

基于Transformer的转移范围优化检测前跟踪方法

张顺生* 刘晓凯 陈垣光

(电子科技大学电子科学技术研究院 成都 611731)

摘要: 现有基于深度学习的检测前跟踪(TBD)方法主要依赖历史状态序列进行运动建模与前向预测,对原始量测平面中目标能量分布及时空一致性信息的显式利用不足,在复杂机动场景下易产生累积误差和轨迹偏移。针对此问题,该文提出一种基于Transformer架构的量测引导转移门控网络(MG-TGN),以数据驱动方式生成自适应状态转移范围。MG-TGN从历史轨迹与量测序列中提取时空特征,预测先验位移概率矩阵,同时利用当前帧量测平面提取局部观测响应以估计观测似然概率,并通过可学习门控系数对二者进行动态融合,确定候选转移集合,从而约束动态规划递推的状态搜索空间。该方法将深度特征融合策略嵌入TBD框架,在保留全局路径搜索优势的同时,提升低信噪比下机动目标的能量累积一致性与轨迹稳定性。实验结果表明,相较于既有深度学习TBD方法,本文方法在信噪比为8 dB时,弱机动场景下目标检测概率提升约5%,强机动场景下提升约28%。

关键词: 检测前跟踪; 机动目标; 动态规划; Transformer架构; 转移范围优化

中图分类号: TN953

文献标识码: A

文章编号: 2095-283X(2026)x-0001-15

DOI: 10.12000/JR26038

CSTR: 32380.14.JR26038

引用格式: 张顺生, 刘晓凯, 陈垣光. 基于Transformer的转移范围优化检测前跟踪方法[J]. 雷达学报(中英文), 待出版. doi: 10.12000/JR26038.

Reference format: ZHANG Shunsheng, LIU Xiaokai, and CHEN Yuanguang. Track-Before-Detect method with transformer-based transition range optimization[J]. *Journal of Radars*, in press. doi: 10.12000/JR26038.

Track-Before-Detect Method with Transformer-Based Transition Range Optimization

ZHANG Shunsheng* LIU Xiaokai CHEN Yuanguang

(Research Institute of Electronic Science and Technology, University of Electronic Science and Technology of China, Chengdu 611731, China)

Abstract: Existing deep learning-based track-before-detect (TBD) methods primarily rely on historical state sequences for motion modeling and forward prediction. They do not explicitly utilize target energy distribution and spatiotemporal consistency information in raw measurement planes, which causes cumulative errors and trajectory drift in complex maneuvering scenarios. To address this issue, this study proposes a Transformer-based measurement-guided transition gating network (MG-TGN), which adaptively generates state transition ranges in a data-driven manner. The MG-TGN extracts spatiotemporal features from historical trajectories and measurement sequences to predict a prior displacement probability matrix. Concurrently, it uses local observation responses from the current-frame measurement plane to estimate the observation likelihood probability. These two probabilistic quantities are dynamically fused using learnable gating coefficients to form a candidate transition set, thereby constraining the state search space for dynamic programming recursion. By embedding a deep feature fusion strategy into the TBD framework, the proposed method retains the advantages of global path search while enhancing both energy accumulation consistency and trajectory stability for

收稿日期: 2026-02-02; 改回日期: ; 网络出版: 2026-xx-xx

*通信作者: 张顺生 zhangss@uestc.edu.cn

*Corresponding Author: ZHANG Shunsheng, zhangss@uestc.edu.cn

责任主编: 周共健 Corresponding Editor: ZHOU Gongjian

©The Author(s) 2026. This is an open access article under the CC-BY 4.0 License

(https://creativecommons.org/licenses/by/4.0/)

maneuvering targets under low signal-to-noise ratio (SNR) conditions. Experimental results demonstrated that, compared with existing deep learning-based TBD methods, the proposed method achieves approximately 5% and 28% higher target detection probabilities in weak and strong maneuvering scenarios, respectively, at an SNR of 8 dB.

Key words: Track-before-detect (TBD); Maneuvering target; Transformer architecture; Transition range optimization; XXX

1 引言

雷达目标检测在高级驾驶辅助、空中目标预警以及海上监视等领域具有广泛应用。传统基于门限的检测方法^[1]通常依赖单帧回波进行判决,然而,在低信噪比(Signal-to-Noise Ratio, SNR)条件下,单帧回波量测中目标回波能量微弱,往往会被噪声淹没,导致传统检测跟踪方法的性能受到严重制约。多帧检测前跟踪(Track-Before-Detect, TBD)为解决上述问题提供了有效路径,TBD方法通过跨帧信息积累估计目标状态,实现对低可观测目标的有效检测与跟踪。典型的TBD实现框架包括动态规划(Dynamic Programming, DP)^[2]、粒子滤波(Particle Filter, PF)^[3,4]以及霍夫变换(Hough Transform, HT)^[5]等。其中,DP-TBD因其有效的递推结构和全局路径优化策略被广泛采用^[6-11]。

随着电磁环境日益复杂,目标机动与隐身性能不断增强,非合作弱目标的可靠探测面临更大挑战^[12]。不同于传统的门限检测器,经典DP-TBD算法在给定状态转移约束的条件下,对多帧观测进行递推积累并通过回溯获得目标轨迹。然而,机动场景给TBD带来了新的挑战^[13-15],目标在相邻帧间的位移与速度变化具有显著不确定性,固定模型假设容易在突发机动阶段产生失配,从而降低检测概率并造成轨迹回溯偏差。

针对机动场景下基于TBD的目标检测与跟踪问题,诸多研究提出了面向机动目标的多帧TBD算法与改进策略。Grossi等人^[16,17]提出了适用于雷达系统的DP-TBD求解形式以及基于运动学边界约束(Kinematic Bound Constraints, KBC)的TBD策略,通过限定速度与加速度上界将状态转移限制在一组物理可达的运动学边界内,因此能够有效约束目标动态范围,降低无效路径数量与计算负担。然而,KBC-TBD针对机动目标的有效性仍依赖于预设的边界参数与运动假设:当目标机动范围超出先验假设时,转移集合过窄将会导致目标漏检,导致算法性能显著下降。针对上述问题,后续研究开始关注自适应的状态转移集合设计问题。Fang等人^[15]提出利用多普勒信息估计径向加速度并动态调整转移范围,初步验证了量测信息对补偿

机动的有效性。在此基础上,Yi等人^[18]将该思想系统化为量测导向(Measurement-directed, MD)的多帧TBD框架,利用当前统计模型更新目标在当前时刻的运动状态,并依据实时的量测状态估计动态引导状态转移范围,实现了对机动目标的自适应处理并降低了计算负担。然而该算法主要依赖于统计模型的准确性,量测噪声易导致模型参数估计失真,使得估计量测引导的状态转移出现偏差,进而导致DP积累的状态序列逐渐偏离真实轨迹。另一方面,Zheng等人^[19,20]也从预测机制的角度增强TBD在机动场景下的鲁棒性,其利用多项式时间序列的一步预测来调整转移概率,该类方法一定程度上缓解了固定转移集合带来的漏检与虚假路径问题,但其有效性仍依赖于历史状态序列的质量与模型参数设定。

