

基于数据驱动的机动目标跟踪



马云红¹,李欣怡¹,王泽霖¹,曹天航¹,王永坤²

1.西北工业大学,陕西 西安 710072

2.中国航空工业集团公司雷华电子技术研究所,江苏 无锡 214063

摘要:目标跟踪是进行目标精准打击的关键,特别是对于机动目标的精确跟踪可以提高对目标状态的估计精度,从而实现目标的精确打击任务。针对机动目标跟踪问题,基于神经网络理论,本文提出了基于数据驱动的机动目标跟踪算法。通过生成大量不同机动方式运动的飞行数据,建立目标机动的数据样本库,采用基于双向输入的深度学习神经网络,对大量不同的机动飞行数据进行训练,生成不同机动轨迹的模型,通过轨迹序列数据与不同机动模型匹配,实现对任意机动目标的运动轨迹预测,进而实现对机动目标的跟踪。仿真结果验证了基于数据驱动进行目标跟踪算法的有效性,提供了机动目标轨迹预测的新思路和新方法,提升了轨迹预测的时效和精度。

关键词:神经网络;数据驱动;机动目标;目标跟踪;轨迹预测

中图分类号:TN953

文献标识码:A

DOI: 10.19452/j.issn1007-5453.2024.04.013

目标跟踪技术在视觉导航和军事侦察等领域具有广泛的应用。目标跟踪是以既定目标的观测位置状态作为参考,在后续时刻准确预测该目标的状态,从而实现对目标的稳定跟踪。对于机动目标跟踪,多模型交互(IMM)算法是一种有效的算法,也得到一些学者的深入研究。Bar-Shalom等^[1]提出了将目标机动建模为目标状态模型的切换,采用IMM算法来估计目标状态,验证了IMM算法比传统滤波器效果更好。尹聚祺和赵楚楚等^[2-3]提出了自适应交互式多模型算法,提高了模型集的自适应能力,优化了不同模型集的计算量。邵堃等^[4]提出了一种自适应交互多模型算法,引入模糊逻辑算法计算机动检测的可信度,利用目标的机动信息和模型的后验概率动态调整模型集。吕铁军等^[5]提出了一种基于角速度估计的自适应交互式多模型算法解决机动目标跟踪。马云红等^[6]提出了一种自适应转弯率目标跟踪算法,根据目标转弯半径和速度实时计算角速度,利用模型先验概率变化的斜率实时校正概率转移矩阵,减少了跟踪误差,提高了跟踪的鲁棒性。尽管这些IMM相关算法取得了较好的跟踪效果,但仍然存在一定的局限,表现在目标的运动模型集包含的模型数量总是有限的,而目标的运动的状态变化是连续的、无法穷尽的,有

限的模型集合难以覆盖目标所有的机动情况^[7],特别是当模型失配时就会导致跟踪精度降低而失去跟踪目标。另外,IMM算法是通过先前时刻的观测估计得到的模型,预测模型滞后于目标当前的实际运动状态,因此产生的由概率转移矩阵控制的运动模型切换,不能消除模型滞后带来的误差。传统方法往往是根据当前目标信息进行一步估计,难以从全局的角度挖掘目标的运动规律。神经网络因其强大的学习能力^[8-11]成为解决复杂模型学习的有效解决手段,用于不确定模型的预测和模型识别。然而,由于训练数据的科学性以及神经网络的网络结构和参数难以确定,对于目标机动轨迹的复杂特征仍然存在巨大挑战^[12]。

为此,本文提出基于目标轨迹数据驱动的深度学习神经网络学习方法,提高机动目标轨迹预测的准确性,从而实现对机动目标的精确跟踪。算法通过生成大量的在目标机动性能约束内的任意的机动方式的小的轨迹段,通过时间窗重叠的拼接,完成对任意的机动轨迹段随机组合,达到模拟任意机动轨迹的目的,经过神经网络的训练,可以快速匹配机动模型,并进行状态预测,实现机动目标快速跟踪。

收稿日期: 2023-09-21; 退修日期: 2024-01-19; 录用日期: 2024-02-29

基金项目: 航空科学基金(2020002005300)

引用格式: Ma Yunhong, Li Xin Xinyi, Wang Zelin, et al. Maneuvering target tracking based on data-driven [J]. Aeronautical Science & Technology, 2024, 35(04): 97-103. 马云红, 李欣怡, 王泽霖, 等. 基于数据驱动的机动目标跟踪[J]. 航空科学技术, 2024, 35(04): 97-103.

