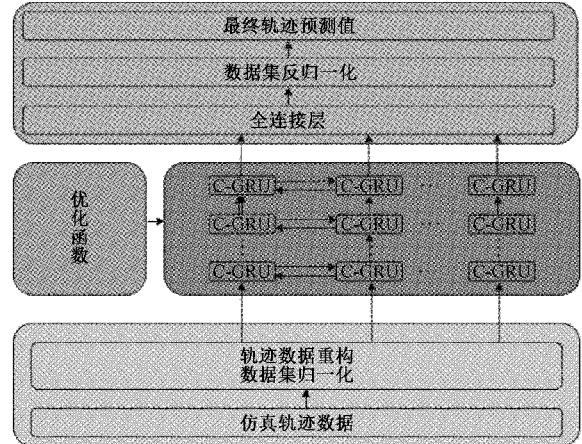


图 3 飞行轨迹预测模型结构

自适应优化算法对网络模型进行优化。

4) 把训练集输入到训练好的 GRU 神经网络模型, 输出预测值 P , 将其与实际值 P_r 作差, 得出误差 $error$:

$$error = P_r - P \quad (10)$$

5) 把误差 $error$ 与训练集的输入结合, 构造成新的数据集, 把误差 $error$ 作为网络模型输出数据。

6) 将重新构建的数据集输入 RBF 神经网络模型进行误差值修正训练, 使用 AMS 自适应优化算法对网络模型进行优化。

7) C-GRU 网络模型输出的预测值 $P_f = P + error_p$, $error_p$ 是 RBF 神经网络对误差修正的预测。

3 仿真实验与分析结果

3.1 实验数据集

本文训练和测试的数据集均来自飞行动力学模型仿真获取到的数据。在仿真中使用推进力、上升力和滚转角来对敌方巡逻机进行控制;不考虑地球自转和公转对敌方巡逻机的影响;敌方巡逻机的飞行速度方向与机体方向近似一致。动力学模型公式表示为^[19]:

$$\left. \begin{aligned} \frac{dx}{dt} &= v \cos\varphi \sin\theta \\ \frac{dy}{dt} &= v \cos\varphi \cos\theta \\ \frac{dz}{dt} &= v \sin\varphi \\ \frac{dv}{dt} &= g(n_x - \sin\varphi) \\ \frac{d\varphi}{dt} &= \frac{g}{v}(n_z \cos\mu - \cos\varphi) \\ \frac{d\theta}{dt} &= \frac{gn_z \sin\mu}{v \cos\varphi} \end{aligned} \right\} \quad (11)$$

式中: x, y, z 为敌方巡逻机在三维地理环境中的飞行轨迹坐标; v 为敌方巡逻机的飞行速度; φ 为敌方巡逻机的航迹角; θ 为敌方巡逻机的航向角; μ 为敌方巡逻机的滚转角;

g 为地球重力加速度, 取 9.8 m/s^2 ; n_x 为敌方巡逻机的轴向过载; n_z 为敌方巡逻机的法向过载。

为了提升模型对飞行轨迹预测的准确度, 而且可以尽量考虑到不同的飞行状态^[20-21]。所以设置飞行动力学仿真模型的航迹角 φ 为 $-40^\circ \sim 40^\circ$; 滚转角 μ 为 $-45^\circ \sim 45^\circ$; 飞行速度 v 为 $20 \sim 120 \text{ m/s}$ 。

本文通过飞行动力学模型进行仿真, 随机生成 12 条飞行轨迹^[22]。其中每段轨迹的前 3 000 个飞行轨迹坐标点为预测模型的训练样本, 后 500 个坐标点为模型测试样本, 用来验证预测模型的性能。在进行训练和预测之前将飞行轨迹进行数据归一化处理, 用来提升飞行轨迹预测模型的性能, 归一化公式如下^[23-24]:

$$S = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (12)$$

式中: X_{\max} 表示为飞行轨迹坐标的最大值、 X_{\min} 表示为飞行轨迹坐标的最小值; S 表示飞行轨迹航迹点归一化值。

3.2 模型参数确定

本文根据飞行轨迹数据集特点及预测的时效性。设置 GRU 神经网络设置为 3 层隐藏层, 每个隐藏层节点数为 110, 学习率为 0.000 2, 激活函数使用 tanh 函数, RBF 神经网络设置为 2 层隐藏层, 每个隐藏层节点数为 120, 学习率为 0.000 1。

