

基于双支协同滤波网络的目标跟踪方法

张文安^{1,2} 乔小龙^{1,2} 林安迪^{1,2} 杨旭升^{1,2}

摘要 针对时序-状态相关性提取不足引起的目标跟踪性能下降问题, 提出一种基于双支协同滤波网络 (DBCF-Net) 的目标跟踪方法. 首先, 为实现运动模型和过程噪声参数的动态调整, 分别设计非马尔科夫信息网络和状态相关信息网络, 以学习运动目标状态演化过程中的时序依赖性及其状态变量间的局部相关性; 其次, 设计一种基于最大均值差异的网络权重协同更新机制, 通过差异化分支网络输出特征来增强分支网络间的学习互补性, 从而提升 DBCF-Net 对未知运动模式的适应能力; 进而, 融合贝叶斯滤波与神经网络的优势, 将无偏量测转换引入 DBCF-Net, 以增强目标跟踪的鲁棒性; 最后, 通过目标跟踪实验验证了 DBCF-Net 的有效性.

关键词 状态估计; 卡尔曼滤波; 目标跟踪; 滤波网络

引用格式 张文安, 乔小龙, 林安迪, 杨旭升. 基于双支协同滤波网络的目标跟踪方法. 自动化学报, 2026, 52(4): 738-748

DOI 10.16383/j.aas.c250590 **CSTR** 32138.14.j.aas.c250590

A Target Tracking Method Based on Dual-Branch Collaborative Filtering Network

ZHANG Wen-An^{1,2} QIAO Xiao-Long^{1,2} LIN An-Di^{1,2} YANG Xu-Sheng^{1,2}

Abstract To address the performance degradation in target tracking caused by insufficient extraction of temporal-state correlations, a dual-branch collaborative filtering network (DBCF-Net) based target tracking method is proposed. First, to achieve dynamic adjustment of motion model and process noise parameters, a non-Markov information network and a state-related information network are designed separately to learn the temporal dependencies in the motion target state evolution process and the local correlations among state variables. Second, a network weight collaborative update mechanism based on maximum mean discrepancy is designed to enhance learning complementarity between the branch networks by differentiating their output features, thereby improving the adaptability of DBCF-Net to unknown motion patterns. Furthermore, leveraging the strengths of Bayesian filtering and neural networks, unbiased measurement transformation is introduced into DBCF-Net to enhance the robustness of target tracking. Finally, target tracking experiments validate the effectiveness of DBCF-Net.

Keywords state estimation; Kalman filter; target tracking; filtering network

Citation Zhang Wen-An, Qiao Xiao-Long, Lin An-Di, Yang Xu-Sheng. A target tracking method based on dual-branch collaborative filtering network. *Acta Automatica Sinica*, 2026, 52(4): 738-748

目标跟踪在民用和军事领域均发挥着重要作用. 过去几十年间, 扩展卡尔曼滤波 (extend Kalman filter, EKF)^[1] 和无迹卡尔曼滤波 (unscented Kalman filter, UKF)^[2] 等方法广泛应用于雷达跟踪、飞行目标监测和导航等任务^[3-7]. 这类方法通常需要

预定义运动模型, 因而其跟踪性能依赖于预定义模型的准确性. 然而, 目标运动通常具有时变性和随机性, 使其难以通过单一或固定模型描述.

针对单一模型目标跟踪的不足, Magill^[8] 提出多模型跟踪方法 (multiple model, MM), 通过融合多个模型的输出来适应目标运动的随机性. Blom 等^[9] 在 MM 框架下引入模型间交互机制, 提出交互式多模型 (interacting multiple model, IMM) 方法, 该方法利用历史观测数据自适应地调整模型权重, 以提升目标跟踪性能. 针对目标跟踪中的某些特定场景, 文献 [10-13] 提出多种改进的 IMM 算法. 由于现实中难以获取足够的信息预定义模型集, 当目标运动超出模型集适用范围, 其跟踪性能将显著下降. 尤其是, 这类方法通常基于一阶马尔科夫假设, 忽略了状态间的时序依赖性, 这将进一步限制其目

收稿日期 2025-10-31 录用日期 2025-12-31

Manuscript received October 31, 2025; accepted December 31, 2025

国家自然科学基金 (U25A20456, 62473335, W2421117), 杭州市科技发展计划项目 (2022AIZD0080) 资助

Supported by National Natural Science Foundation of China (U25A20456, 62473335, W2421117) and Hangzhou Science and Technology Development Plan Project (2022AIZD0080)

本文责任编辑 孟凡利

Recommended by Associate Editor MENG Fan-Li

1. 浙江工业大学信息工程学院 杭州 310023 2. 浙江省复杂系统智能感知与控制重点实验室 杭州 310023

1. College of Information Engineering, Zhejiang University of Technology, Hangzhou 310023 2. Zhejiang Key Laboratory of Intelligent Perception and Control for Complex Systems, Hangzhou 310023

标跟踪的性能. 近年来, 神经网络凭借强大特征提取和模式识别能力广泛应用于目标跟踪领域. 例如, Liu 等^[14]提出一种基于 Bi-LSTM 的 DeepMTT 网络模型, 以学习运动轨迹中的时序特征. Yang 等^[15]在 DeepMTT 的基础上引入注意力机制以提取序列之间的相关性, 改进 DeepMTT 模型. Zhai 等^[16]将 XGBoost 用于构建跟踪模型, 通过学习观测数据与真实状态间的映射关系以及利用滑动窗口动态更新数据, 以实现自适应目标跟踪. 然而, 此类方法倾向于信任可用的标注数据, 缺乏先验信息的约束, 因而导致其跟踪性能受限, 同时缺乏模型可解释性. 为此, 融合神经网络和贝叶斯滤波的方法^[17-23]成为解决这一问题的的重要途径. Chen 等^[18]提出融合神经网络与状态空间模型的框架, 从特征空间中学习状态转移函数, 并结合贝叶斯滤波以实现运动估计和预测任务. Revach 等^[20]提出一种滤波网络架构 KalmanNet, 利用神经网络来学习卡尔曼增益. 在此基础上, Choi 等^[21]提出 Split-KalmanNet, 通过两个分支网络来并行学习状态估计和新息的协方差以减小模型失配而产生的误差. Escoriza 等^[22]将 KalmanNet 应用于竞速赛车的姿态估计中, 取得较好的效果. 然而, 上述方法对目标运动的随机性及目标状态变量间的局部相关性考虑不足, 这将限制其在目标跟踪中的应用.

为此, 本文提出一种基于双支协同滤波网络 (dual-branch collaborative filtering network, DB-CF-Net) 的目标跟踪方法, 融合贝叶斯滤波与神经网络的优势以增强目标跟踪的鲁棒性. 本文主要贡献在于: 1) 设计双支协同网络来学习目标状态的时序依赖性及状态变量间的局部相关性, 以实现运动模型和过程噪声参数的动态调整; 2) 设计基于最大均值差异 (maximum mean discrepancy, MMD) 的网络权重协同更新机制, 使得分支网络间具有学习互补性, 增强未知运动模式的适应能力.

1 问题描述

考虑非马尔科夫性系统模型

$$\mathbf{x}_k = f_g(\mathbf{x}_{k-1}, \mathbf{x}_{k-2}, \dots) + \mathbf{w}_k \quad (1)$$

其中, $f_g(\cdot)$ 为状态转移函数, 其描述运动目标历史状态与当前状态的依赖关系; \mathbf{x}_k 为状态向量; \mathbf{w}_k 为过程噪声, 服从零均值、协方差为 Q_k 的高斯分布. 其观测模型为

$$\mathbf{z}_k = h(\mathbf{x}_k) + \mathbf{u}_k \quad (2)$$

其中, $h(\cdot)$ 为非线性观测函数, 即

$$h(\mathbf{x}_k) = \begin{bmatrix} \sqrt{p_{x,k}^2 + p_{y,k}^2} \\ \arctan\left(\frac{p_{y,k}}{p_{x,k}}\right) \end{bmatrix} \quad (3)$$

$\mathbf{z}_k = [r_k, m, \beta_k, m]^T$ 为观测向量, 包含径向距离和方位角; \mathbf{u}_k 为观测噪声, 服从零均值、协方差为 R_k 的高斯分布, 且与过程噪声 \mathbf{w}_k 不相关; $p_{x,k}$ 和 $p_{y,k}$ 为运动目标的位置信息.