1 生成机动轨迹数据集

采用神经网络学习方法进行目标机动的模型预测,需要大量的训练数据。而飞行器的每一次实际飞行要耗费大量的人力物力,也难以完成所有的机动组合,因此难以获得充足的机动目标轨迹真实数据。本文通过选择不同的目标运动状态方程模拟目标的运动模型,生成机动目标轨迹数据,获取训练数据并构建充足的轨迹数据库。

1.1 目标运动状态空间模型

目标的运动状态空间表示为

$$\begin{cases} \mathbf{x}_k = \mathbf{F}_{k-1} \mathbf{x}_{k-1} + \omega_{k-1} \\ \mathbf{z}_k = \mathbf{H}_k \mathbf{x}_k + m_k \end{cases} \quad (1)$$

式中, $\mathbf{x}_k, \mathbf{y}_k$ 为目标 k 时刻的状态矢量; \mathbf{F} 为目标状态转移矩阵, 由目标运动模型确定; \mathbf{z}_k 为目标 k 时刻的量测矢量, \mathbf{H} 为量测矩阵; ω 为系统的过程噪声; m 为系统的测量噪声。量测矢量 $\mathbf{z}_k = [\theta_k, r_k]^T$ 中, θ_k 为目标方位角测量值, r_k 为目标距离的测量值。式(2)为目标在状态空间中的位置信息与观测空间中的雷达测量数据的关系, m_θ 和 m_r 分别是方位角和距离的量测噪声, x_k 和 y_k 分别是轨迹的平面坐标。

$$\begin{bmatrix} \theta_k \\ r_k \end{bmatrix} = \begin{bmatrix} \arctan \frac{x_k}{y_k} \\ \sqrt{x_k^2 + y_k^2} \end{bmatrix} + \begin{bmatrix} m_\theta \\ m_r \end{bmatrix} \quad (2)$$

1.2 机动轨迹生成器

由于不同的运动模型对应不同的状态转移矩阵, 给出了初始状态、系统噪声、量测噪声和状态转移矩阵, 可以根据式(1)生成任意的机动轨迹段。本文假设雷达为机场监控雷达, 其探测半径为 0~30km; 目标的速度不超过声速 (0~340m/s); 飞行器的转弯角速率在 -15~15(°)/s 之间, 转弯角速率定义为目标左转弯时为正, 目标右转弯时为负, 转弯率变化的最小分辨率为 0.1(°)/s。由此生成任意的目标机动轨迹, 将这些轨迹数据存储到数据库, 作为训练深度神经网络的数据集。

1.3 适用于神经网络训练的轨迹样例生成

为保证生成的轨迹数据便于进行深度神经网络训练, 本文选择固定长度的轨迹段作为训练样本集, 将轨迹段的长度 t_s 设置为 10s, 采样周期为 0.1s, 则一段轨迹中有 100 个采样点。轨迹段的初始位置所在的雷达探测范围内的某一个随机值, 如式(3)所示

$$\begin{cases} D_0 = f_r(0, 30000 - v_m \times t_s) \\ V_0 = f_r(0, v_m) \\ \theta_d = f_r(-180, 180) \\ \theta_v = f_r(-180, 180) \end{cases} \quad (3)$$

式中, $f_r()$ 表示在范围内取均匀分布随机数; v_m 为最大飞行速度, 设为 340m/s; D_0 为量测的随机初始距离; V_0 为随机初始速度; θ_d 为相对正北方向在 $[-180^\circ, 180^\circ]$ 范围内的均匀分布随机值, θ_v 为相对正北方向在 $[-180^\circ, 180^\circ]$ 范围内的均匀分布随机值。假设记初始点为 $\mathbf{x}_0 = [x_0, \dot{x}_0, y_0, \dot{y}_0]$, 则相应的轨迹段初始数据生成表达式为

$$\begin{cases} x_0 = D_0 \times \cos(\theta_d) \\ \dot{x}_0 = V_0 \times \cos(\theta_v) \\ y_0 = D_0 \times \sin(\theta_d) \\ \dot{y}_0 = V_0 \times \sin(\theta_v) \end{cases} \quad (4)$$

设系统噪声 $\omega_k = [\omega_d, \omega_v, \omega_d, \omega_v]^T$ 和测量噪声矢量 $\mathbf{m}_k = [m_r, m_\theta]^T$ 都服从正态分布, 即 $\omega_d \sim N(0, \sigma_d^2)$, $\omega_v \sim N(0, \sigma_v^2)$, $m_r \sim N(0, \sigma_r^2)$, $m_\theta \sim N(0, \sigma_\theta^2)$ 。噪声的标准差 σ_a 在 8~12m/s² 区间随机取值, 则 $\sigma_d = 0.5\sigma_a T^2$, $\sigma_v = \sigma_a T$ 。设雷达观测的距离噪声标准差为 $\sigma_r = 50\text{m}$, 方位角噪声为 $\sigma_\theta = 1^\circ$ 。