鉴于传统方法在复杂机动场景下存在局限性,深度学习凭借其时序建模与特征提取能力,已在目标检测等视觉感知任务中取得显著进展,为雷达目标检测研究提供了新的解决思路^[22-26]。当前,将深度学习引入TBD的研究主要分为两类。一类是将神经网络作为TBD框架的增强模块,如Zhu等人^[27]在DP-TBD中引入DBU-Net以提升复杂环境下的检测性能,但其本质上是基于深度学习的TBD后处理模块,仍然受到经典TBD性能上限的制约。另一类研究则继承了传统TBD方法中的预测机制^[18],将预测模型从传统方法替换为深度神经网络,对历史状态序列进行运动建模和状态预测。例如,Song等人^[29]提出基于长短期记忆网络的TBD方法以动态预测目标运动状态。类似地,Mou等人^[30]引入Transformer架构进行轨迹预测,同样实现了深度预测模型与TBD框架的融合。尽管上述基于历史状态序列的预测策略引入了数据驱动的运动建模能力,但由于缺乏基于原始量测数据的校正机制,低SNR环境下仅依赖DP积累获取的历史状态信息可靠性较低,预测误差易随时间累积并导致轨迹偏移,进而造成目标丢失或误检;面对突发机动时响应滞后,易引发跟踪延迟或预测失配。

总的来说,基于量测点估计的TBD方法先从当前帧提取点迹,再进行运动参数修正和调整,这

类方法的性能依赖于点迹提取的质量，虚警点会使参数估计产生偏差。另一方面，部分基于历史轨迹序列的学习式TBD方法利用已回溯的历史状态进行前向预测，对原始量测平面中空间能量分布与时序一致性信息的显式建模仍不充分。与上述方法不同，本文在状态转移过程中进一步引入原始量测信息，在特征层面实现轨迹先验与量测响应的联合表征，输出位移概率分布与自适应候选转移集合。该方法以数据驱动的门控校正替代固定转移范围，在不依赖显式运动模型的前提下缓解了传统模型失配问题，同时保留了DP-TBD跨帧能量积累的核心优势。

2 模型与基础算法

2.1 目标模型

本文考虑笛卡儿坐标系下二维 $x-y$ 平面内的点目标机动场景。设目标在滑动窗口内第 k 帧的状态向量由 $\mathbf{x}_k \in \mathbb{R}^s$ 表示，其中 $\mathbb{R}^s$ 为 s 维状态空间。目标第 k 帧的状态向量表示为 $\mathbf{x}_k = [x_k, \dot{x}_k, y_k, \dot{y}_k]^T$ ， (x_k, y_k) 表示目标在 $x-y$ 平面内的位置坐标， $\dot{x}_k$ 和 $\dot{y}_k$ 分别表示沿 x 轴与 y 轴方向的速度分量。以时刻 t_0 为当前窗口的第1帧，考虑长度为 K 的连续滑动批处理窗口 $W_t = (t_0, t_0 + 1, \dots, t_0 + K - 1)$ ，该窗口内的状态序列可表示为

$$\mathbf{X}_{t_0:t_0+K-1} = (\mathbf{x}_{t_0}, \mathbf{x}_{t_0+1}, \dots, \mathbf{x}_{t_0+K-1}) \quad (1)$$

目标状态随时间的演化采用一阶马尔可夫过程假设，可用如下通用状态转移方程描述：

$$\mathbf{x}_{k+1} = \mathcal{F}_{m_k} \mathbf{x}_k + \mathbf{v}_k \quad (2)$$

其中， $\mathcal{F}_{m_k}$ 为状态转移矩阵，其具体形式取决于当前时刻的运动模型 m_k ， $\mathbf{v}_k$ 为随机过程噪声。当需要考虑更复杂的运动行为时，可依据文献[13]进一步扩展状态转移矩阵的形式，例如引入加速度约束模型、曲线运动模型或变转弯率模型等，以适配更复杂的机动模式。

2.2 量测模型

本文采用TBD方法中广泛使用的栅格化量测模型作为深度学习辅助框架的输入，该类模型已在红外[21]、雷达[15]等传感器的TBD方法中得到充分应用。假设雷达观测区域被离散为 $N_x \times N_y$ 的栅格平面，每个栅格单元的数值对应应该分辨单元内的回波幅值。设第 k 帧的量测平面为 $\mathbf{z}_k$ ，其在位置 (i, j) 处的积累统计量记为 $z_k(i, j)$ ， $(i \in [1, N_x], j \in [1, N_y])$ 。在目标存在的假设下，目标所在单元的量测由目标回波分量与噪声分量共同组成，其统计意义上的平

均能量高于无目标假设。但在低SNR条件下，目标回波可能被噪声淹没，因此需要通过TBD方法进行跨帧能量积累。具体地，量测模型可表示为

$$z_k(i, j) = \begin{cases} A_k + n_k^{H_1}, & H_1: (i, j) \text{ 存在目标} \\ n_k^{H_0}, & H_0: \text{其他} \end{cases} \quad (3)$$

其中， H_1 和 H_0 分别表示观测区域内存在目标与不存在目标两种假设。 A_k 为目标信号幅度， $n_k^{H_1}$ 和 $n_k^{H_0}$ 为高斯白噪声分量。设噪声功率为 P_n ，目标回波功率为 $P_s = |A_k|^2$ ，根据信噪比公式有

$$A_k = \sqrt{P_n \cdot 10^{\text{SNR}/10}} \quad (4)$$

假设各量测单元之间及量测噪声在空间上相互独立且同分布。将窗口内 K 帧量测平面统一表示为

$$\mathbf{Z}_{t_0:t_0+K-1} = (\mathbf{z}_{t_0}, \mathbf{z}_{t_0+1}, \dots, \mathbf{z}_{t_0+K-1}) \quad (5)$$

其中， $\mathbf{Z}_{t_0:t_0+K-1}$ 表示由连续 K 帧二维量测平面 $\mathbf{z}_k$ 沿时间维堆叠得到的三维量测序列，作为后续网络模型和DP-TBD递推处理的输入。

2.3 DP-TBD算法基础

为利用跨帧能量积累提升低可观测目标的检测能力，本文采用DP-TBD作为路径搜索框架。考虑将连续状态空间离散到栅格状态集合，将连续状态变量 $\mathbf{x}_k = [x_k, \dot{x}_k, y_k, \dot{y}_k]^T$ 离散化为状态 $\bar{\mathbf{x}}_k = [\bar{x}_k, \bar{\dot{x}}_k, \bar{y}_k, \bar{\dot{y}}_k]^T$ ，并以回波幅度作为多帧积累统计量的近似[8]，从而避免对精确观测概率密度及其参数的强依赖。

令 $I_k(\bar{\mathbf{x}}_k)$ 为离散状态 $\bar{\mathbf{x}}_k$ 在第 k 帧的值函数，DP-TBD沿潜在轨迹对目标能量进行递推累积，其递推形式可描述为

$$I_k(\bar{\mathbf{x}}_k) = \max_{\bar{\mathbf{x}}_{k-1} \in \tau(\bar{\mathbf{x}}_k)} [I_{k-1}(\bar{\mathbf{x}}_{k-1})] + |z_k| \quad (6)$$

$$\Psi_k(\bar{\mathbf{x}}_k) = \arg \max_{\bar{\mathbf{x}}_{k-1} \in \tau(\bar{\mathbf{x}}_k)} I_{k-1}(\bar{\mathbf{x}}_{k-1}) \quad (7)$$