本文将从以下两方面对机动目标运动进行分析: 1) 从历史状态中分析运动目标状态间的时序相关性. 如图 1(a) 所示, 构建 S 形转弯运动模型往往需要多个历史状态, 这体现出状态演变的时序相关性. 2) 根据历史状态分析目标运动模式的局部不变性. 如图 1(b) 所示, 在不同的运动模式区域内, 状态变量之间呈现各异的局部相关性, 且往往由当前主导的运动模式所确定, 这反映出状态变量间的局部相关性. 目标运动过程可由如下微分方程描述:

$$\dot{\mathbf{x}}_k = f'_g(\mathbf{x}_k, \mathbf{x}_{k-1}, \mathbf{x}_{k-2}, \dots) + \mathbf{w}_k \quad (4)$$

式 (4) 中, $f'_g(\cdot)$ 通常难以获取且随着状态演化而变化. 为此, 构建一个嵌套函数以描述其非马尔科夫性, 即

$$f'_g = f_r(\underbrace{g_m^\Delta(\mathbf{x}_k, \mathbf{x}_{k-1}, \mathbf{x}_{k-2}, \dots)}_{g_m}, \underbrace{g_s^\Delta(\mathbf{x}_k, \mathbf{x}_{k-1}, \mathbf{x}_{k-2}, \dots)}_{g_s}) \quad (5)$$

式 (5) 中, g_m^Δ 和 g_s^Δ 模块用于提取并封装历史状态对当前状态的影响, 分别表示为 g_m 和 g_s , 该影响表现为两方面: 1) 历史状态的时序依赖关系对当前状态的影响; 2) 状态内部多个变量间的局部相关性.

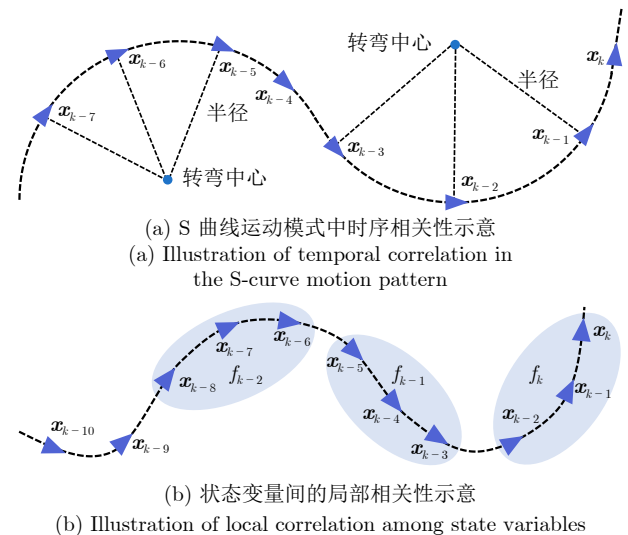


图 1 目标运动的时序相关性和局部相关性
Fig. 1 Temporal correlation and local correlation of target motion

性对当前状态的影响。\$g_m\$ 和 \$g_s\$ 通常为难以显式构建物理意义的潜在变量。\$f_r\$ 为模型学习函数。基于此，\$f'_g\$ 可由 \$g_m\$ 和 \$g_s\$ 决定，\$f'_g\$ 可视为一个以 \$g_m\$ 和 \$g_s\$ 为潜在参数的函数。式 (4) 可重新描述为

$$\dot{\mathbf{x}}_k = f_{[g_m, g_s]}(\mathbf{x}_k) + \mathbf{w}_k \quad (6)$$

对式 (6) 离散化，可得：

$$\mathbf{x}_k = \mathbf{x}_{k-1} + \Delta t f_{[g_m, g_s]}(\mathbf{x}_{k-1}) + \mathbf{w}_k \quad (7)$$

式 (7) 中，\$\Delta t\$ 为采样周期，\$f_{[g_m, g_s]}\$ 可表示为类线性结构^[18]，即

$$f_{[g_m, g_s]}(\mathbf{x}_{k-1}) = F_{[g_m, g_s]} \mathbf{x}_{k-1} \quad (8)$$

其中，\$F_{[g_m, g_s]}\$ 为 \$f_{[g_m, g_s]}\$ 的类线性结构形式。假设式 (6) 包含采样周期 \$\Delta t\$，则描述目标运动的系统模型可写为

$$\mathbf{x}_k = (\mathbf{I} + F_{[g_m, g_s]}) \mathbf{x}_{k-1} + \mathbf{w}_k \quad (9)$$

其中，\$\mathbf{I}\$ 为单位矩阵。由于非线性滤波方法往往不可避免地引入线性化近似误差，本文利用无偏量测转换方法将观测数据从观测空间转换至状态空间。由此，一方面有助于网络从转换后的数据中有效学习目标的运动特性；另一方面也可避免非线性滤波引入线性化误差。该观测数据无偏量测转换过程可表示为

$$\begin{cases} p_{x,k,m}^{\text{ucm}} = r_{k,m} \cdot \cos(\beta_{k,m}) \cdot e^{\frac{\sigma_\beta^2}{2}} \\ p_{y,k,m}^{\text{ucm}} = r_{k,m} \cdot \sin(\beta_{k,m}) \cdot e^{\frac{\sigma_\beta^2}{2}} \end{cases} \quad (10)$$

其中，\$\sigma_\beta\$ 为方位角噪声的标准差；\$e^{\frac{\sigma_\beta^2}{2}}\$ 为无偏量测转换中对直接量测转换的补偿项，以保证其与真实状态间的无偏性。

经转换之后的观测向量为

$$\hat{\mathbf{z}}_k = [p_{x,k,m}^{\text{ucm}}, p_{y,k,m}^{\text{ucm}}]^T \quad (11)$$

2 双支协同滤波网络

本文提出的双支协同滤波网络 (DBCF-Net) 如图 2 所示。首先，通过双支协同网络学习运动目标状态演化过程中的时序依赖性及状态中多变量间的局部相关性，进而构建运动目标的状态转移模型及其过程噪声统计特性；其次，建立了基于最大均值差异的网络权重更新机制，通过扩大最大均值差异度量，使得双分支网络具有学习互补性；最后，结合贝叶斯滤波，引入无偏量测转换，以避免非线性滤波过程中引入线性化误差。

2.1 数据预处理

为增强对目标运动的建模能力，本文构建了用于描述目标运动的输入序列。在无偏量测转换的基础上，采用一阶差分来近似计算运动目标的速度，作为位置信息的补充：

$$\begin{cases} v_{x,k} = \frac{x_{k,m}^{\text{ucm}} - x_{k-1,m}^{\text{ucm}}}{\Delta t} \\ v_{y,k} = \frac{y_{k,m}^{\text{ucm}} - y_{k-1,m}^{\text{ucm}}}{\Delta t} \end{cases} \quad (12)$$

由此可得包含位置和速度的轨迹序列 \$\tilde{\mathbf{x}}_{k:1} = [\tilde{\mathbf{x}}_k, \tilde{\mathbf{x}}_{k-1}, \tilde{\mathbf{x}}_{k-2}, \dots]\$，\$\tilde{\mathbf{x}}_k = [x_{k,m}^{\text{ucm}}, y_{k,m}^{\text{ucm}}, v_{x,k}, v_{y,k}]\$。由于序列 \$\tilde{\mathbf{x}}_{k:1}\$ 中位置和速度的数值尺度差异较大，尺度较小的速度信息会被尺度较大的位置信息所淹没，而且激活函数在输入数据过大时可能会进入饱和区。为了避免这种现象，使用实例归一化 (instance normalization, IN) 对序列 \$\tilde{\mathbf{x}}_{k:1}\$ 进行处理，即

$$\tilde{\mathbf{x}}_{k:1}^{\text{IN}} = \left[\frac{\tilde{\mathbf{x}}_k - \boldsymbol{\mu}}{\boldsymbol{\sigma}}, \frac{\tilde{\mathbf{x}}_{k-1} - \boldsymbol{\mu}}{\boldsymbol{\sigma}}, \frac{\tilde{\mathbf{x}}_{k-2} - \boldsymbol{\mu}}{\boldsymbol{\sigma}}, \dots \right] = \left[\tilde{\mathbf{x}}_k^{\text{IN}}, \tilde{\mathbf{x}}_{k-1}^{\text{IN}}, \tilde{\mathbf{x}}_{k-2}^{\text{IN}}, \dots \right] \quad (13)$$