基于以上参数, 利用轨迹生成器生成用于深度神经网络训练的轨迹段数据和对应的雷达测量数据。轨迹生成器通过设定不同的转移矩阵, 包含多个运动模型, 为网络训练提供充足的含有目标机动信息和量测噪声特征的数据源。

2 基于数据驱动的深度神经网络训练

循环神经网络(RNN)能够记忆序列化的数据, 机动目标轨迹就是一系列的时序数据。因此选择基于RNN及其衍生的改进神经网络模型作为设计适用于机动目标轨迹识别的深度神经网络模型, 实现基于数据驱动的目标在线跟踪。Mike Schuster提出了一种双向RNN模型(Bi-RNN), 包含正向网络模型及反向网络模型, 采用前后向两个独立网络进行历史信息输入^[13], 用来自序列两端的信息来估计输出, 比单层RNN模型的训练效果更稳定。选用Bi-RNN神经网络进行轨迹模型的训练和学习。

与传统的基于模型的跟踪算法不同, 基于数据驱动的深度神经网络机动目标跟踪是基于经过离线训练的深度神经网络(DTN)来跟踪机动目标没有多模型跟踪算法中的机动检测和模型匹配过程, 避免了估计延迟。算法包括训练和在线跟踪阶段, 如图1所示。

目标跟踪算法主要有以下几个步骤: (1) 轨迹映射模块将轨迹数据库中的轨迹段的雷达测量数据处理为适合DTN学习的输入输出; (2) 在训练阶段, 以均方根误差作为损失函数训练学习轨迹段的运动模型; (3) 在跟踪阶段, 采

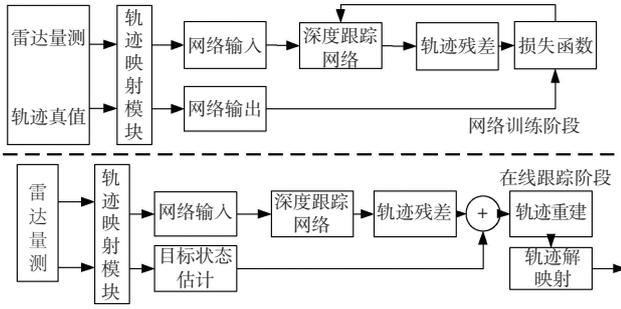


图1 基于深度神经网络的目标跟踪算法框架

Fig.1 A target tracking framework based on DTN

用相同步骤处理雷达实时测量数据,由训练后的DTN网络预测残差修正UKF的状态估计;(4)进行轨迹重建和解映射完成对目标机动轨迹的在线跟踪。

2.1 基于NACT-UKF的轨迹映射和解映射

轨迹映射模块基于已经建立的轨迹段数据库。由于雷达量测的目标距离的数值远远大于目标方位角的数值,采用原始数据时距离信息的数值量级远远大于方位角的信息数量级,而且不同轨迹段的数据变化范围大,也容易带来神经网络学习效果不佳。另外,网络输入层中单元的激活函数会落入零梯度区域(饱和区域),阻碍了该单元对损失函数的反向学习过程。为此,本文设计了一种基于自适应转弯率无迹卡尔曼滤波算法(NACT-UKF)的轨迹映射器,将轨迹的雷达量测数据转换为适合神经网络训练的输入数据,使神经网络快速收敛。

轨迹映射的步骤如下:(1)从轨迹数据库中取得一对轨迹段的雷达测量值;(2)通过NACT-UKF算法对雷达量测值进行一次滤波估计,NACT为转弯率自适应算法,UKF将雷达观测空间的输入数据转换到目标状态空间,得到目标状态空间的估计数据;(3)对轨迹段状态估计数据输入进行归一化,作为深度神经网络的输入;(4)轨迹段实际量测数据经过轨迹映射模块得到映射后的量测值;(5)基于轨迹映射数据,根据式(5)计算残差并作为神经网络的输出。

残差计算公式为

$$r_{1:k}^i = x_{1:k}^i - \hat{x}_{1:k}^i \quad (5)$$

式中, $r_{1:k}^i$ 为第*i*条轨迹的第1~*k*各个点的残差, $x_{1:k}^i$ 为各点的轨迹状态数据, $\hat{x}_{1:k}^i$ 为神经网络预测状态数据。

映射器的表达式为式(6),其中第*i*条轨迹的归一化参数为 (C_a^i, C_b^i, l, u) , u 和 l 是归一化的上下限,设置为1和-1。 C_a^i, C_b^i 为预测轨迹点中的最小值和最大值, $m_{1:k}^i$ 为映射以后的序列值。

$$[m_{1:k}^i, \text{Map}_i] = \text{map} \{ \hat{x}_{1:k}^i \}_l^u$$

$$\begin{cases} C_a^i = \min(\hat{x}_i, \hat{y}_i) \\ C_b^i = \max(\hat{x}_i, \hat{y}_i) \\ m_{1:k}^i = \frac{(u-l)(\hat{x}_{1:k}^i - C_a^i)}{C_b^i - C_a^i} \end{cases} \quad (6)$$