其中， $|z_k|$ 表示当前帧量测平面在对应单元处的幅值， $\Psi_k(\bar{\mathbf{x}}_k)$ 表示目标在第 k 帧的前驱状态集合， $\tau(\bar{\mathbf{x}}_k)$ 为帧间转移时允许的状态转移范围。

在获得窗口末帧累积统计量后，对最后一帧进行门限判决：

$$\begin{aligned} \hat{\mathbf{x}}_K &= \arg \max_{\bar{\mathbf{x}}_K \in \mathbb{R}^s} [I_K(\bar{\mathbf{x}}_K)] \\ \text{s.t. } \max [I_K(\hat{\mathbf{x}}_K)] &> V_T \end{aligned} \quad (8)$$

当末帧最优累积值 $\max[I_K(\hat{\mathbf{x}}_K)]$ 超过门限 V_T 时判定目标存在，此时对应的最优状态为 $\hat{\mathbf{x}}_K$ 。门限 V_T 通常在给定虚警概率条件下，通过对无目标存在时的噪声平面进行蒙特卡罗试验确定。

通过回溯得到目标在每帧的轨迹估计:

$$\hat{\mathbf{x}}_k = \Psi_k(\bar{\mathbf{x}}_{k+1}) \quad (9)$$

从末帧最优状态 $\hat{\mathbf{x}}_K$ 出发, 沿递推过程中记录的回溯指针逐帧回推, 最终可得到批处理窗口内目标状态序列估计: $\hat{\mathbf{X}}_{t_0:t_0+K-1} = (\hat{\mathbf{x}}_{t_0}, \hat{\mathbf{x}}_{t_0+1}, \dots, \hat{\mathbf{x}}_{t_0+K-1})$ 。

3 基于Transformer的状态转移范围优化方法

机动弱目标场景下, DP-TBD的性能与复杂度在很大程度上受制于帧间状态转移范围的设定: 转移范围过大会显著扩展可行路径集合, 在提升机动覆盖能力的同时会引入大量虚假路径并显著增加DP计算量; 转移范围过小则会在强机动条件下导致目标真实路径被移除, 使得目标能量难以沿真实路径持续积累, 从而引发漏检或轨迹断裂。本文将转移范围优化问题建模为目标在离散位移域上的不确定性估计问题: 在每个时刻 k , 基于历史信息与当前观测证据, 推断目标从上一状态到下一状态的位移分布。为此, 本节提出一种量测引导的转移门控网络(Measurement-Guided Transition Gating Network, MG-TGN), 所提算法引入原始量测空间证据对转移范围进行更新, 并利用Transformer的注意力机制有效建模跨帧长序列依赖关系, 从多帧量测序列和先验轨迹序列中学习机动弱目标的时空一致性特征。所提网络在特征层面通过交叉注意力融合历史状态序列和量测平面信息, 预测目标在相邻帧间的位移及其概率矩阵, 并自适应生成候选转移集合以约束DP-TBD的转移范围搜索空间。

3.1 整体框架

为了解决基于雷达的TBD方法中帧间状态转移范围估计问题, 本文提出由MG-TGN与DP-TBD组成的闭环耦合框架, 如图1所示。

完整的推理流程采用长度为 K 的滑动窗口批处理机制。首先对窗内量测序列执行积累与回溯得到

轨迹估计; 随后将回溯的轨迹结果作为下一个处理窗口中MG-TGN的历史状态序列的先验输入, 同时, 在获取当前时刻的量测输入后, MG-TGN在下一窗内输出目标位移估计并生成候选状态集合, 从而形成“预测-更新-预测”的闭环迭代。具体地, MG-TGN的输入为量测序列 $\mathbf{Z}_{t_0:t_0+K} = (\mathbf{z}_{t_0}, \mathbf{z}_{t_0+1}, \dots, \mathbf{z}_{t_0+K})$ 与轨迹序列 $\hat{\mathbf{X}}_{t_0:t_0+K-1}$, 输出为当前位移估计, 位移概率矩阵与门控系数, 并通过自适应的Top-M选择, 得到当前帧的候选转移状态集合 $\mathcal{S}_k$, 用于限制DP-TBD的可达状态: 仅在 $\mathcal{S}_k$ 上更新值函数, 且其后向搜索在物理可达邻域内的候选转移状态集合中进行, 从而在不破坏运动合理性的前提下显著压缩搜索空间并抑制虚假路径扩散。

与仅依赖历史状态序列进行单峰值迭代推理的学习式TBD方法不同, MG-TGN的核心思路是: 每一帧同时利用原始量测序列与历史轨迹信息, 解码器的交叉注意力从量测特征中检索与轨迹先验一致的局部响应, 并利用当前帧原始量测平面实现门控校正。同时, 当位移概率矩阵不确定性较高时, 增大Top-M候选集合规模, 以避免真实路径过早丢失, 从而缓解低SNR与目标机动条件下的误差级联问题。

3.2 MG-TGN状态转移范围优化网络

MG-TGN是一种基于交叉注意力的类Transformer编码器-解码器框架: 量测平面经特征提取与token化后得到编码器的键值(Key, Value), 历史轨迹经过Transformer编码后生成查询(Query)表征, 二者通过交叉注意力机制实现位移估计。同时, 引入当前帧量测平面的空间特征作为观测证据, 并对轨迹与量测表征进行动态加权, 实现量测引导的门控校正。MG-TGN网络整体设计如图2所示, 主要由3个关键模块构成: 位移估计模块、量测引导模块与自适应门控校正模块。




图1 基于Transformer状态转移范围优化的检测前跟踪方法推理流程

Fig. 1 Inference pipeline for Transformer-based TBD with optimized state transition range

3.2.1 位移估计模块

位移估计模块的任务是从历史轨迹序列与原始量测序列中提取互补的目标运动与能量分布特征，学习得到位移空间 $\mathcal{D} = [-R, R]^2$ 上的预测位移概率

矩阵 $\pi_{\text{pred}}(\Delta)$ ，其中 Δ 表示位移量， $\Delta = (\Delta x, \Delta y)$ 。该模块由轨迹编码分支、量测编码分支、交叉注意力融合3部分组成，具体组成如图3所示。

在DP-TBD框架下可以得到回溯轨迹序列




图 2 MG-TGN整体网络架构

Fig. 2 The overall architecture of the MG-TGN network




图 3 位移估计模块

Fig. 3 Architecture of the displacement-estimation module

$\hat{\mathbf{X}}_{t_0:t_0+K-1}$, 每个时刻的状态可以表示为 $\hat{\mathbf{x}}_k$ 。同样的, 为增强对位移的鲁棒性并显式编码运动学信息, 本文构造轨迹编码分支输入的四维运动学特征: $u_k = [x_k, y_k, \Delta x_k, \Delta y_k], k = 1 \dots K$ 。随后对其进行线性映射与归一化:

$$\mathbf{e}_k = \text{LN}(\mathbf{W}u_k + \mathbf{b}) \in \mathbb{R}^D \quad (10)$$

其中 D 为嵌入向量(Embedding)维数。

为获得序列的全局表征, 轨迹编码分支中引入可学习的轨迹CLS token, 记为 $\mathbf{e}_{\text{cls}} \in \mathbb{R}^D$ 。随后叠加可学习位置编码, 并输入多层Transformer Encoder:

$$\mathbf{H}_{\text{traj}} = \text{TransEncoder}([\mathbf{e}_{\text{cls}}, \mathbf{e}_1, \dots, \mathbf{e}_K]) \quad (11)$$