为了确定一组参数可以让损失函数达到最小, 当 Adam 在二阶矩估计采用移动指数加权平均的方法, 容易造成学习率在来回波动, 使网络模型无法收敛到最优^[25-26]。因此, 本文使用 Adam 的变种算法 AMS 自适应优化算法, 对网络模型进行优化。具体公式如下:

$$\begin{cases} g_t = \nabla f_t(w_t) \\ m_t = \beta_1 m_{t-1} + (1-\beta_1) g_t \\ v_t = \beta_2 v_{t-1} = (1-\beta_2) g_t^2 \\ \bar{v}_t = \max(v_{t-1}, v_t) \\ w_{t+1} = w_t - \frac{\eta \times m_t}{\sqrt{v_t} + \epsilon} \end{cases} \quad (13)$$

式中: $f(w)$ 为映射函数; w 为网络需要优化的参数; m 表示为一介动量; v 表示为二阶动量; β_1 和 β_2 表示为超参数; η 表示为学习率。

3.3 网络模型评价函数

使用均方根误差(root mean square error, RMSE)和平均绝对误差(mean absolute error, MAE)用来评价网络模型优差^[27]。

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (14)$$

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (15)$$

式中: y 表示为实际飞行轨迹值; \hat{y} 表示为预测飞行轨迹值; m 表示为飞行轨迹样本数量。

3.4 实验结果分析

1) 损失图对比

通过实验结果分析 Adam 和 AMS 优化算法的在测试和训练中的损失。如图 4 所示, Adam 优化的网络模型在训练到 150 次后损失逐渐趋于稳定, 在 1.2×10^{-2} 上下浮动。如图 5 所示, AMS 优化的网络模型在训练到 55 次后损失趋于稳定, 在 9.7×10^{-3} 上下浮动。所以 AMS 自适应优化算法和 Adam 自适应优化算法相比在收敛速度上有所提升^[28]。所以 AMS 自适应优化算法可以提升基于 C-GRU 飞行轨迹预测模型的性能。

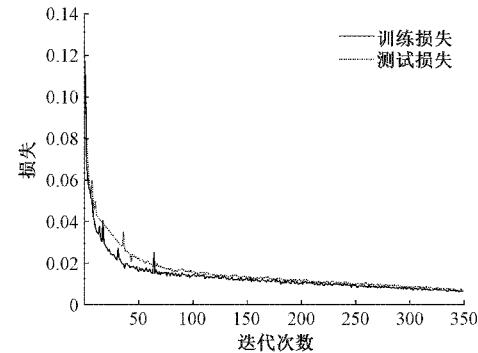


图 4 Adam 算法损失值

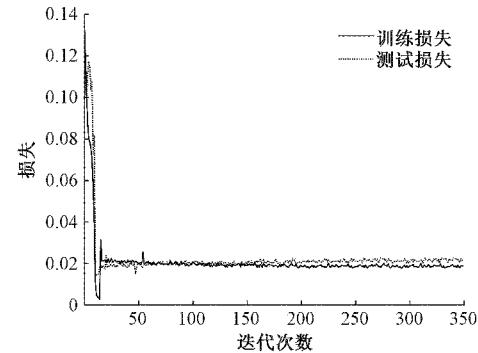


图 5 AMS 算法损失值

2) 预测数据分析

根据本文建立的基于 C-GRU 的飞行轨迹预测模型。利用飞行动力学模型仿真生成 12 组飞行航迹点数据, 构建数据集用来训练和验证网络模型的实际性能。整理出实验数据, 如表 1 所示。在预测的 12 组飞行轨迹数据中, X 轴的 MAE 最大为 3.57 m、最小为 0.56 m; Y 轴的 MAE 最大为 4.26 m、最小为 1.22 m; Z 轴的 MAE 最大为 4.50 m、最小为 1.20 m。所以, 基于 C-GRU 飞行轨迹预测方法可以较好的解决预测精度问题。