轨迹映射是为了便于神经网络的训练和计算,神经网络的输出需要经过解映射才能还原为轨迹数据。解映射将映射计算轨迹还原为状态轨迹。解映射如式(7)所示

$$\hat{x}_{1:k}^i = \frac{(C_b^i - C_a^i)m_{1:k}^i}{u-l} - C_a^i \quad (7)$$

2.2 神经网络训练

本文采用多层双向循环门控网络BiGRU和一层全连接的输出层构成深度训练神经网络DTN。采用DTN进行训练,训练的输入为序列信息 $m_{1:k}^i$,输出为对目标状态残差的估计 $r_{1:k}^i$ 。

经过充分训练的DTN,可以对轨迹残差 $r_{1:k}^i$ 进行回归预测,并修正滤波估计值 \tilde{r}_k ,具体过程为:从轨迹数据库中随机按照批次抽取轨迹段的量测对,对其进行NACT-UKF滤波和轨迹映射,获得DTN的输入输出对。DTN的损失函数为轨迹残差的均方根误差,如式(8)所示

$$\text{loss} = \sqrt{\sum_{k=1}^N (\tilde{r}_k - r_k)^2} \quad (8)$$

在误差反向传播的过程中使用mini-batch梯度下降法令loss最小, k 表示轨迹段上的量测点数。每个batch大小设为50。网络训练阶段的流程如图2所示。

3 基于数据驱动的机动目标跟踪算法

3.1 在线跟踪

利用训练好的DTN神经网络模型进行在线跟踪目标。由于DTN的输入是序列化的轨迹段,因此利用滑动窗口对映射后的长轨迹进行分割,滑动窗口大小和轨迹段训练样本的长度一致,为10s。将分割好的轨迹段送入DTN,预测轨迹残差 $r_{1:k}^i$,通过式(9)修正UKF估计值,提高预测精度。

$$\tilde{m}_{1:k}^i = \tilde{r}_{1:k}^i + m_{1:k}^i \quad (9)$$

3.2 轨迹重构

基于深度神经网络的目标轨迹预测,将目标的轨迹信息裁剪成适当长度的片段,用作深度训练网络的输入,获得最小预测轨迹残差,用残差修正估计。为了获得完整轨迹的状态估计,需要对神经网络的修正结果进行轨迹重构。

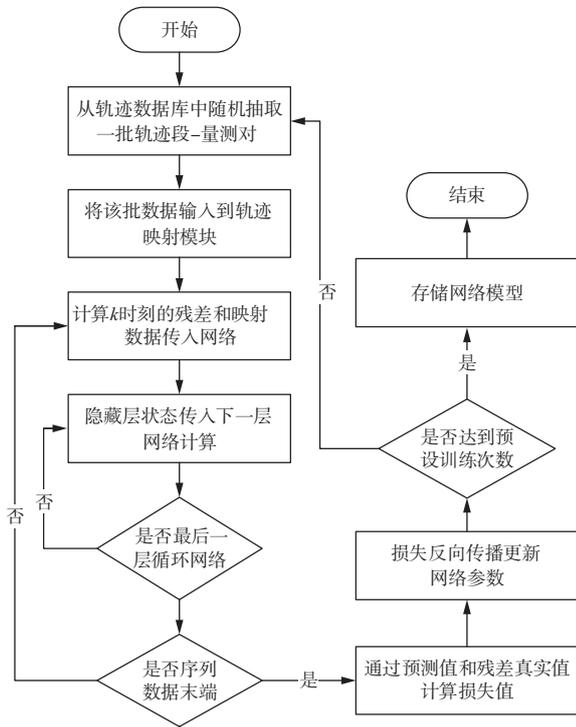


图2 DTN训练流程

Fig.2 Training process of DTN

轨迹重构时,首先确定相邻轨迹片段的重叠长度,保证轨迹片段重组的稳定性。设神经网络输出的轨迹片段 $\tilde{m}_{1:s}$,即轨迹片段长度为 s ,假设与下一段轨迹重叠长度为 d ,则下一轨迹段为 $\tilde{m}_{s-d+1:2s-d}$ 。对前后两个片段的重叠区域做算术平均,如式(10)所示,其中 $i \in [1, s]$,重复此过程即可完成整段轨迹的重建

$$\tilde{m}_{s-d+i}^r = 0.5(\tilde{m}_{s-d+i} + \tilde{m}_{s-d+i}^{\text{next}}) \quad (10)$$