轨迹序列经过Transformer编码器后, CLS token对应的输出记为 $\mathbf{h}_{\text{traj}} \in \mathbb{R}^D$, 用于表征历史轨迹的全局运动特征。

对于量测编码分支, 考虑量测平面 $\mathbf{Z}_k$ 中目标能量稀疏且噪声主导, 直接对全图进行注意力建模将导致较大的计算冗余和背景干扰。为此, 本文对窗口内每一帧提取与目标相关的感兴趣区域(Region of Interest, ROI)序列: $\mathbf{R}_{t_0:t_0+K-1}$ 。具体地, ROI的中心由窗口回溯的状态序列 $\hat{\mathbf{X}}_{t_0:t_0+K-1}$ 确定, 获取尺寸为 $P \times P$ 的量测平面区域。为了将二维ROI转换为token序列, 采用卷积Patch Embedding。对时序特征叠加空时位置编码以保留结构信息, 编码后的历史量测表示为

$$\mathbf{T}_{\text{meas}} = (\mathbf{t}_1, \mathbf{t}_2, \dots, \mathbf{t}_N) \quad (12)$$

其中, N 为沿时间维堆叠的总token数。加入可学习的CLS token并输入Transformer Encoder:

$$\mathbf{H}_{\text{meas}} = \text{TransEncoder}([\mathbf{t}_{\text{cls}}, \mathbf{T}_{\text{meas}}]) \quad (13)$$

ROI量测序列经Patch Embedding和Transformer编码器后得到量测token特征: $\mathbf{H}_{\text{meas}} \in \mathbb{R}^{N_m \times D}$, 其中 N_m 为量测token数量。量测CLS token对应的输出记为 $\mathbf{h}_{\text{meas}} \in \mathbb{R}^D$, 用于表征ROI量测序列的全局观测特征。

在交叉注意力融合阶段, 轨迹全局表征 $\mathbf{h}_{\text{traj}}$ 经线性映射后作为Query, 量测编码器输出的token特征 $\mathbf{H}_{\text{meas}}$ 经线性映射后作为Key和Value。以历史轨迹运动特征作为查询, 从量测token序列中自适应检索与当前运动状态相关的观测响应。通过多头注意力可以得到:

$$\text{Attention} = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{D}}\right)\mathbf{V} \quad (14)$$

其中, $\mathbf{Q} = \mathbf{h}_{\text{traj}}, \mathbf{K} = \mathbf{V} = \mathbf{H}_{\text{meas}}$ 。最终融合后的

表征经MLP分类头映射到 $C = (2R + 1)^2$ 个位移评分, 这里统一用 $f_{\text{pred}}(\cdot)$ 表示:

$$\mathbf{s}_{\text{pred}} = f_{\text{pred}}(\mathbf{h}_{\text{traj}}, \mathbf{H}_{\text{meas}}) \quad (15)$$

$$\pi_{\text{pred}} = \text{softmax}(\mathbf{s}_{\text{pred}}) \quad (16)$$

预测位移概率 π_{pred} 体现了依赖历史轨迹信息与量测信息对下一步位移的概率估计, 可用于在当前帧观测不可靠时提供稳定约束。

3.2.2 量测引导模块

量测引导模块旨在充分利用当前帧原始量测平面对帧间转移进行观测约束, 从而提升转移范围设计的可靠性。为了避免利用纯历史信息外推导致的累积误差, 量测引导模块引入当前量测平面的观测信息: 在上一帧状态邻域空间内提取当前帧量测特征, 并将其映射为位移空间上的观测似然概率, 在门控校正阶段用于约束和更新预测位移, 使其向真实目标位移区域收敛。

考虑DP-TBD中从上一帧位置 (x_k, y_k) 向下一帧搜索时, 转移范围枚举通常限制在一个局部状态转移集合中, 为使网络输出与TBD积累结构一致, 所提方法在当前帧量测平面 $\mathbf{z}_{k+1}$ 构造对应的局部邻域观测窗口:

$$\mathbf{W}_{k+1}(\Delta x, \Delta y) = \mathbf{z}_{k+1}(x_k + \Delta x, y_k + \Delta y) \quad (17)$$

其中, $\Delta x, \Delta y$ 与位移估计模块的 Δ 对应, 由此得到大小为 $(2R + 1) \times (2R + 1)$ 的观测子图, 使得网络能够直接学习不同候选位移在当前帧的量测响应特征, 本文实验中取 $R = 6$ 。具体的数据处理流程如图4所示。

量测引导模块采用轻量级首层卷积模块与若干残差块对观测窗口特征进行局部上下文聚合, 以增强弱目标结构并抑制背景干扰。利用轻量级首层卷积模块完成通道扩展与基础的特征聚合, 该过程可表示为

$$\mathbf{U}_{k+1}^{(0)} = f(\mathbf{W}_{k+1}) \quad (18)$$

其中, $f(\cdot)$ 由 3×3 卷积、组归一化与GELU激活函数组成, 完成通道扩展与基础特征聚合。随后, 网络经过两级残差特征提取:

$$\mathbf{U}_{k+1} = f_{\text{res}}(\mathbf{U}_{k+1}^{(0)}) \quad (19)$$

图4所示的结构中, 第一阶段采用标准残差设计, 保留观测窗口内的目标能量结构, 第二阶段采用空洞卷积残差结构, 扩大有效感受野, 提高对真实目标响应与随机噪声峰的区分能力。得到 $\mathbf{U}_{k+1}$ 后, 采用轻量预测头将每个窗口位置映射为




图 4 量测引导模块

Fig. 4 Architecture of the measurement-guided module

候选位移的评分。此外，输出端设有可学习的全局缩放因子，用于将该CNN支路与Transformer支路输出的数值量级对齐。上述过程可表示为

$$\mathbf{s}_{\text{meas}} = f_{\text{meas}}(\mathbf{U}_{k+1}) \quad (20)$$

$$\pi_{\text{meas}} = \text{softmax}(\mathbf{s}_{\text{meas}}) \quad (21)$$

经softmax后得到观测似然位移概率矩阵 π_{meas} 。

由此，模型能够在目标回波较弱时，根据当前帧量测信息对目标可能的转移方向与位移幅度进行约束；同时，为后续门控校正模块提供判断依据，实现自适应状态更新机制。

3.2.3 自适应门控校正模块

自适应门控校正模块旨在实现预测位移与观测似然的动态融合，其核心思想是通过可学习的门控机制，使融合权重能够适应于观测环境的变化。基于该融合权重输出最终更新的后验位移概率矩阵 π_{upd} ，并据此生成DP-TBD的自适应转移状态候选集合。

门控校正模块的具体构成如图5所示，该模块输入包括历史轨迹全局表征 $\mathbf{h}_{\text{traj}}$ 、量测全局表征 $\mathbf{h}_{\text{meas}}$ 和观测窗口的统计特征向量 $\phi(\mathbf{W}_{k+1})$ ，其中 $\phi(\mathbf{W}_{k+1})$ 由窗口最大值、均值、标准差、局部峰值4个统计量构成。门控系数定义如下：

$$\begin{aligned} \beta &= \beta_{\max} \cdot \sigma(g([\mathbf{h}_{\text{traj}}, \mathbf{h}_{\text{meas}}, \phi(\mathbf{W}_{k+1})])), \\ \beta &\in (0, \beta_{\max}) \end{aligned} \quad (22)$$