为直观的展现 C-GRU 在飞行轨迹预测的优势。本文选取现有的 GRU 和 LSTM 网络模型进行仿真实验对比。利用平均绝对误差 3 个方向变化较小的第 2 组和变化较大的第 11 组仿真飞行轨迹数据进行仿真实验。

表 1 飞机轨迹预测结果

轨迹数据	1	2	3	4	5	6	7	8	9	10	11	12	m
平均绝对 误差 MAE	X 轴	0.56	1.73	3.55	3.01	2.52	2.94	2.33	3.44	3.41	2.12	3.57	2.08
	Y 轴	1.37	1.50	3.43	2.31	4.26	3.14	1.51	2.54	1.81	4.01	1.22	2.55
	Z 轴	1.25	1.31	2.81	2.12	3.74	4.50	2.41	3.91	2.66	2.67	1.20	4.26

如图 6 所示,C-GRU 飞行轨迹预测模型,其预测结果比现有网络模型预测的结果更加贴近实际飞行轨迹。如图 7 所示,C-GRU 预测模型对各轴轨迹预测的均方根误差均小于其他现有网络模型,其预测精度与 GRU 相比提高了 21.3%,与 LSTM 相比提高了 36.7%。

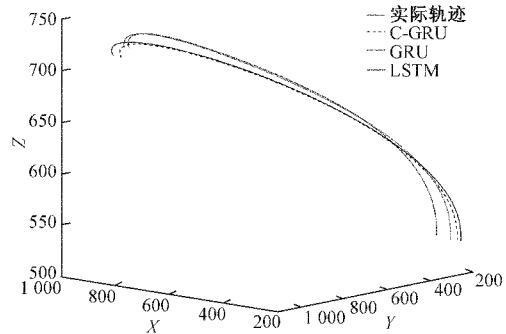


图 6 第 2 组轨迹数据仿真对比结果

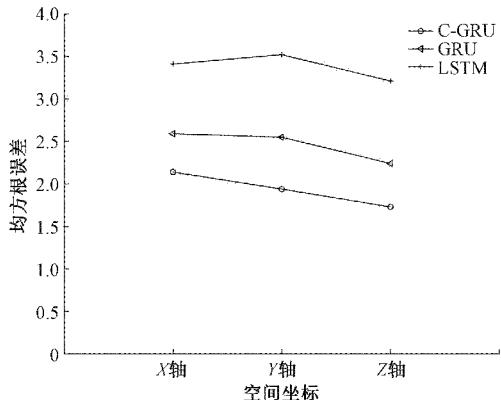


图 7 第 2 组轨迹数据各轴均方根误差

如图 8 所示,第 11 组飞行轨迹中有小角度的转向,在预测精度上没有第 2 组数据预测的高,但是与现有模型相比在精度的上仍有优势。如图 9 所示,C-GRU 预测精度与 GRU 相比提高了 18.5%,与 LSTM 相比提高了 23.7%。而且使用 C-GRU 模型对这两组数据进行预测,其均方根误差在 Y 轴和 Z 轴上误差相近。因此 C-GRU 飞行轨迹预测模型的准确度更高,适用于不同的飞行状态轨迹,可以有效的反映敌方巡逻机的飞行轨迹。

如图 10 所示,C-GRU 预测模型平均时间开销较大,平均耗时约耗时 4.1 ms。但是与现有的轨迹预测模型平均时间开销相近,而且敌方巡逻机在预测模型开销时间内飞行轨迹变化一般比较小。所以基于 C-GRU 的飞行轨迹预