在轨迹数据库中用于训练网络的轨迹片段为10s,即深度神经网络的分段输出为10s。为了保证跟踪效果,将重叠片段设置为9s,假设测试算法的轨迹为100s,则在线跟踪过程如图3所示。在整个跟踪过程中,通过滑动窗口依次获得10s的输入数据,送入DTN网络中进行修正,将修正后的轨迹进行重构,最后通过式(7)进行解映射得到跟踪结果。图3给出了流程示意图。

4 基于数据驱动的目标跟踪仿真

4.1 DTN网络参数

构建10万条轨迹数据用于网络训练。将轨迹数据分为两部分,即数据的85%作为训练数据用于训练网络,其余15%作为测试数据用于测试神经网络估计性能,训练回合为20000次。分别选择GRU网络层数为1~5,以网络节

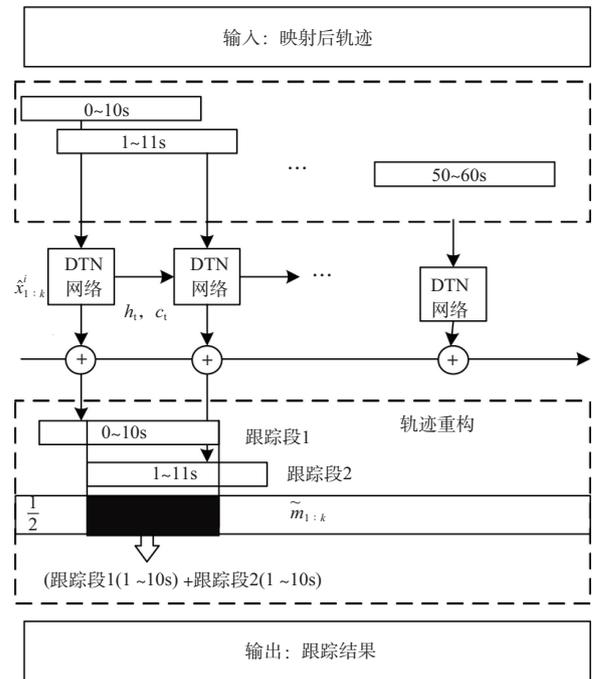


图3 在线跟踪示意图

Fig.3 Online tracking diagram

点数为32、64、128、256进行试验,通过试验确定合适的网络层数和网络节点数。试验结果得出,DTN结构为三层,网络节点数为128时,输出的跟踪误差最小,选用BiGRU和一层全连接的输出层构成,其中输出层的网络节点数为4,BiGRU的网络节点数为128,并采用阶梯递减学习速率(StepLR)作为学习率调整策略,初始学习率为 10^{-2} ,更新步长为100,更新学习率的乘法因子为0.65。

4.2 跟踪弱机动目标的仿真实验

4.2.1 弱机动目标跟踪

本组仿真用于验证算法在跟踪弱机动目标场景下的跟踪性能。测试轨迹为3条,其参数见表1。目标初始状态为 $[x, y, \dot{x}, \dot{y}]$,分别为二维平面的位置和速度信息。T1、T2、T3分别表示三个不同的轨迹段数据,表示三个不同的弱机动目标10s内的轨迹信息。T1目标匀速运动,T2进行左转弯运动,T3目标进行右转弯运动。采用了不同跟踪算法,得到跟踪误差,见表1。图4为匀速直线运动的跟踪轨迹,图5为左转弯跟踪轨迹,图6为右转弯跟踪轨迹。仿真结果可以看出DTN算法在跟踪匀速直线、左转弯和右转弯的目标时的跟踪误差都明显小于EKF算法,略小于UKF算法。但是DTN的跟踪轨迹相较于UKF算法更平滑,也更接近目标的运动轨迹。

表1 特定运动目标轨迹跟踪

Table 1 Trajectory of the special motion model

| 轨迹 | T1 CV | T2 左转 7.45(°)/s | T3 右转 4.5(°)/s |
|----------|--|--|---|
| 起始状态 | [6km, 3km, 20m/s ² , 20m/s ²] | [15km, -3km, -45m/s ² , 175m/s ²] | [0.8km, 2.4km, -70m/s ² , 50m/s ²] |
| EKF 误差/m | 19.87 | 38.32 | 22.63 |
| UKF 误差/m | 18.34 | 26.57 | 19.19 |
| DTN 误差/m | 13.21 | 20.16 | 16.05 |