图 5 门控校正模块

Fig. 5 Architecture of the gated correction module

其中， $g(\cdot)$ 为多层感知机， $\sigma(\cdot)$ 为Sigmoid函数， $\beta_{\max}$ 为取值上界，用于防止瞬时量测异常主导位移估计，实验中取 $\beta_{\max} = 2.0$ 。

量测引导的位移校正机制如下：

$$\begin{aligned} \mathbf{s}_{\text{upd}} &= \mathbf{s}_{\text{pred}} + \beta \cdot \mathbf{s}_{\text{meas}}, \\ \pi_{\text{upd}} &= \text{softmax}(\mathbf{s}_{\text{upd}}) \end{aligned} \quad (23)$$

$\mathbf{s}_{\text{pred}}$ 与 $\mathbf{s}_{\text{meas}}$ 均定义在离散候选位移空间 $\mathcal{D} = \{(\Delta x, \Delta y) | \Delta x, \Delta y \in [-R, R]\}$ 上，分别对应候选位移先验评分与观测评分。当信噪比较高时，局部邻域观测会呈现显著峰值， β 将取较大值；当信噪比较低时，邻域响应平坦或多峰， β 取较小值，模型更多依赖历史信息的位移估计项。

为实现候选转移集合的自适应生成，基于后验位移概率矩阵 π_{upd} 描述候选位移集合上的置信度，考虑到 π_{upd} 的集中或分散程度能够反映当前位移预测的不确定性，本文采用其归一化信息熵作为不确定性度量：

$$\hat{H}(\pi_{\text{upd}}) = \frac{-\sum_{c=1}^C \pi_c \log_2 \pi_c}{\log C} \in [0, 1] \quad (24)$$

其中， $\log_2 C$ 用于减小候选集合的变化对熵上界的影响。基于 $\hat{H}(\pi_{\text{upd}})$ 得到自适应候选集合大小：

$$M = \left\lceil M_{\min} + \hat{H}(\pi_{\text{upd}})(M_{\max} - M_{\min}) \right\rceil \quad (25)$$

实验中， $M_{\min} = 10, M_{\max} = 50$ ， $M_{\min}$ 保证高置信度时真实位移邻域不被遗漏， $M_{\max}$ 限制低置信度时候选数规模，确保DP递推效率。

因此，候选转移状态集合可表示为

$$\mathcal{S}_k = \text{TopM}(\pi_{\text{upd}}) \quad (26)$$

3.3 损失函数

MG-TGN的训练目标是在离散位移空间

$\mathcal{D} = [-R, R]^2$ 上学习可靠的位移概率矩阵。为保证更新的后验位移概率矩阵准确性与位移估计模块中预测位移的稳定性,采用软标签交叉熵作为监督。设位移空间的高斯软标签为 $\tilde{\pi}(\Delta)$,主损失函数式(27),约束模型学习目标真实位移。

$$\mathcal{L}_{\text{upd}} = - \sum_{\Delta \in \mathcal{D}} \tilde{\pi}(\Delta) \ln \pi_{\text{upd}}(\Delta) \quad (27)$$

加入位移估计分支的辅助损失:

$$\mathcal{L}_{\text{pred}} = - \sum_{\Delta \in \mathcal{D}} \tilde{\pi}(\Delta) \ln \pi_{\text{pred}}(\Delta) \quad (28)$$

通过该辅助损失,促使位移估计模块学习到更稳健的运动先验,输出合理的位移预测,并与后续门控校正机制形成互补。

训练总损失为

$$\mathcal{L} = \mathcal{L}_{\text{upd}} + \lambda \mathcal{L}_{\text{pred}} \quad (29)$$

其中 λ 为权重系数。模型既能依赖历史信息给出合理的位移预测,也能基于当前帧观测信息校正位移偏差,以提升DP-TBD推理过程的鲁棒性。

3.4 MG-TGN辅助的DP-TBD推理

设 $\mathbf{z}_{k+1}$ 为第 $k+1$ 帧的观测平面, $I_{k+1}(\mathbf{x}_{k+1})$ 为当前窗口值函数积累平面。传统DP-TBD在固定邻域中搜索最优状态前驱,而本文采用MG-TGN输出的候选集合 $\mathcal{S}_k$ 替代固定邻域的方式实现转移范围内的后向搜索策略:

$$\begin{aligned} I_{k+1}((x_{k+1}, y_{k+1})) \\ = \max_{\Delta \in \mathcal{S}_k} [I_k((x_{k+1}, y_{k+1}) - (\Delta x, \Delta y)) \\ + |z_{k+1}|] \end{aligned} \quad (30)$$

其中 Δ 为MG-TGN输出的候选位移向量。

在每个滑动窗迭代积累的末帧,根据式(8)判决确定目标存在性,并对最优状态进行回溯得到当前窗口内轨迹序列。将所有回溯的候选轨迹作为下一窗的历史轨迹先验,输入MG-TGN以生成新的候选位移集合。基于式(24)和(25)可自适应扩大候选集合可显著降低真实路径被提前过滤的风险。具体实现如算法1所示,图6展示了DP-TBD与所提方法的帧间状态转移。

经典DP-TBD为了保证机动目标不漏检,搜索范围会采用较大的转移窗口,因此状态递推需要在大量候选集合中进行枚举比较,计算开销快速增长。同时,当运动模型失配时,搜索窗口要么过窄造成漏检,要么过宽造成虚假路径增多。在MG-TGN中,量测信息用于估计离散位移域上的观测似然概率,并与历史预测结果融合,生成自适应候选转移集合,用于约束状态转移搜索范围。本文方法的核




图6 后向搜索的转移范围示例

Fig. 6 Illustration of transition range

算法1 MG-TGN辅助的DP-TBD推理流程

Alg. 1 Inference Pipeline of DP-TBD Using MG-TGN

1. 初始化值函数,利用宽门控DP递推和纯量测引导的MG-TGN实现首个窗口初始化,得到轨迹序列 $\hat{\mathbf{X}}_1: K$;
2. while $t + K - 1 \leq T$ do
3. 窗口 $W_t \leftarrow [t, t + K - 1]$
4. 在窗口内执行DP递推:
5. 基于 W_{t-1} 轨迹先验和量测信息及 $\mathbf{z}_t$
6. MG-TGN输出 π_{upd} , 构造候选转移集合 $\mathcal{S}_k$;
7. 根据公式(30), 针对 $\Delta \in \mathcal{S}_k$ 更新值函数;
8. 记录轨迹回溯指针;
9. 阈值判决, 轨迹回溯;
10. 下一滑窗迭代;
11. end while
12. 返回: 整条轨迹序列 $\hat{\mathbf{X}}_1: N$

心在于利用当前量测对DP-TBD的状态转移集合进行门控优化,而不是替代DP-TBD的递推判决机制。

4 仿真实验与分析

本节首先介绍数据集生成与评估指标,随后给出本文所提方法的模型与训练参数,并与其他检测算法进行对比,通过数值仿真展示机动目标的检测与跟踪结果。所有基于深度学习的对比算法均使用PyTorch框架,实验的硬件配置:第13代 Intel(R) Core(TM) i7-13700KF CPU处理器及NVIDIA GeForce RTX 4090 GPU显卡,内存24 G。