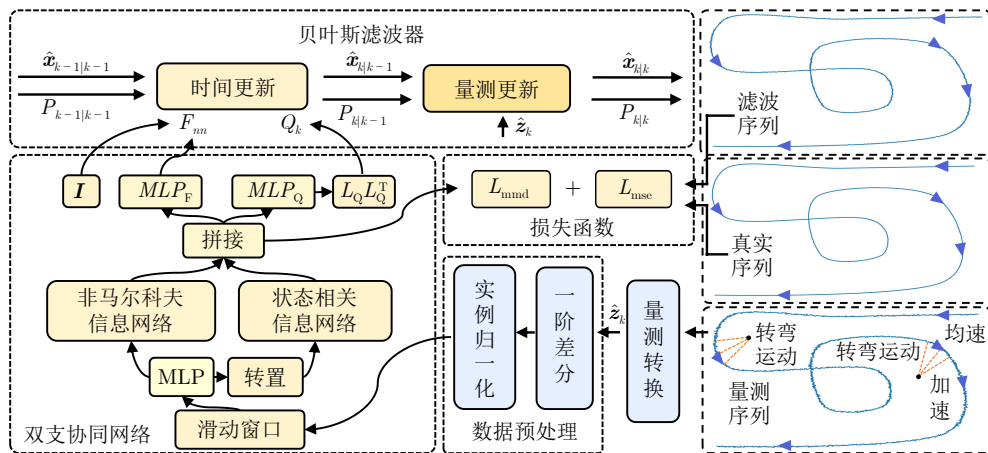


图 2 双支协同滤波网络框图

Fig. 2 Dual-branch collaborative network block diagram

式(13)中, $\boldsymbol{\mu} = [\mu_x, \mu_y, \mu_{vx}, \mu_{vy}]^T$, $\boldsymbol{\sigma} = [\sigma_x, \sigma_y, \sigma_{vx}, \sigma_{vy}]^T$, μ_* 和 σ_* 为序列 $\tilde{\boldsymbol{x}}_{k:1}$ 对应分量的均值和标准差.

2.2 双支协同网络

如图3所示, 双支协同网络包含非马尔科夫信息网络和状态相关信息网络, 分别从时间维度和空间维度对输入序列进行编码. 非马尔科夫信息网络将学习状态间的时序相关性特征. 类似地, 状态相关信息网络将学习状态变量局部相关性特征. 由于序列 $\tilde{\boldsymbol{x}}_{k:1}^{\text{IN}}$ 的长度随时间而增加, 直接处理变长序列往往会带来计算及建模的困难, 因此引入固定窗口长度 D 的滑动窗口 W_k :

$$W_k = \{\tilde{\boldsymbol{x}}_k^{\text{IN}}, \tilde{\boldsymbol{x}}_{k-1}^{\text{IN}}, \dots, \tilde{\boldsymbol{x}}_{k-D+1}^{\text{IN}}\} \quad (14)$$

通过一个多层感知机将 W_k 投影到 C 维的特征空间中, 以提取 $\tilde{\boldsymbol{x}}_{k:1}^{\text{IN}}$ 的浅层特征, 即

$$W_c = \text{MLP}(W_k) \quad (15)$$

其中, $W_c \in \mathbf{R}^{D \times C}$ 为非马尔科夫信息分网络的输入. 由于 W_c 的高维度状态是时间独立的, 其缺乏状态演化过程所需的时间依赖性. 同时为克服循环神经网络 (recurrent neural network, RNN) 等传统序列方法偏向关注相邻状态间的信息传递这一局限性, 在使用三层门控循环单元 (gated recurrent unit, GRU) 对序列进行隐藏状态的提取之后, 再使用两层卷积神经网络 (convolutional neural network, CNN) 提取特征图中时间维度特征. 与常规 CNN 不同的是, 本文采用宽度大于高度的非对称卷积核^[24]来扩展感受视野, 从而加强该分支网络在时间维度上的特征提取能力, 其输出特征可表示为

$$g_m = \text{CNN}(\text{GRU}(W_c)) \quad (16)$$

状态相关信息网络对输入序列进行特征提取与

非马尔科夫信息网络类似, 但两者输入有所不同. 将输入序列 W_c 转置可得: $W_c^T \in \mathbf{R}^{C \times D}$, W_c^T 表示同一个状态分量在不同时间的局部演化特征, 但其缺乏对目标运动状态演化中多变量间的局部相关性. 为捕捉这些特征, 将输入序列通过三层 GRU 对序列进行隐藏状态提取后, 使用两层卷积神经网络提取状态多变量间的局部相关性特征:

$$g_s = \text{CNN}(\text{GRU}(W_c^T)) \quad (17)$$

为融合分支网络输出的特征 g_s 和 g_m , 构建出运动目标的状态转移模型, 将特征拼接并输入到输出维度为 $L_{\text{state}} \times L_{\text{state}}$ 的多层感知机中, 随后得到 $F_k \in \mathbf{R}^{L_{\text{state}} \times L_{\text{state}}}$:

$$F_k = \text{MLP}_F([g_s \cdot g_m]) \quad (18)$$

其中, $[\cdot]$ 表示向量拼接操作. 由此, 运动目标的状态转移模型可构建为

$$F_{nn} = \mathbf{I} + F_k \quad (19)$$

为准确刻画目标机动模式切换及外部环境引入的不确定性, 将从数据中学习过程噪声统计特性. 为保证其正定性, 过程噪声协方差 Q_k 通过 Cholesky 分解表示, 即

$$Q_k = L_Q L_Q^T \quad (20)$$

其中, L_Q 为下三角矩阵, 其矩阵元素可由特征 $\Psi \in \mathbf{R}^{L_{\text{state}}(L_{\text{state}}+1)/2}$ 通过如下参数化方式得到:

$$L_{Q,ij}(\Psi) = \begin{cases} 0, & i < j \\ e^{\Psi \frac{L_{\text{state}}(L_{\text{state}}-1)}{2} + i}, & i = j \\ \Psi \frac{(i-2)(i-1)}{2} + j, & i > j \end{cases} \quad (21)$$

通过引入指数映射, 使得 L_Q 对角线元素为正, 以确保 Q_k 具有正定性. Ψ 可通过一个多层感知机 MLP_Q 得到, 即

$$\Psi = \text{MLP}_Q([g_m \cdot g_s]) \quad (22)$$

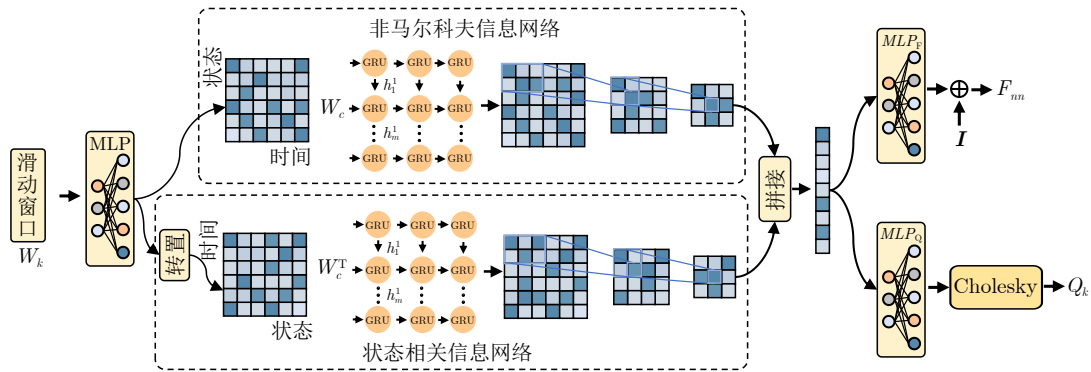


图3 双支协同网络内部框图

Fig.3 Dual-branch collaborative network internal block diagram

2.3 目标跟踪方法设计

贝叶斯滤波是一种常见的用于递归估计未知概率密度函数的概率方法, 包括时间更新和量测更新两步.