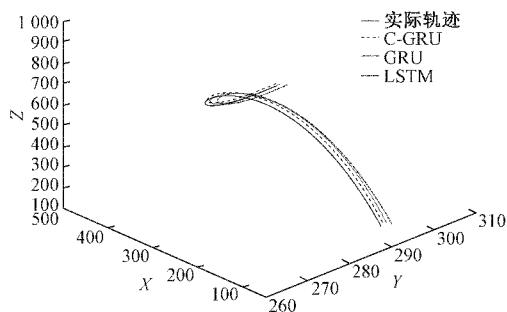


图 8 第 11 组轨迹数据仿真对比结果

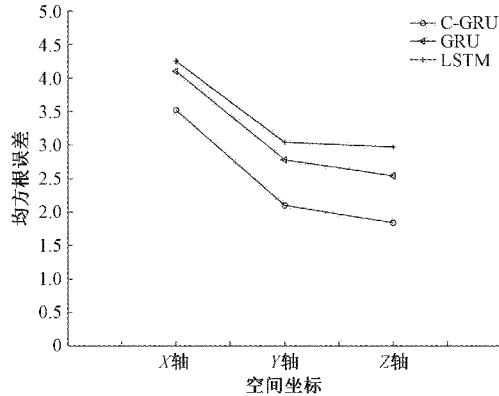


图 9 第 11 组轨迹数据各轴均方根误差

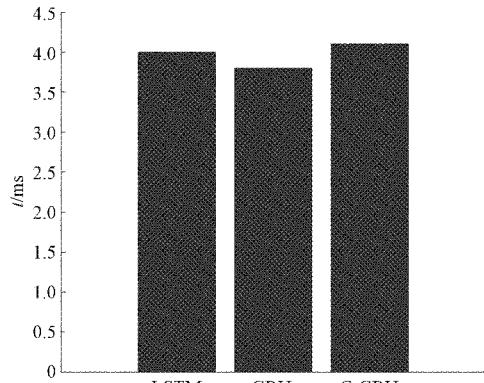


图 10 预测模型平均时间开销

测模型在实际应用中具有良好的时间效率。

4 结 论

本文主要解决无人机在航迹规划过程中,对敌方巡逻机的飞行轨迹变化进行提前预测,来对无人机的航迹进行调整。提出一种基于 C-GRU 飞行轨迹预测方法,使

RBF 网络对 GRU 网络预测的误差进行修正, 来提高轨迹的预测精度。将 C-GRU 预测模型与现有的 GRU、LSTM 预测模型进行一系列的仿真实验。实验结果表明, C-GRU 模型在时间开销与现有模型相差不大的情况下, 平均预测精度与 GRU 相比提高了 19.9%, 与 LSTM 相比提高了 30.2%。在飞行轨迹预测方面 C-GRU 飞行轨迹预测模型具有良好的实际应用价值。但是目前的网络模型在 X 轴方向上的预测精度相对于 Y 轴和 Z 轴存在一定的差距, 下一步的研究计划着重解决如何提高模型对转向区域的预测精度。