4.1 仿真数据集与评价指标

4.1.1 仿真数据集构建

根据第2节所描述的目标模型与量测模型,采

用运动学状态模型和复值量测平面合成的方式模拟雷达回波生成时序数据。为构造具有不同机动模式的目标运动样本,本文在数据生成阶段采用多模型运动轨迹生成方式。具体地,基于式(2)的通用状态转移方程,设 $\mathcal{F}_{m_k} = \{\mathbf{F}_{CV}, \mathbf{F}_{CA}, \mathbf{F}_{CT}\}$,分别对应于匀速(Constant Velocity, CV)、匀加速(Constant Acceleration, CA)以及协同转弯(Coordinated Turn, CT)模型的状态转移矩阵。目标在不同运动模型之间进行随机切换,从而形成包含不同机动强度的分段运动轨迹。

经过离散化后,每条样本对应一段长度为 $T = 30$ 的二维离散量测序列,单帧量测为 $H \times W$ 的复值平面,本文中采用 128×128 单元, $\Delta x = \Delta y = 20$ m,量测平面取幅度信息,用于后续MG-TGN训练与DP-TBD推理评估。仿真数据集中,目标回波的信噪比包含1~16 dB,不同信噪比下的原始量测数据如图7所示。

为了系统评估所提MG-TGN辅助DP-TBD框架在不同机动条件下的稳健性,本文在仿真数据生成阶段将机动目标建模划分为弱机动目标和强机动目标^[13,30],并对加速度、转弯率等加以约束,以实现机动强度可控的仿真数据生成,用于TBD框架下的验证和测试。具体地,机动参数设置包括:速度范围 $\|v_{\max}\|$,加速度上限 $\|a_{\max}\|$,转弯率上限 $\|\omega_{\max}\|$,以及模型切换概率 p_{turn} ,仿真实验中的具体设置如表1所示。其中,弱机动目标设置较小的运动参数约束,且模型切换概率小,保持较为单一的运动模型,具体的轨迹示意如图8所示。需要注意的是,表中的参数阈值用于本文仿真分组与对比分析,属于实验参数设置而非标准的机动性划分依据。

仿真数据集包含10000条不同信噪比下的独立序列样本用于训练,不同机动条件下的验证集和测试集各包含2000条。针对MG-TGN的监督训练与

DP-TBD的窗口化累积推理,序列进一步按长度为 K 的滑动窗口切分。

4.1.2 评价指标

根据文献[18],本文采用的评价指标包含:目标检测概率 P_d ,正确航迹检测概率 $P_{d-\text{track}}$,回溯轨迹的均方根位置误差RMSE。其中,目标检测概率表征每个窗口末帧估计的目标位置与真实目标位置匹配的概率;航迹检测概率表征每个窗口输出的轨迹序列与真实轨迹序列匹配的概率;仿真实验中允许的容差单元为 $r_{\text{tol}} = 2$;RMSE表征估计轨迹与真值轨迹的位置误差,取测试集中的均方根误差结果。

4.2 模型参数与训练策略

MG-TGN采用类Transformer Encoder-Decoder框架实现轨迹与量测引导的位移域估计,本节给出模型的网络配置与训练策略,其中关键超参数如表2所示,训练过程的优化器、学习率、与训练轮次等训练参数如表3所示。

采用端到端监督训练MG-TGN,以验证集指标作为主要收敛依据。优化器选用AdamW,批大小为32,初始学习率设为 5×10^{-4} ,权重衰减为 1×10^{-4} ,并通过梯度裁剪来提升训练稳定性。为避免过拟合并保证训练的有效性,采用验证集上的总损失不再下降作为训练收敛的判断依据:若损失函数连续10个epoch下降幅度低于 10^{-4} 则停止训练,同时设置最大训练轮数上限。

4.3 实验结果与分析

为评估所提网络的位移估计能力以及其在TBD框架下的轨迹回溯性能,本节可视化网络输出位移估计结果,并且在两类机动场景中分别统计了目标检测概率 P_d 、轨迹级检测概率 $P_{d-\text{track}}$ 以及回溯轨迹的定位误差RMSE,绘制其随SNR变化的性能曲线。实验中积累帧数 $K = 8$ 。




图7 输入数据:不同信噪比下的原始量测平面

Fig. 7 The raw measurement planes in different SNR conditions

表 1 不同机动条件下的目标运动参数

Tab. 1 Target motion parameters under different maneuvering conditions

参数	弱机动	强机动
速度约束 $\ v_{\max}\ $	100 m/s	400 m/s
加速度 $\ a_{\max}\ $	5 m/s ²	40 m/s ²
转弯率 $\ \omega_{\max}\ $	0.05 π	0.3 π
切换概率 p_{turn}	0.01	0.25

MG-TGN的输出为离散位移域上的概率矩阵,用于表征目标从上一帧位置到下一帧位置的转移不确定性。网络输出位移估计模块的预测位移概率 $\pi_{\text{pred}}(\Delta)$,量测引导模块的观测似然概率 $\pi_{\text{meas}}(\Delta)$,以及更新的后验位移概率 $\pi_{\text{upd}}(\Delta)$,分别对应图9中的可视化结果。最终位移估计结果在整个量测平面的可视化展示见图10。

如图9所示,在低SNR条件下,目标回波能量常常淹没在噪声中,导致当前帧观测信息不稳定,此时,量测引导模块输出的概率置信度低。经过门控校正模块,自适应门控因子会降低不可靠观测对更新的影响,使更新的概率更偏向于位移估计模块提供的约束,因此最终输出的 $\pi_{\text{upd}}(\Delta)$ 不会因瞬时量测异常而产生显著偏移,从而提升了位移估计的稳健性。当信噪比提高至10 dB时,量测引导模块输出的观测概率在真实位移附近,即使位移估计模块的预测位移存在偏差,门控校正模块仍能够有效利用当前帧观测进行校正,使更新后的位移概率向真实位移收敛。

为了验证所提MG-TGN辅助DP-TBD方法在不同机动条件下的有效性,实验按照4.1.1节构建弱机动与强机动两类典型场景,并在不同信噪比设置下进行对比实验。性能评价采用4.1.2节所描述的3种评估指标,对比方法选取KBC-TBD^[17], MD-

TBD^[18], LSTM-TBD^[28]及Trans-TBD^[29],既包含经典的TBD方法,也包括基于深度学习的TBD对比方法。为了更直观地对比不同方法的轨迹回溯效果,本节选取SNR=8 dB机动条件下的单条测试样本,给出了所提MG-TGN-TBD方法与经典TBD方法(KBC-TBD^[17])回溯得到的完整轨迹序列可视化结果,如图11所示。图12、图13、图14分别为4.1.2节所描述的3项评价指标曲线。

由图12可以看出,随着SNR增大,两种机动场景下TBD方法的检测概率均呈现稳定上升趋势,说明跨帧能量积累对弱目标检测具有普遍增益,且所提MG-TGN-TBD在两种场景下均取得较好的检测性能。