1) 时间更新

$$p(\mathbf{x}_k | \mathbf{z}_{1:k-1}) = \int p(\mathbf{x}_k | \mathbf{x}_{k-1}) p(\mathbf{x}_{k-1} | \mathbf{z}_{1:k-1}) d\mathbf{x}_{k-1} \quad (23)$$

2) 量测更新

$$p(\mathbf{x}_k | \mathbf{z}_{1:k}) = \frac{p(\mathbf{z}_k | \mathbf{x}_k) p(\mathbf{x}_k | \mathbf{z}_{1:k-1})}{\int p(\mathbf{z}_k | \mathbf{x}_k) p(\mathbf{x}_k | \mathbf{z}_{1:k-1}) d\mathbf{x}_k} \quad (24)$$

其中, $p(\cdot)$ 表示概率密度函数. 由式 (18) ~ (22) 可得状态转移模型 F_{nn} 和过程噪声协方差 Q_k . 运动目标状态 \mathbf{x}_k 的先验均值 $\hat{\mathbf{x}}_{k|k-1}$ 和协方差 $P_{k|k-1}$ 可由式 (25) 和式 (26) 计算得到, 即

$$\begin{aligned} \hat{\mathbf{x}}_{k|k-1} &= \int f_g(\mathbf{x}_{k-1}) p(\mathbf{x}_{k-1} | \mathbf{z}_{1:k-1}) d\mathbf{x}_{k-1} = \\ &\int F_{nn} \mathbf{x}_{k-1} N(\mathbf{x}_k; \hat{\mathbf{x}}_{k-1|k-1}, P_{k-1|k-1}) d\mathbf{x}_{k-1} = \\ &F_{nn} \hat{\mathbf{x}}_{k-1|k-1} \end{aligned} \quad (25)$$

$$\begin{aligned} P_{k|k-1} &= \int (f_g(\mathbf{x}_{k-1}) - \hat{\mathbf{x}}_{k|k-1})(f_g(\mathbf{x}_{k-1}) - \hat{\mathbf{x}}_{k|k-1})^T \times \\ &p(\mathbf{x}_{k-1} | \mathbf{z}_{1:k-1}) d\mathbf{x}_{k-1} = \\ &\int (F_{nn} \mathbf{x}_{k-1})(F_{nn} \mathbf{x}_{k-1})^T \times \\ &N(\mathbf{x}_k; \hat{\mathbf{x}}_{k-1|k-1}, P_{k-1|k-1}) d\mathbf{x}_{k-1} - \\ &\hat{\mathbf{x}}_{k|k-1} \hat{\mathbf{x}}_{k|k-1}^T + Q_k = \\ &F_{nn} P_{k-1|k-1} F_{nn}^T + Q_k \end{aligned} \quad (26)$$

其中, $N(\cdot)$ 表示高斯分布. 对式 (10) 中无偏量测转换得到的伪线性量测 $\hat{\mathbf{z}}_k$ 需重新计算量测噪声协方差矩阵 $R_{\text{ucm}, k}$, 即

$$R_{\text{ucm}, k} = \begin{bmatrix} R_{11} & R_{21} \\ R_{12} & R_{22} \end{bmatrix} \quad (27)$$

$R_{\text{ucm}, k}$ 中各元素可由式 (28) ~ (30) 计算得到:

$$\begin{aligned} R_{11} &= \text{Var}(p_{x, k, m}^{\text{ucm}} | r_k, m, \beta_k, m) = \\ &E[(\lambda_\beta^{-1} r_{k, m} \cos \beta_{k, m} - r \cos \beta)^2 | r_k, m, \beta_k, m] = \\ &E[(\lambda_\beta^{-1} r_{k, m} \cos \beta_{k, m} - (r_{k, m} - u_{k, r}) \times \\ &\cos(\beta_{k, m} - u_{k, \beta}))^2 | r_k, m, \beta_k, m] = \\ &(\lambda_\beta^{-2} - 2) r_{k, m}^2 \cos^2 \beta_{k, m} + \\ &\frac{1}{2} (r_{k, m}^2 + \sigma_r^2) (1 + \lambda'_\beta \cos 2\beta_{k, m}) \end{aligned} \quad (28)$$

$$\begin{aligned} R_{22} &= \text{Var}(p_{y, k, m}^{\text{ucm}} | r_k, m, \beta_k, m) = \\ &E[(\lambda_\beta^{-1} r_{k, m} \sin \beta_{k, m} - r \sin \beta)^2 | r_k, m, \beta_k, m] = \\ &E[(\lambda_\beta^{-1} r_{k, m} \sin \beta_{k, m} - (r_{k, m} - u_{k, r}) \times \\ &\sin(\beta_{k, m} - u_{k, \beta}))^2 | r_k, m, \beta_k, m] = \\ &(\lambda_\beta^{-2} - 2) r_{k, m}^2 \sin^2 \beta_{k, m} + \\ &\frac{1}{2} (r_{k, m}^2 + \sigma_r^2) (1 - \lambda'_\beta \cos 2\beta_{k, m}) \end{aligned} \quad (29)$$

$$\begin{aligned} R_{12} = R_{21} &= \text{Cov}(p_{x, k, m}^{\text{ucm}}, p_{y, k, m}^{\text{ucm}} | r_k, m, \beta_k, m) = \\ &E[(\lambda_\beta^{-1} r_{k, m} \cos \beta_{k, m} - r \cos \beta) \times \\ &(\lambda_\beta^{-1} r_{k, m} \sin \beta_{k, m} - r \sin \beta)] = \\ &E[\lambda_\beta^{-2} r_{k, m}^2 \cos \beta_{k, m} \sin \beta_{k, m} - \\ &\lambda_\beta^{-1} r_{k, m} (r_{k, m} - u_{k, r}) \cos \beta_{k, m} \sin(\beta_{k, m} - \\ &u_{k, \beta}) - \lambda_\beta^{-1} r_{k, m} (r_{k, m} - \\ &u_{k, r}) \sin \beta_{k, m} \cos(\beta_{k, m} - u_{k, \beta}) + \\ &(r_{k, m} - u_{k, r})^2 \sin(\beta_{k, m} - \\ &u_{k, \beta}) \cos(\beta_{k, m} - u_{k, \beta})] = \\ &(\lambda_\beta^{-2} - 2) r_{k, m}^2 \cos \beta_{k, m} \sin \beta_{k, m} + \\ &\frac{1}{2} (r_{k, m}^2 + \sigma_r^2) \lambda'_\beta \sin 2\beta_{k, m} \end{aligned} \quad (30)$$

式 (28) ~ (30) 中, $u_{k, \beta}$ 和 $u_{k, r}$ 为方位角和径向距离的量测噪声, σ_k 是 $u_{k, r}$ 的标准差, $\lambda_\beta = E(\cos u_{k, \beta}) = e^{-\frac{\sigma_\beta^2}{2}}$, $\lambda'_\beta = E(\cos 2u_{k, \beta}) = e^{-2\sigma_\beta^2}$, 其伪线性观测矩阵为

$$H_{\text{ucm}} = \begin{bmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \end{bmatrix} \quad (31)$$

运动目标的系统状态包含多个状态分量 (如位置、速度和加速度等), 无偏量测转换得到伪线性量测为目标的位置信息, H_{ucm} 矩阵前两列所对应的对角元素置 1, 以反映系统状态到伪线性量测间的映射关系.