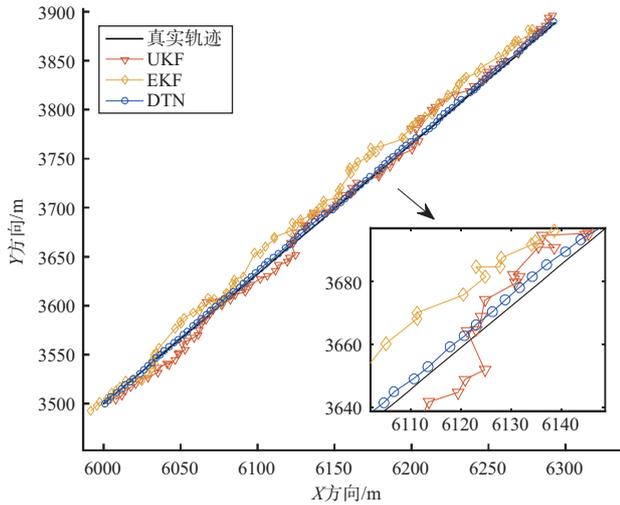


图4 轨迹T1跟踪

Fig.4 Trajectory tracking of T1

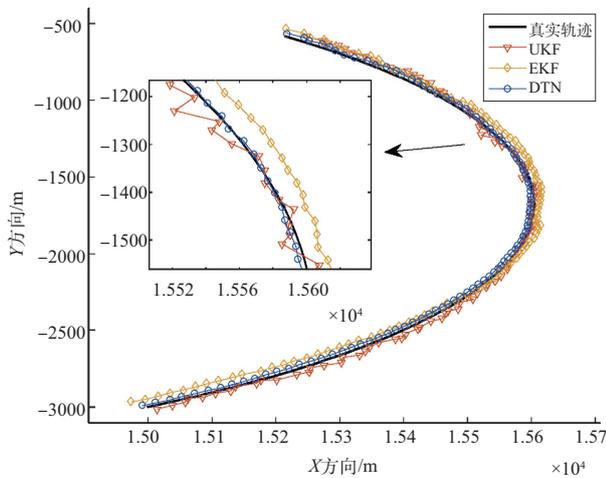


图5 轨迹T2的跟踪

Fig.5 Trajectory tracking of T2

4.2.2 跟踪强机动目标的仿真验证

目标进行强机动时无法获知目标正在进行哪种运动模型的运动以及何时会发生运动模型切换,采用DTN可以规避这种不足。将DTN算法与文献[6]提出的自适应转弯率的IMM算法(NACT-IMM)进行比较,针对三组轨迹算例进

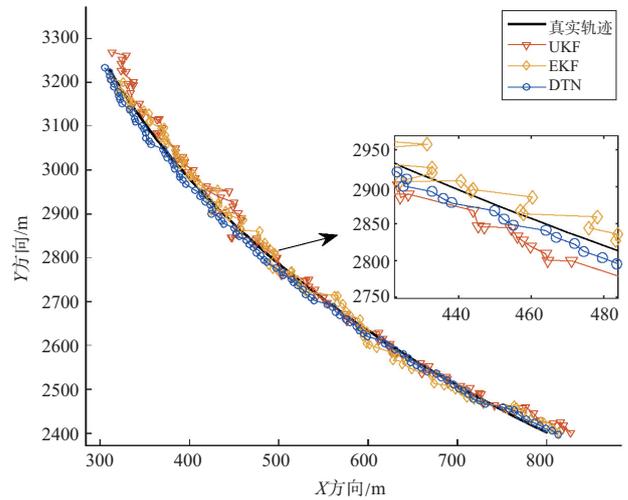


图6 轨迹T3跟踪误差

Fig.6 Trajectory tracking error of T3

行了1000次的蒙特卡罗试验。分别选择最大机动的位置进行比较。最大机动位置的误差数据见表2,轨迹T4的结果跟踪效果如图7所示,轨迹T5的仿真结果如图8所示,轨迹T6的仿真结果如图9所示。从仿真结果可以看出,采用基于数据驱动的DTN算法跟踪误差更小。而且DTN的仿真计算时间为24.8ms,显著小于NACT-IMM的时间为74.7ms。

表2 跟踪强机动目标T4结果比较

Table 2 Tracking the strong maneuvering target

| 轨迹 | 最大机动位置的跟踪误差/m | |
|----|---------------|-------|
| | NACT-IMM | DTN |
| T4 | 56.76 | 30.58 |
| T5 | 48.87 | 32.54 |
| T6 | 75.34 | 35.78 |

5 结束语

本文提出了一种基于数据驱动的机动目标跟踪算法。算法主要通过轨迹生成器生成大量可能的目标机动运动的轨迹数据,再基于生成的目标轨迹数据进行神经网络学习训练,得到可以进行轨迹预测的神经网络。实际轨迹数据输入神经网络,神经网络给出轨迹模型预测残差并进行修正,实现在线机动目标位置的预测,完成目标跟踪。由于数据驱动来自大量的轨迹生成,大量的轨迹数据可以充分包含目标的机动运动模型,从而快速实现目标轨迹预测。本文进行了基于数据驱动的神经网络的目标跟踪算法和传统目标跟踪算法的仿真比较,仿真结果显示,基于数据驱动