在弱机动场景下,SNR较高时各方法性能趋近,但在低SNR区间($\text{SNR} \leq 9\text{dB}$),KBC-TMD受限于固定转移范围,低SNR下能量扩散明显,检测概率最低;MD-TBD虽引入MD策略,但低SNR下量测点提取精度不足,性能提升有限。基于深度学习的TBD方法中,基于轨迹预测的LSTM-TBD与Trans-TBD的搜索范围在大多数情况下能够覆盖目标真实转移范围,即便存在轻微回溯偏差也不会导致级联误差显著增大,因此在该场景下两种方法性能接近。从整体来看本文所提MG-TGN-TBD在 $\text{SNR} = 8\text{dB}$ 时 P_d 较Trans-TBD提升约5%,轨迹检测概率下降更为平缓,从图14中可以看出,MG-TGN-TBD的定位误差也相对更小。

强机动场景下,目标具有更快的速度且存在更明显的转弯和加速度突变,导致目标帧间位移增大、运动不确定性增强。由图12、图13可见,相较于弱机动场景,所有方法的 $P_d, P_{d-\text{track}}$ 曲线整体向更高SNR区间偏移,不同方法间性能差距增大。在 $\text{SNR} \leq 10\text{dB}$ 时,所提方法的性能优势显著。KBC-TBD方法由于目标强机动,转移范围设置可能无




图 8 不同机动条件下的目标运动轨迹示意图

Fig. 8 Target trajectories under different maneuvering conditions

表 2 MG-TGN关键网络参数
Tab. 2 The key parameters of MG-TGN

参数	数值
序列长度	8
轨迹编码器层数	4
量测编码器层数	4
解码器层数	4
特征维度	192
多头注意力头数	8
前馈神经网络维度	512
Dropout	0.1
位移预测头MLP层数	3
位移预测头隐藏维度	256

表 3 模型训练参数
Tab. 3 Model training parameters

参数	数值
优化器	AdamW
初始学习率	5×10^{-4}
学习率策略	余弦退火
权重衰减	1×10^{-4}
Batchsize	32
辅助损失权重	0.25

法覆盖真实位移，导致能量累积偏移、出现漏检，也会因更宽的转移范围引起噪声累积，导致检测性能恶化。MD-TBD因量测点估计受噪声干扰，无法准确估计强机动条件下的目标状态转移，检测概率显著下降。同样地，LSTM-TBD与Trans-TBD




图 9 MG-TGN位移概率矩阵

Fig. 9 Distribution of displacement estimation

在低SNR条件下也会大幅影响网络的判别能力，导致检测概率 P_d 、轨迹检测率 $P_{d-track}$ 降低且RMSE




图 10 MG-TGN位移估计结果

Fig. 10 Results of displacement estimation




图 11 轨迹回溯结果对比

Fig. 11 Visualization of trajectory backtracking result

较高。所提MG-TGN-TBD优势在该场景下进一步凸显，在 $\text{SNR} = 8 \text{ dB}$ 时 P_d 较Trans-TBD提升约28%，并在图14所示的RMSE指标上表现出更优的定位精度。

本文方法主要优势在于可以利用量测信息对轨迹信息实现转移范围的自适应门控校正。一方面，位移估计模块提供的 $\pi_{\text{pred}}(\Delta)$ 能够维持递推稳定性，避免完全由噪声主导；另一方面，量测引导模块输出的 $\pi_{\text{meas}}(\Delta)$ 能够对基于历史信息的预测偏差进行校正，使 $\pi_{\text{upd}}(\Delta)$ 向真实位移收敛。尤其在机动突变导致先验位移预测偏离的情况下，门控校正模块通过增强量测引导项，可将 $\pi_{\text{upd}}(\Delta)$ 拉回真实位移邻域，从而保证DP-TBD递推仍能覆盖真实转移路径。因此，本文方法在强机动场景下的优势突出，且在低SNR区间内由于门控更新机制，在检测和跟踪指标上均取得了更好的性能。

为进一步评估所提方法在相同测试条件下的计算效率，统计了不同方法处理单条样本序列的平均运行时间，结果如表4所示。

其中，KBC-TBD的运行时间最长，其需要设置较大的转移窗口以覆盖强机动目标，候选状态数量最多，DP递推中逐候选位移进行值函数更新的




图 12 不同机动场景下的目标检测概率曲线


Fig. 12 curves of P_d under different maneuvering scenarios

图 13 不同机动场景下的轨迹检测概率曲线

Fig. 13 curves of $P_{d-\text{track}}$ under different maneuvering scenarios




图 14 不同机动场景下的RMSE曲线

Fig. 14 curves of RMSE under different maneuvering scenario

表 4 平均运行时间对比

Tab. 4 Comparison of average execution times

方法	平均运行时间(ms)
KBC-TBD	759.1
MD-TBD	595.5
LSTM-TBD	383.4
Trans-TBD	407.5
MG-TGN-TBD	342.3

计算开销随候选状态数线性增长。本文所提MG-TGN-TBD在对比方法中运行时间较短，主要是MG-TGN通过后验位移概率矩阵确定候选集规模，较全核搜索减少了DP递推的状态枚举量，有效降低了计算开销。

为验证MG-TGN中位移估计模块和量测引导模块对跟踪性能的贡献，在相同测试集下进行了消融实验，结果如表5所示。其中，仅位移估计指移除量测引导模块，仅依赖输出的先验位移预测生成候选集；仅量测引导指移除位移估计模块，仅依赖输出的观测似然位移预测生成候选集。

从表5可见，任一模块的移除均会导致检测概率下降。量测引导模块的独立性能弱于位移估计模块，这表明仅依赖当前帧局部窗口的幅值响应，缺乏历史轨迹与历史量测空间的时序约束，在低SNR下易受噪声干扰。然而，完整模型相比仅保留位移估计模块仍有提升，说明量测引导提供的空间响应具有一定有效性，二者互补，经门控融合后可以实现较为可靠的位移估计。

4.4 计算复杂度分析

本文所提算法的计算复杂度主要由MG-TGN引入的推理复杂度和DP-TBD递推积累的复杂度构

表 5 消融实验结果

Tab. 5 Results of ablation experiment

模型变体	位移估计	量测引导	P_d
完整MG-TGN	✓	✓	0.837
w/o 位移估计	✓	×	0.743
w/o 量测引导	×	✓	0.512

成。对于MG-TGN的推理复杂度，其计算开销主要来源于Transformer注意力与前馈神经网络的运算，假设轨迹分支token数为 L ，量测分支的token数为 N_e ，特征维度为 d ，Transformer编解码器层数简记 L_n 。因此，MG-TGN单次推理时的主要计算复杂度可表示为： $\mathcal{O}(L_n(L^2d + N_e^2d)) + \mathcal{O}(Cd)$ ，其中第1项为注意力计算，第2项是计算位移概率矩阵的开销。对于DP-TBD递推积累的复杂度，其计算开销主要源于DP迭代的帧数 K 和转移集合数 M ，假设量测平面的网格数为 N_{hw} ，则DP-TBD的计算复杂度可表示为： $\mathcal{O}(K \cdot N_{hw} \cdot M)$ 。因此本文算法完成一次窗口内前向推理的总体复杂度可记为 $\mathcal{O}(K(L_n(L^2d + N_e^2d)) + \mathcal{O}(Cd) + \mathcal{O}(K \cdot N_{hw} \cdot M))$ 。