观测预测值协方差 $P_{z, k|k-1}$ 以及先验状态估计值与观测预测值间的互协方差 $P_{xz, k|k-1}$ 可由式 (32) ~ (34) 计算得到:

$$\begin{aligned} P_{z, k|k-1} &= \\ &\int h(\mathbf{x}_k) h^T(\mathbf{x}_k) N(\mathbf{x}_k; \hat{\mathbf{x}}_{k|k-1}, P_{k|k-1}) d\mathbf{x}_k - \\ &\hat{\mathbf{z}}_{k|k-1} \hat{\mathbf{z}}_{k|k-1}^T + R_{\text{ucm}, k} = \\ &\int (H_{\text{ucm}} \mathbf{x}_k)(H_{\text{ucm}} \mathbf{x}_k)^T N(\mathbf{x}_k; \hat{\mathbf{x}}_{k|k-1}, P_{k|k-1}) d\mathbf{x}_k - \\ &\hat{\mathbf{z}}_{k|k-1} \hat{\mathbf{z}}_{k|k-1}^T + R_{\text{ucm}, k} = \\ &H_{\text{ucm}} P_{k|k-1} H_{\text{ucm}}^T + R_{\text{ucm}, k} \end{aligned} \quad (32)$$

$$P_{x_z, k|k-1} = \int \mathbf{x}_k h^T(\mathbf{x}_k) N(\mathbf{x}_k; \hat{\mathbf{x}}_{k|k-1}, P_{k|k-1}) d\mathbf{x}_k - \hat{\mathbf{x}}_{k|k-1} \hat{\mathbf{z}}_{k|k-1}^T = \int \mathbf{x}_k (H_{ucm} \mathbf{x}_k)^T N(\mathbf{x}_k; \hat{\mathbf{x}}_{k|k-1}, P_{k|k-1}) d\mathbf{x}_k - \hat{\mathbf{x}}_{k|k-1} \hat{\mathbf{z}}_{k|k-1}^T = P_{k|k-1} H_{ucm}^T \quad (33)$$

$$\hat{\mathbf{z}}_{k|k-1} = H_{ucm} \hat{\mathbf{x}}_{k|k-1} \quad (34)$$

由式 (35) 和式 (36) 可得 \mathbf{x}_k 的后验状态均值 $\hat{\mathbf{x}}_{k|k}$ 和后验协方差 $P_{k|k}$:

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + K_g (\hat{\mathbf{z}}_k - \hat{\mathbf{z}}_{k|k-1}) \quad (35)$$

$$P_{k|k} = P_{k|k-1} - K_g P_{z, k|k-1} K_g^T \quad (36)$$

其中, 滤波增益 K_g 为

$$K_g = P_{x_z, k|k-1} (P_{z, k|k-1})^{-1} \quad (37)$$

2.4 联合损失函数设计

为优化双支协同滤波网络的性能, 所设计的损失函数包括两部分. 其中, 第一部分用于优化目标跟踪的性能, 即为状态估计值与状态真值间的均方误差:

$$L_{mse} = \frac{1}{MT} \sum_{i=1}^M \sum_{k=1}^T (\mathbf{x}_{i, k, gt} - \hat{\mathbf{x}}_{i, k|k})^T \times (\mathbf{x}_{i, k, gt} - \hat{\mathbf{x}}_{i, k|k}) \quad (38)$$

其中, T 为目标运动序列长度, M 为单个训练批次的样本数, $\mathbf{x}_{i, k, gt}$ 和 $\hat{\mathbf{x}}_{i, k|k}$ 分别为状态真值和状态估计值.

第二部分使用最大均值差异约束项. 其原因在于, 非马尔科夫信息网络与状态相关信息网络特征提取角度上有所不同, 但相似的结构使其存在学习冗余性. 因此通过最大化两个分支网络输出特征分布间的差异, 将使其具有学习互补性. 在包含 M 个样本的训练批次中, 分支网络输出特征为 $G_s = \{g_s^{(1)}, g_s^{(2)}, \dots, g_s^{(M)}\}$ 和 $G_m = \{g_m^{(1)}, g_m^{(2)}, \dots, g_m^{(M)}\}$. 其中, G_m 与 G_s 可视为两个独立的样本集. 为使分支网络专注于学习非马尔科夫特征与状态变量间相关性特征, 其关键在于最大化由两个样本集 G_s 和 G_m 所分别表征的复杂分布 P_S 和 P_M 间的差异. 然而, P_S 和 P_M 间的差异往往无法直接计算. 因此, 引入最大均值差异 MMD 作为度量两个概率分布差异的非参数方法, 仅依赖于样本即可计算出其分布间距离. 具体而言, P_S 和 P_M 的 MMD 距离可由 MMD 经验公式计算得到, 即

$$MMD(P_S, P_M) = \left\| \frac{1}{M} \sum_{i=1}^M \phi(g_s^{(i)}) - \frac{1}{M} \sum_{j=1}^M \phi(g_m^{(j)}) \right\|_{\mathcal{H}} \quad (39)$$

其中, $\phi(\cdot)$ 表示将样本映射到再生核希尔伯特空间 \mathcal{H} 的映射函数. 通过使用核技巧, MMD 的计算可以避免在高维空间中操作 $\phi(\cdot)$, 即

$$MMD^2 = \frac{1}{M^2} \sum_{i, j=1}^M \kappa(g_s^{(i)}, g_s^{(j)}) + \frac{1}{M^2} \sum_{j, i=1}^M \kappa(g_m^{(i)}, g_m^{(j)}) - \frac{2}{M^2} \sum_{i=1}^M \sum_{j=1}^M \kappa(g_s^{(i)}, g_m^{(j)}) \quad (40)$$

其中, $\kappa(\cdot)$ 为核函数且具有内积关系 $\kappa(g_s^{(i)}, g_m^{(i)}) = \langle \phi(g_s^{(i)}), \phi(g_m^{(i)}) \rangle$. 本文使用高斯核函数, MMD 值越大表示两个分布差异越大; 反之, 则越小. 为使分支网络具有学习互补性, 使用 MMD 距离倒数作为损失函数的第二部分, 即

$$L_{mmd} = \frac{1}{MMD(G_s, G_m)} \quad (41)$$

最终的损失函数为

$$Loss = \lambda L_{mse} + (1 - \lambda) L_{mmd} \quad (42)$$

式 (42) 中, λ 为调节两个损失函数项的权重系数. 完整的 DBCF-Net 算法流程见算法 1.

算法 1. DBCF-Net 算法

- 1: 初始化网络参数 θ
- 2: **for** $i = 1$ **to** $Epoch$ **do**
- 3: 初始化 GRU 隐藏状态
- 4: 从训练数据中随机抽取 M 条轨迹: $\{\mathbf{x}_{1:T}, \mathbf{z}_{1:T}\}^M$
- 5: **for** k **in** T **do**
- 6: 由式 (27) ~ (30) 计算 $R_{ucm, k}$
- 7: 由式 (10) 进行无偏量测转换
- 8: 由式 (12) 和式 (13) 进行预处理
- 9: 双支协同网络前向传播得 F_{nn}, Ψ, G_s, G_m
- 10: 由式 (20) ~ (22) 计算 Q_k
- 11: 由式 (25) 和式 (26) 进行时间更新
- 12: 由式 (32) ~ (37) 进行量测更新
- 13: 由式 (42) 计算损失函数
- 14: **end for**
- 15: 使用梯度更新网络参数 θ
- 16: **end for**

3 实验

3.1 训练数据

本文采用 LAST 数据集来生成轨迹数据以完成模型训练和验证^[14]. LAST 数据集是为民用机场

监视任务而构建的基于状态空间模型的仿真数据集. 本文依据光电跟踪系统参数设置 LAST 数据集参数, 其中方位角与测距噪声标准差分别设置为 $0.04^\circ \sim 0.05^\circ$ 和 $0.8 \sim 1.2$ m, 采样频率设置为 10 Hz, 其他参数依照文献 [14] 进行设置, 包括飞行距离范围、飞行速度范围、转弯率范围及加速度扰动等. 总共生成 15 000 条轨迹, 其中, 13 000 条用于模型训练, 2 000 条用于验证. 为直观展示所用数据集, 图 4 展示了从训练数据中抽取的 2 000 条轨迹的可视化图.

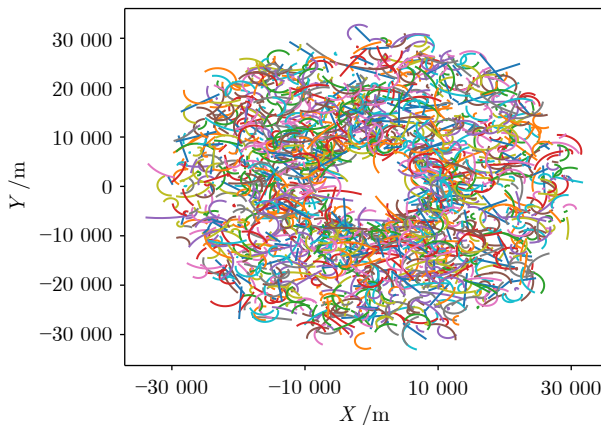


图 4 训练数据轨迹图

Fig. 4 Training data trajectory chart

3.2 实验设置

为验证所提方法的有效性, 本文设计 6 条飞行轨迹, 轨迹持续时间均为 75 s, 覆盖多种运动模式, 且具有不同的初始位置、速度与转弯率. 具体运动参数如表 1 所示. 轨迹的量测噪声和过程噪声标准差范围与训练数据保持一致. 此外, 本文还将所提方法与交互式多模型 (IMM)、KalmanNet 及 DeepMTT 方法进行对比. 在 IMM 方法中, 分别以扩展卡尔曼滤波 (EKF) 和无迹卡尔曼滤波 (UKF) 作为基底滤波器, 且已知运动模型参数. KalmanNet 方

法采用匀速模型作为基础模型, 并使用无偏量测转换后的数据进行训练.