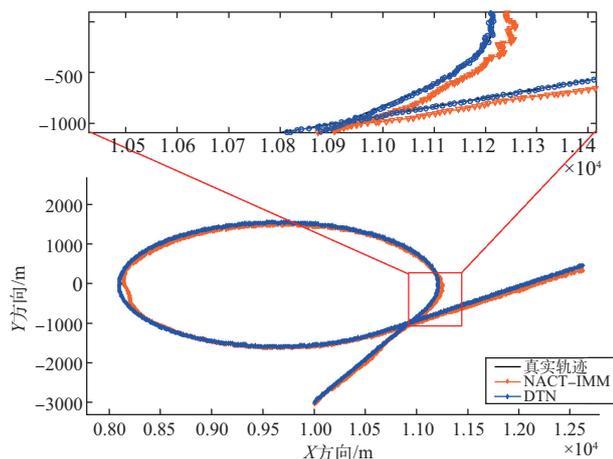


图7 强机动轨迹T4跟踪

Fig.7 Trajectory tracking of strong maneuvering target T4

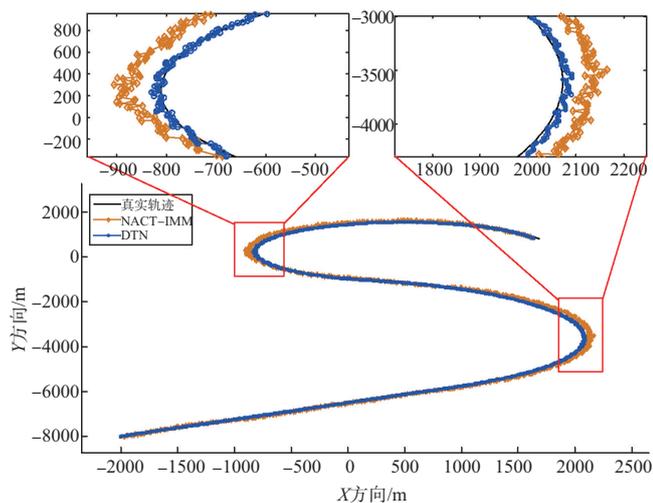


图8 强机动轨迹T5跟踪

Fig.8 Trajectory tracking of strong maneuvering target T5

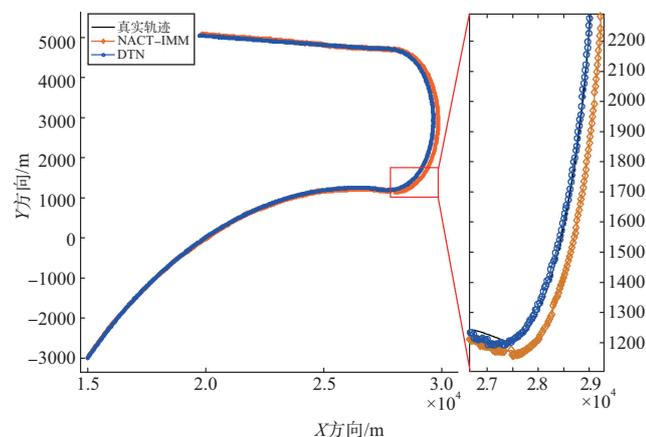


图9 强机动轨迹T6跟踪

Fig.9 Trajectory tracking of strong maneuvering target T6

的神经网络目标跟踪效果优于传统的目标跟踪算法,有效地规避了传统模型预测的时延问题。本文采用的深度学习神经网络进行目标轨迹跟踪,进行了轨迹段的重构,重构的重叠段对跟踪精度的影响可以进一步深入研究。 **AST**