参考文献

- [1] 杨大鹏, 张丕状, 姚金杰. 基于 RFID 无人机数据综合管理系统设计[J]. 国外电子测量技术, 2020, 39(5): 55-60.
- [2] 樊玉琦, 刘瑜岚, 许雄, 等. 基于点迹时空关系的雷达目标航迹识别[J]. 电子测量与仪器学报, 2020, 34(9): 108-116.
- [3] 张志远, 倪国新, 徐艳国. 轨迹预测技术的现状及发展综述[J]. 电子测量技术, 2020, 43(13): 111-116.
- [4] SLATTERY R, ZHAOY. Trachatory sysisis for air traffic automation[J]. Journal of Guidance, Control and Dynamics, 1997, 20(2): 232-238.
- [5] 谭伟, 陆百川, 黄美灵. 神经网络结合遗传算法用于航迹预测[J]. 重庆交通大学学报(自然科学版), 2010, 29(1): 147-150.
- [6] 杨任农, 张振兴, 张滢, 等. 基于 NARX 神经网络的飞机飞行性能模型预测[J]. 西北大学学报, 2017, 47(1): 7-12.
- [7] 张涛, 郭基联, 徐西蒙, 等. 基于 Elman 神经网络的战斗机空战轨迹预测[J]. 飞行力学, 2018, 36(5): 86-91.
- [8] 汤新民, 韩云祥, 韩松臣. 基于混杂系统模型的航空器 4D 航迹推测[J]. 南京航空航天大学学报, 2012, 44(1): 105-112.
- [9] 乔少杰, 韩楠, 朱新文, 等. 基于卡尔曼滤波的动态轨迹预测算法[J]. 电子学报, 2018, 46(2): 418-423.
- [10] BAKLACIOGLU T, CAVCAR M. Aero propulsive modeling for climb and descent trajectory prediction of transport aircraft using genetic algorithms [J]. The Aeronautical Journal, 2014, 118: 66-73.
- [11] THARINDU F, SIMON D, SRIDHA S, et al. An LSTM framework for human trajectory prediction and abnormal event detection[J]. Neural Networks, 2018, 108: 466-478.
- [12] 胡玉可, 夏维, 胡笑旋, 等. 基于循环神经网络的船舶航迹预测[J]. 系统工程与电子技术, 2020, 42(4): 871-877.
- [13] 徐国庆, 马建文, 吴晨辉, 等. 基于 Attenton-LSTM 神经网络的船舶航行预测[J]. 舰船科学技术, 2019, 41(23): 177-180.
- [14] 王昊, 刘震. 基于信息感知权重和误差预测的时间序列在线预测方法[J]. 仪器仪表学报, 2020, 41(11): 31-41.
- [15] 牛哲文, 余泽远, 李波, 等. 基于深度门控循环单元神经网络的短期风功率预测模型[J]. 电力自动化设备, 2018, 38(5): 36-42.
- [16] 张驰, 郭媛, 黎明. 人工神经网络模型发展及应用综述[J]. 计算机工程与应用, 2021, 57(11): 57-69.
- [17] 王新, 杨任农, 左家亮, 等. 基于 HPSO-TPFENN 的目标机轨迹预测[J]. 西北工业大学学报, 2019, 37(3): 612-620.
- [18] ZENG W L, QUAN ZH B. A deep learning approach for aircraft trajectory prediction in terminal airspace [J]. Access, 2020, 8: 151250-151266.
- [19] VIRTANEN K, RAIPIO T. Modeling pilots sequential maneuvering decisions by a multistage influence diagram[J]. Journal of Guidance, Control, and Dynamics, 2004, 27(4): 665-677.
- [20] PENG H, WANG H F, DU B W, et al. Spatial temporal incidence dynamic graph neural networks for traffic flow forecasting [J]. Information Sciences, 2020, 521: 14-15.
- [21] WANG Q Y, ZHANG Z L, WANG Z Y, et al. The trajectory prediction of spacecraft by grey method [J]. Measurement Science and Technology, 2016, 27(8): 085011.
- [22] QIAO S J, SHEN D Y, WANG X T, et al. A self-adaptive parameter selection trajectory prediction approach via hidden Markov models [J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(1): 284-296.
- [23] 王泽天, 高岭, 高全力. 基于改进马尔科夫链的移动轨迹预测方法[J]. 西安工程大学学报, 2020, 34(2): 97-102.
- [24] 周捷, 马秋瑞, 李健, 等. 基于 BP 和 GRNN 神经网络的乳房运动轨迹预测[J]. 西安工程大学学报, 2019, 32(2): 117-122.
- [25] 徐圣良. 一种无人战斗机飞行轨迹的跟踪方法[J]. 西安工程大学学报, 2016, 30(4): 464-470.
- [26] 储开斌, 郭俊俊. 智能车运动轨迹跟踪算法的研究[J]. 电子测量与仪器学报, 2020, 34(6): 131-137.
- [27] CHENG Q, ARGON N T, EVANS C S, et al. Forecasting emergency department hourly occupancy using time series analysis [J]. American Journal of Emergency Medicine, 2021, 48.
- [28] KESKAR N S, SOCHER R. Improving generalization performance by switching from adam to SGD [J]. ArXiv Preprint, 2017, ArXiv:1712.07628.

作者简介

钱来, 硕士研究生, 主要研究方向为无人任务分配、无人机自组网、网络安全。

E-mail: 2458619593@qq.com

王伟, 副教授, 主要研究方向为网络信息安全、网络智能化应用。

E-mail: 17445643@qq.com