3.3 模型参数及训练细节

实验的网络模型基于 Python 语言实现, 由 Pytorch 2.2.1 库搭建, 在英特尔 i5 12600KF 处理器以及英伟达 RTX 4070 显卡上完成训练和测试. GRU 层数为 3, 隐藏状态长度为 128, CNN 卷积核尺寸为 (6, 3), 模型训练总轮次设置为 300, 训练批次设置为 32, 使用 Adam 优化器, 学习率设置为 0.001, λ 设置为 0.9.

3.4 实验结果分析

不同方法的跟踪轨迹可视化图、状态均方根误差 (root mean square error, RMSE) 曲线图以及平均均方根误差 (average RMSE, ARMSE) 值, 如图 5、图 6 和表 2 所示. 此外, 本文还绘制跟踪轨迹局部放大图, 以直观展示各方法的跟踪性能. 表 2 总结了各方法的跟踪性能, 从表 2 可以看出, KalmanNet 整体性能相对较差, 该方法难以有效应对目标运动复杂多变的情况, 导致其跟踪性能较差; DeepMTT 方法在目标机动性较弱时跟踪效果尚可, 但在机动性较强的情况下, 其跟踪性能有所下降, 这是因为该方法采用 UKF-CV (constant velocity) 对观测数据进行预处理, 当运动目标的机动性较强时, 该预处理方法无法为后级模型提供准确的信息. IMM-UKF 和 IMM-EKF 方法的跟踪效果优于前两种方法, 这主要得益于其多运动模型能更好地适配目标复杂的运动过程. 然而, 此类基于模型的跟踪方法通常采用马尔科夫假设, 未考虑历史状态对当前状态的影响, 因此跟踪精度存在一定局限. 此外, 由于 IMM 方法的模型交互机制的存在, 正确模型会受到其他模型的干扰, 这进一步限制了其跟踪性能. 与基于模型的跟踪方法不同, 本文提出的 DBCF-Net, 融合基于模型与深度学习方法的优点, 能够动态调整运动模型及参数, 为后级滤波器提供

表 1 测试轨迹运动参数

Table 1 Test trajectory maneuver parameters

轨迹序号	初始状态	第 1 段	第 2 段	第 3 段
1	[-17 000.0 m, 2 600.0 m, 200.0 m/s, 120.0 m/s]	20 s, CV	25 s, CT, $\omega = 3.6$ ($^\circ$)/s	30 s, CT, $\omega = -6.4$ ($^\circ$)/s
2	[-6 860.0 m, 24 320.0 m, 90.0 m/s, -130.0 m/s]	25 s, CT, $\omega = 1.0$ ($^\circ$)/s	25 s, CT, $\omega = -1.6$ ($^\circ$)/s	25 s, CT, $\omega = -6.4$ ($^\circ$)/s
3	[17 155.0 m, -9 300.0 m, -169.0 m/s, 140.0 m/s]	10 s, CV	50 s, CT, $\omega = 8.00$ ($^\circ$)/s	15 s, CV
4	[13 345.0 m, -11 300.0 m, 69.0 m/s, 140.0 m/s]	25 s, CV	30 s, CT, $\omega = -7.0$ ($^\circ$)/s	20 s, CT, $\omega = 6.48$ ($^\circ$)/s
5	[19 134.0 m, 19 144.0 m, -235.0 m/s, -33.0 m/s]	20 s, CT, $\omega = 6.08$ ($^\circ$)/s	30 s, CV	25 s, CT, $\omega = -9.01$ ($^\circ$)/s
6	[9 360.0 m, -8 740.0 m, -140.0 m/s, -1.0 m/s]	20 s, CT, $\omega = 9.08$ ($^\circ$)/s	30 s, CT, $\omega = -8.1$ ($^\circ$)/s	25 s, CT, $\omega = 1.08$ ($^\circ$)/s

注: CT: Constant turn.

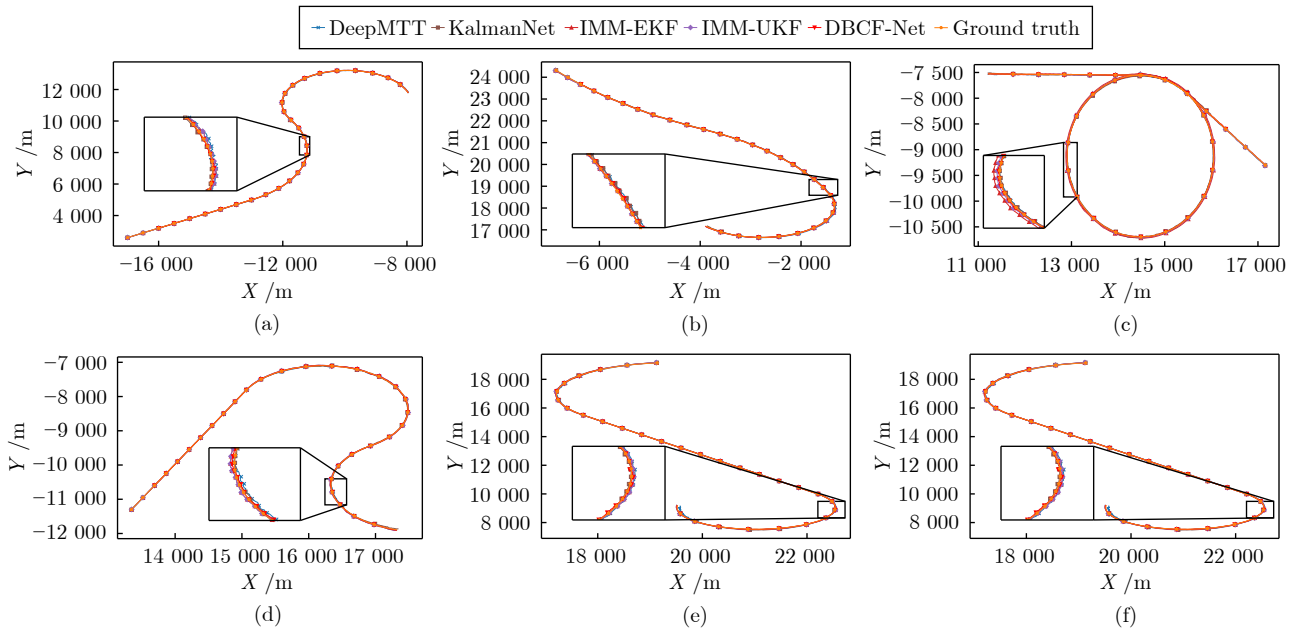


图 5 6 条轨迹的跟踪结果, 其中放大的子图中包含 30 个采样点的轨迹片段 (主图中每隔 2.5 s (25 个采样点) 标记一次采样点, 子图中每隔 0.5 s 标记一次采样点)

Fig.5 The tracking results of six trajectories, where the enlarged subplot contains 30 sampled trajectory segments (In the main plot, sampling points are marked at intervals of 2.5 s (corresponding to 25 sampling points), while in the subplot, they are marked every 0.5 s)