参考文献

- [1] Bar-Shalom Y, Chang K C. Tracking a Maneuvering Target Using Input Estimation Versus the Interacting Multiple Model Algorithm[J]. IEEE Transactions on Aerospace & Electronic Systems, 1989, 25(2):296-300.
- [2] 尹聚祺,杨震,罗亚中,等. 空间机动目标跟踪的改进自适应IMM算法[J]. 系统工程与电子技术, 2021, 43(12):3658-3666. Yin Juqi, Yang Zhen, Luo Yazhong, et al. Improved adaptive IMM algorithm for space maneuvering target tracking, [J]. Systems Engineering and Electronics, 2021,43(12): 3658-3666. (in Chinese)
- [3] 赵楚楚,王子微,丁冠华,等. 基于模糊逻辑的改进自适应IMM跟踪算法[J]. 信号处理, 2021, 37(5):724-734. Zhao Chuchu, Wang Ziwei, Ding Guanhua, et al. Fuzzy-logic adaptive IMM algorithm for target tracking[J]. Journal of Signal Processing, 2021,37(5):724-734. (in Chinese)
- [4] 邵堃,雷迎科. 基于模糊逻辑和机动检测的AGIMM跟踪算法[J]. 空军工程大学学报(自然科学版),2020,21(4):80-87. Shao Kun, Lei Yingke. AGIMM tracking algorithm based on fuzzy logic and maneuvering detection[J]. Journal of Air Force Engineering University (Nature Science Edition), 2020,21(4): 80-87. (in Chinese)
- [5] 吕铁军,蒋宏,丁全心,等. 基于角速度估计自适应的IMM目标跟踪算法[J]. 航空科学技术, 2012(1):74-77. Lyu Tiejun, Jiang Hong, Ding Quanxin, et al. Turn rate-based adaptive interactive multiple-model target tracking[J]. Aeronautical Science & Technology, 2012(1):74-77. (in Chinese)
- [6] Ma Yunhong, Wang Zelin, Zhang Yimin, et al. Maneuvering target tracking based on adaptive turning rate interactive multiple model[C]. 2022 IEEE 17th International Conference on Control & Automation (ICCA),2022.
- [7] 彭章友,陈琳妍. 基于BPNN的自适应机动目标跟踪[J]. 电子测量技术,2019,42(15):29-34. Peng Zhangyou, Chen Linyan. Adaptive maneuvering target tracking based on Back propagation neural network[J].

- Electronic Measurement Technology, 2019, 42(15): 29-34. (in Chinese)
- [8] Liu Jingxia, Wang Zulin, Xu Mai. Deep MTT: A deep learning maneuvering target-tracking algorithm based on bidirectional LSTM network [J]. Information Fusion, 2020, 53:289-304.
- [9] 洪培钦, 罗灵鲲, 刘冰, 等. 引入轻量注意力的孪生神经网络目标跟踪算法[J]. 计算机工程与应用, 2022, 58(12):112-121.
- Hong Peiqin, Luo Lingkun, Liu Bing, et al. Siamese neural network target tracking algorithm with lightweight attention[J]. Computer Engineering and Applications, 2022, 58(12):112-121. (in Chinese)
- [10] 宋婷, 贺丰收, 程宇峰. 深度学习技术在雷达目标检测中的研究进展[J]. 航空科学技术, 2020, 31(12):12-20.
- Song Ting, He Fengshou, Cheng Yufeng. Research progress of deep learning technology in radar target detection[J]. Aeronautical Science & Technology, 2020, 31(12):12-20. (in Chinese)
- [11] 武天才, 王宏伦, 刘一恒, 等. 基于深度学习的飞行器故障情况下可配平能力快速预示方法[J]. 航空科学技术, 2023, 34(2): 72-77.
- Wu Tiancai, Wang Honglun, Liu Yiheng, et al. Fast prediction method of aircraft trim capability under actuator faults based on deep learning [J]. Aeronautical Science & Technology, 2023, 34(2):72-77. (in Chinese)
- [12] 徐西蒙, 杨任农, 于洋, 等. 基于运动分解和H-SVM的空战目标机动识别[J]. 控制与决策, 2020, 35(5): 1265-1272.
- Xu Ximeng, Yang Rennong, Yu Yang, et al. Target maneuvering recognition in air combat based on motion decomposition and H-SVM[J]. Control and Decision, 2020, 35(5): 1265-1272. (in Chinese)
- [13] Schuster M, Paliwal K K. Bidirectional recurrent neural networks[J]. IEEE Transactions on Signal Processing, 1997, 45 (11):2673-2681.

Maneuvering Target Tracking Based on Data-driven

Ma Yunhong¹, Li Xinyi¹, Wang Zelin¹, Cao Tianhang¹, Wang Yongkun²

1. Northwestern Polytechnical University, Xi'an 710072, China

2. AVIC Leihua Electronic Technology Research Institute, Wuxi 214063, China

Abstract: Target tracking is the key to accurate target strike, especially for maneuvering targets, which can improve the estimation accuracy of target state and achieve precise target strike tasks. This paper proposes a data-driven maneuvering target tracking algorithm based on neural network theory for the tracking problem of maneuvering targets. By generating a large amount of flight data with different maneuvering modes, a data sample library for target maneuvering is established. A deep neural network based on bidirectional input is used to train a large amount of different data, generate models of maneuvering trajectories, and match trajectory sequence data with different maneuvering models to achieve trajectory prediction for any maneuvering target, thereby achieving tracking of maneuvering targets and effectively improving the tracking accuracy of maneuvering targets. The simulation results validate the effectiveness of data-driven target tracking algorithms, provides new ideas and methods for predicting maneuvering target trajectories, and improves the timeliness and accuracy of trajectory prediction.

Key Words: neural networks; data-driven; maneuvering target; target tracking; trajectory prediction

Received: 2023-09-21; Revised: 2024-01-19; Accepted: 2024-02-29

Foundation item: Aeronautical Science Foundation of China(2020002005300)