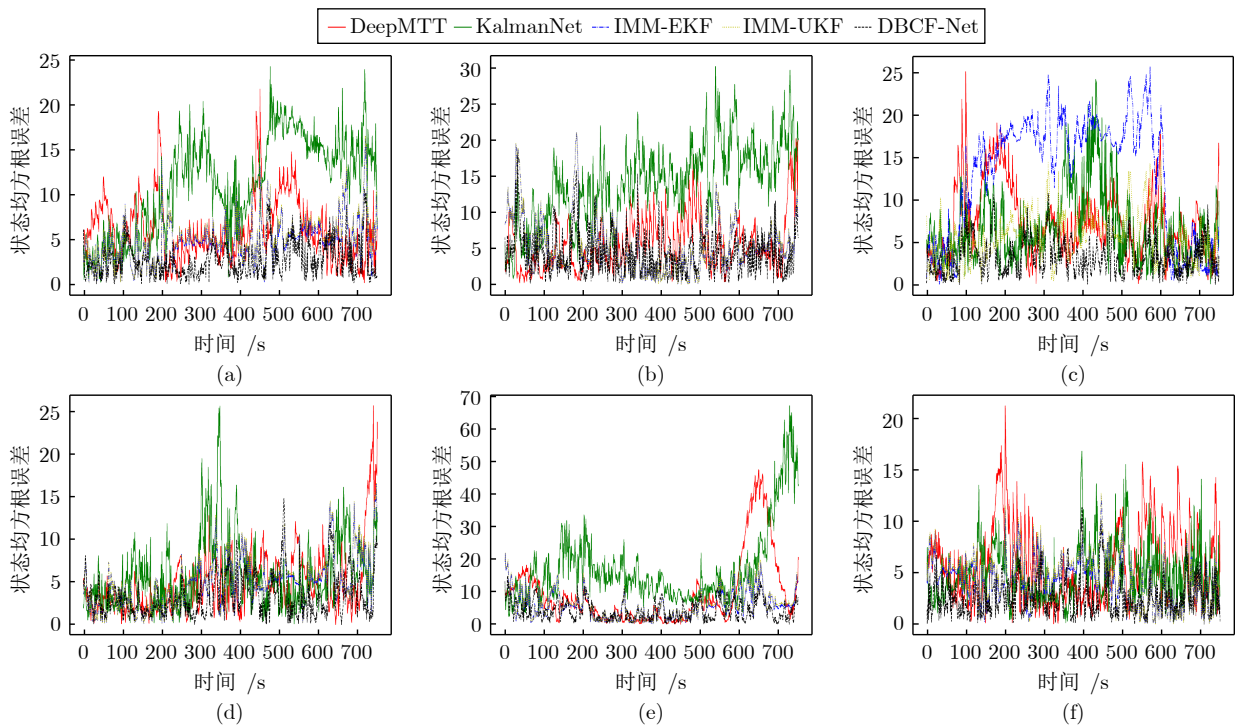


图 6 6 条测试轨迹的目标状态估计的均方根误差

Fig.6 RMSE of the target state estimation for the six test trajectories

高质量先验模型信息, 实现了较好的跟踪效果. 从跟踪轨迹可视化图 (图 5) 可以看出, DBCF-Net 的跟踪轨迹始终与目标真实运动轨迹高度吻合, 在跟

踪过程中不仅保持较小的误差, 还表现出较高的稳定性; 而从状态均方根误差图 (图 6) 可以看出, 其他方法相比 DBCF-Net 波动更明显.

3.5 消融实验

为验证本文提出的网络结构及基于 MMD 约束网络权重更新机制的有效性, 本节设计系统的消融实验, 在两条测试轨迹上对比以下模型: 单分支模型 Single 1 (仅保留非马尔科夫信息网络)、单分支模型 Single 2 (仅保留状态相关信息网络) 和无 MMD 约束模型 (No MMD). 测试轨迹运动参数如表 3 所示.

表 4 展示了消融实验测试轨迹的 ARMSE 值. 从表 4 可以看出, DBCF-Net 在两条轨迹的位置和速度误差上均表现最优, 图 7 进一步直观展示了其跟踪轨迹与真实轨迹的贴合度更高且波动更小. 单

分支模型中, 仅保留非马尔科夫网络 (Single 1) 和状态相关信息网络 (Single 2) 时, 位置和速度的 ARMSE 明显增大. 测试轨迹 1 中, 位置跟踪误差增大至 6.758 和 6.920, 速度误差增大至 8.908 和 10.813, 这表明双支协同网络通过双分支特征融合, 有效提升了目标跟踪的性能. 在移除 MMD 损失函数后模型性能出现下降, 测试轨迹 2 的位置跟踪误差增大至 9.209, 速度误差增大至 9.189, 说明 MMD 损失函数通过差异化分支网络的输出, 有效增强了方法对未知运动模型的适应能力. 通过消融实验验证了双分支网络结构与基于 MMD 约束网络权重协同更新机制的有效性.

表 2 不同方法在测试轨迹上的平均均方根误差 (ARMSE)
Table 2 The ARMSE of states for different methods on the test trajectory

方法	参数	轨迹 1	轨迹 2	轨迹 3	轨迹 4	轨迹 5	轨迹 6
IMM-EKF	位置 (m)	4.872	5.208	12.942	4.942	5.969	4.236
	速度 (m/s)	9.606	6.569	21.949	8.336	11.263	8.919
IMM-UKF	位置 (m)	5.089	5.267	5.564	5.082	6.310	4.437
	速度 (m/s)	10.149	6.689	11.320	8.707	12.177	9.404
DeepMTT	位置 (m)	6.061	5.576	7.240	4.889	9.473	5.797
	速度 (m/s)	3.676	4.493	6.904	4.400	7.595	6.045
KalmanNet	位置 (m)	11.302	14.067	6.641	5.863	17.151	4.977
	速度 (m/s)	12.279	13.168	15.105	13.652	14.708	9.856
DBCF-Net	位置 (m)	2.678	4.400	3.339	3.365	4.364	2.682
	速度 (m/s)	3.806	4.430	4.900	3.956	5.103	3.938

注: 加粗字体表示最优结果.

表 3 消融实验测试轨迹运动参数
Table 3 Test trajectory maneuver parameters of ablation experiment

轨迹序号	初始状态	第 1 段	第 2 段	第 3 段
1	[-19280.0 m, 18250.0 m, 180.0 m/s, 50.0 m/s]	5 s, CV	20 s, CT, $\omega = -9.0$ ($^{\circ}$)/s	15 s, CT, $\omega = 8.4$ ($^{\circ}$)/s
2	[-16900.0 m, 15500.0 m, 220.0 m/s, 300.0 m/s]	5 s, CV	15 s, CT, $\omega = 5.0$ ($^{\circ}$)/s	20 s, CT, $\omega = -3.4$ ($^{\circ}$)/s

表 4 消融实验测试轨迹 ARMSE 值
Table 4 ARMSE of ablation experiment test trajectory

方法	参数	轨迹 1	轨迹 2
DBCF-Net	位置 (m)	5.106	5.317
	速度 (m/s)	6.161	7.265
Single 1	位置 (m)	6.758	8.169
	速度 (m/s)	8.908	9.801
Single 2	位置 (m)	6.920	8.409
	速度 (m/s)	10.813	7.631
No MMD	位置 (m)	7.233	9.209
	速度 (m/s)	9.666	9.189

4 结束语

针对时序-状态相关性提取不足引起的目标跟踪性能下降问题, 本文提出双支协同滤波网络 DBCF-Net. DBCF-Net 通过双支协同网络学习运动目标状态演化过程的时序依赖性及状态中多变量间的局部相关性, 实现运动模型和过程噪声参数的动态调整. 同时, 建立基于最大均值差异的网络权重协同更新机制, 使得双分支网络具有学习互补性, 提升对未知模型的适应能力. 本文所提方法目前仅在 XY 平面内的目标跟踪实验中验证了其有效性, 未涉及更为复杂的三维运动场景. 因此, 未来的研究

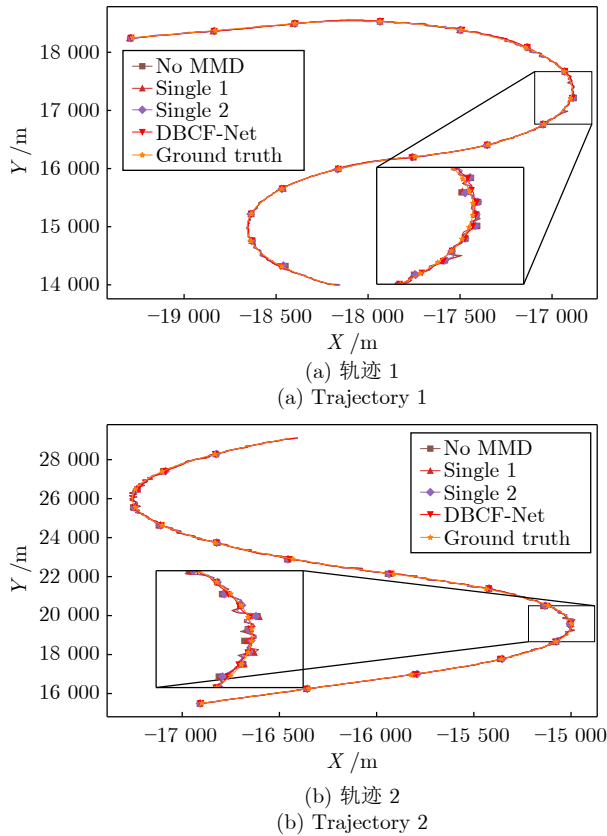


图 7 消融实验跟踪结果可视化图

Fig. 7 Visualization of the tracking results obtained in the ablation experiments

将进一步把方法扩展至三维运动情形, 探索更具鲁棒性的滤波算法。同时, 将进一步优化网络结构, 以提升方法在复杂动态环境中的实用性及鲁棒性。

参考文献

- Cortina E, Otero D, Attellis C E. Maneuvering target tracking using extended Kalman filter. *IEEE Transactions on Aerospace and Electronic Systems*, 1991, **27**(1): 155–158
- Julier S J, Uhlmann J K. Unscented filtering and nonlinear estimation. *Proceedings of the IEEE*, 2004, **92**(3): 401–422
- Solaiman S, Alsawat E, Alharthi R. Simultaneous tracking and recognizing drone targets with millimeter-wave radar and convolutional neural network. *Applied System Innovation*, 2023, **6**(4): Article No. 68
- Yan B, Wei Y, Liu S, Huang W, Feng R, Chen X. A review of current studies on the unmanned aerial vehicle-based moving target tracking methods. *Defence Technology*, 2025, **51**: 201–219
- Alhafnawi M, Bany S H, Masadeh A, Al-Obiedollah H, Ayyash M, El-Khazali R, et al. A survey of indoor and outdoor UAV-based target tracking systems: Current status, challenges, technologies, and future directions. *IEEE Access*, 2023, **11**: 68324–68339
- Yasmeen A, Daescu O. Recent research progress on ground-to-air vision-based anti-UAV detection and tracking methodologies: A review. *Drones*, 2025, **9**(1): Article No. 58
- Yang Y, Moran B, Wang X, Brown T C, Williams S, Pan Q. Experimental analysis of a game-theoretic formulation of target tracking. *Automatica*, 2020, **114**: 1–10
- Magill D. Optimal adaptive estimation of sampled stochastic processes. *IEEE Transactions on Automatic Control*, 1965, **10**(4): 434–439
- Blom H A P, Bar-Shalom Y. The interacting multiple model algorithm for systems with Markovian switching coefficients. *IEEE Transactions on Automatic Control*, 1988, **33**(8): 780–783
- Dacipour E, Bar-Shalom Y. IMM tracking of maneuvering targets in the presence of glint. *IEEE Transactions on Aerospace and Electronic Systems*, 1998, **34**(3): 996–1003
- Wu W, Cheng P. A nonlinear IMM algorithm for maneuvering target tracking. *IEEE Transactions on Aerospace and Electronic Systems*, 1994, **30**(3): 875–886
- Li W, Jia Y, Du J, Yu F. Gaussian mixture PHD smoother for jump markov models in multiple maneuvering targets tracking. In: *Proceedings of the American Control Conference*. San Francisco, USA: IEEE, 2011. 3024–3029
- Xu L, Li X R. Hybrid grid multiple-model estimation with application to maneuvering target tracking. In: *Proceedings of the 13th International Conference on Information Fusion*. Edinburgh, UK: IEEE, 2010. 1–7
- Liu J, Wang Z, Xu M. DeepMTT: A deep learning maneuvering target-tracking algorithm based on bidirectional LSTM network. *Information Fusion*, 2020, **53**: 289–304
- Yang X, Qiao D. Attention-based bidirectional LSTM network for target tracking. In: *Proceedings of IEEE International Conference on Electronic Technology, Communication and Information*. Changchun, China: IEEE, 2021. 151–156
- Zhai B, Yi W, Li M, Ju H, Kong L. Data-driven XGBoost-based filter for target tracking. In: *Proceedings of the International Radar Conference*. Nanjing, China: IET, 2019. 6683–6687
- Zhang Wen-An, Lin An-Di, Yang Xu-Sheng, Yu Li, Yang Xiao-Niu. A survey on Bayesian filtering with deep learning. *Acta Automatica Sinica*, 2024, **50**(8): 1502–1516
(张文安, 林安迪, 杨旭升, 俞立, 杨小牛. 融合深度学习的贝叶斯滤波综述. *自动化学报*, 2024, **50**(8): 1502–1516)
- Chen C, Lu C X, Wang B, Trigoni N, Markham A. DynaNet: Neural Kalman dynamical model for motion estimation and prediction. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, **32**(12): 5479–5491
- Yang Xu-Sheng, Li Fu-Xiang, Hu Fo, Zhang Wen-An. Human motion estimation based on EMG-inertial fusion: A Gaussian filtering network approach. *Acta Automatica Sinica*, 2024, **50**(5): 991–1000
(杨旭升, 李福祥, 胡佛, 张文安. 基于肌电-惯性融合的人体运动估计: 高斯滤波网络方法. *自动化学报*, 2024, **50**(5): 991–1000)
- Revach G, Shlezinger N, Ni X, Escoriza A L, van Sloun R J G, Eldar Y C. KalmanNet: Neural network aided Kalman filtering for partially known dynamics. *IEEE Transactions on Signal Processing*, 2022, **70**: 1532–1547
- Choi G, Park J, Shlezinger N, Eldar Y C, Lee N. Split KalmanNet: A robust model-based deep learning approach for state estimation. *IEEE Transactions on Vehicular Technology*, 2023, **72**(9): 12326–12331
- Escoriza A L, Revach G, Shlezinger N, van Sloun R J G. Data-driven Kalman-based velocity estimation for autonomous racing. In: *Proceedings of the IEEE International Conference on Autonomous Systems*. Montreal, QC, Canada: IEEE, 2021. 1–5
- Yang Xu-Sheng, Wang Xue-Er, Wang Peng-Jun, Zhang Wen-An. Estimation of human limb motion based on progressive unscented Kalman filter network. *Acta Automatica Sinica*, 2023,

49(8): 1723–1731

(杨旭升, 王雪儿, 汪鹏君, 张文安. 基于渐进无迹卡尔曼滤波网络的人体肢体运动估计. 自动化学报, 2023, 49(8): 1723–1731)

- 24 Ding X, Guo Y, Ding G, Han J. ACNet: Strengthening the kernel skeletons for powerful CNN via asymmetric convolution blocks. In: Proceedings of IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, South Korea: 2019. 1911–1920



张文安 浙江工业大学信息工程学院教授. 主要研究方向为多源信息融合估计和网络化系统.

E-mail: wazhang@zjut.edu.cn

(**ZHANG Wen-An** Professor at the College of Information Engineering, Zhejiang University of Technology.)

His research interests include multi-source information fusion estimation and networked systems.)



乔小龙 浙江工业大学信息工程学院硕士研究生. 主要研究方向为多源信息融合估计和深度学习.

E-mail: 211123030055@zjut.edu.cn

(**QIAO Xiao-Long** Master student at the College of Information Engineering, Zhejiang University of Tech-

nology. His research interests include multi-source information fusion estimation and deep learning.)



林安迪 浙江工业大学信息工程学院博士研究生. 主要研究方向为多源信息融合估计.

E-mail: 201706061126@zjut.edu.cn

(**LIN An-Di** Ph.D. candidate at the College of Information Engineering, Zhejiang University of Tech-

nology. His main research interest is multi-source information fusion estimation.)



杨旭升 浙江工业大学信息工程学院副教授. 主要研究方向为多源信息融合估计和目标定位. 本文通信作者.

E-mail: xsyang@zjut.edu.cn

(**YANG Xu-Sheng** Associate professor at the College of Information Engineering, Zhejiang University of

Technology. His research interests include multi-source information fusion estimation and target positioning. Corresponding author of this paper.)