与经典DP-TBD相比，本文方法额外引入了MG-TGN的推理开销，但本算法通过优化转移范围，显著缩小了DP递推的有效转移范围，降低了DP-TBD计算量。当量测平面 N_{hw} 较大时或需要较大机动范围的场景下，DP递推通常占据主要开销，此时本文方法的复杂度优势相对明显，且能够在保证对强机动真实转移范围覆盖的同时抑制噪声引起的状态扩散。

5 结语

本文面向机动环境下的雷达弱目标检测前跟踪问题，提出了一种基于Transformer架构优化转移

范围的TBD方法。所提方法继承TBD方法中的预测思想,并创新性地引入原始量测信息,在离散位移域上构建量测引导的转移门控网络MG-TGN,以数据驱动方式学习状态转移的不确定性,将输出结果其作为DP递推的候选转移集合,实现对搜索范围的自适应优化并有效抑制噪声扩散。MG-TGN同时输出位移估计得到的先验预测位移概率、由当前量测生成的观测概率以及融合更新后的后验概率,通过门控校正机制实现自适应的信息融合。通过对比实验得到,所提方法在低SNR区间和强机动场景下可以有效提升目标的检测跟踪性能。

利益冲突 所有作者均声明不存在利益冲突

Conflict of Interests The authors declare that there is no conflict of interests

参 考 文 献

- [1] JALIL A, YOUSAF H, and BAIG M I. Analysis of CFAR techniques[C]. The 13th International Bhurban Conference on Applied Sciences and Technology (IBCAST), Islamabad, Pakistan, 2016: 654–659. doi: [10.1109/IBCAST.2016.7429949](https://doi.org/10.1109/IBCAST.2016.7429949).
- [2] BARNIV Y. Dynamic programming solution for detecting dim moving targets[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1985, AES-21(1): 144–156. doi: [10.1109/TAES.1985.310548](https://doi.org/10.1109/TAES.1985.310548).
- [3] BOCQUEL M, DRIESSEN H, and BAGCHI A. Multitarget particle filter addressing ambiguous radar data in TBD[C]. 2012 IEEE Radar Conference, Atlanta, USA, 2012: 575–580. doi: [10.1109/RADAR.2012.6212206](https://doi.org/10.1109/RADAR.2012.6212206).
- [4] GARCIA F J I, MANDAL P K, BOCQUEL M, *et al.* Riemann–Langevin particle filtering in track-before-detect[J]. *IEEE Signal Processing Letters*, 2018, 25(7): 1039–1043.
- [5] LI Yuefeng, ZHANG Xiangyu, WANG Guohong, *et al.* A novel HT-TBD detection approach for near-space target[C]. The 3rd IEEE International Conference on Computer and Communications (ICCC), Chengdu, China, 2017: 1720–1724. doi: [10.1109/CompComm.2017.8322834](https://doi.org/10.1109/CompComm.2017.8322834).
- [6] YI Wei, KONG Lingjiang, YANG Jianyu, *et al.* A modified dynamic programming approach for dim target detection and tracking[C]. The 2nd International Congress on Image and Signal Processing, Tianjin, China, 2009: 1–5. doi: [10.1109/CISP.2009.5300953](https://doi.org/10.1109/CISP.2009.5300953).
- [7] 易伟. 基于检测前跟踪技术的多目标跟踪算法研究[D]. [博士学位论文], 电子科技大学, 2012.
YI Wei. Research on track-before-detect algorithms for multiple-target detection and tracking[D]. [Ph.D. dissertation], University of Electronic Science and Technology of China, 2012.
- [8] YI Wei, MORELANDE M R, KONG Lingjiang, *et al.* An efficient multi-frame track-before-detect algorithm for multi-target tracking[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2013, 7(3): 421–434. doi: [10.1109/JSTSP.2013.2256415](https://doi.org/10.1109/JSTSP.2013.2256415).
- [9] 方梓成. 多帧联合检测与跟踪技术研究[D]. [硕士学位论文], 电子科技大学, 2017.
FANG Zicheng. Research on multi-frame detection and tracking technique[D]. [Master dissertation], University of Electronic Science and Technology of China, 2017.
- [10] 陆晓莹. 基于动态规划的雷达弱目标检测前跟踪算法研究[D]. [博士学位论文], 电子科技大学, 2023. doi: [10.27005/d.cnki.gdztu.2023.005491](https://doi.org/10.27005/d.cnki.gdztu.2023.005491).
LU Xiaoying. Research on track-before-detect algorithm based on dynamic programming for weak target with radar[D]. [Ph.D. dissertation], University of Electronic Science and Technology of China, 2023. doi: [10.27005/d.cnki.gdztu.2023.005491](https://doi.org/10.27005/d.cnki.gdztu.2023.005491).
- [11] CAI Jiong, WANG Rui, LI Muyang, *et al.* An efficient threshold determination algorithm for DP-TBD based on structural analogy and saddle-point approximation[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2023, 59(6): 8263–8281. doi: [10.1109/TAES.2023.3301458](https://doi.org/10.1109/TAES.2023.3301458).
- [12] LI Wujun, YI Wei, TEH K C, *et al.* Radar multiframe detection in a complicated multitarget environment[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5107516. doi: [10.1109/TGRS.2023.3298040](https://doi.org/10.1109/TGRS.2023.3298040).
- [13] LI X R and JILKOV V P. Survey of maneuvering target tracking. Part I. Dynamic models[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2003, 39(4): 1333–1364. doi: [10.1109/TAES.2003.1261132](https://doi.org/10.1109/TAES.2003.1261132).
- [14] LI Xinzhe, WANG Shouyong, and ZHENG Daikun. A DP-TBD algorithm with adaptive state transition set for maneuvering targets[C]. 2016 CIE International Conference on Radar (RADAR), Guangzhou, China, 2016: 1–4. doi: [10.1109/RADAR.2016.8059476](https://doi.org/10.1109/RADAR.2016.8059476).
- [15] FANG Zicheng, YI Wei, KONG Lingjiang, *et al.* A multi-frame track-before-detect algorithm for maneuvering targets in radar system[C]. 2016 IEEE Radar Conference (RadarConf), Philadelphia, USA, 2016: 1–6.
- [16] GROSSI E, LOPS M, and VENTURINO L. A novel dynamic programming algorithm for track-before-detect in radar systems[J]. *IEEE Transactions on Signal Processing*, 2013, 61(10): 2608–2619. doi: [10.1109/TSP.2013.2251338](https://doi.org/10.1109/TSP.2013.2251338).
- [17] GROSSI E, LOPS M, and VENTURINO L. Track-before-detect for multiframe detection with censored observations[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2014, 50(3): 2032–2046. doi: [10.1109/TAES.2013.130148](https://doi.org/10.1109/TAES.2013.130148).

- [18] YI Wei, FANG Zicheng, LI Wujun, *et al.* Multi-frame track-before-detect algorithm for maneuvering target tracking[J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(4): 4104–4118. doi: [10.1109/TVT.2020.2976095](https://doi.org/10.1109/TVT.2020.2976095).
- [19] ZHENG Daikun, WANG Shouyong, and MENG Qingwen. Dynamic programming track-before-detect algorithm for radar target detection based on polynomial time series prediction[J]. *IET Radar, Sonar & Navigation*, 2016, 10(8): 1327–1336.
- [20] ZHENG Daikun, XU Hong, and ZHOU Chang. Maneuvering target joint detection and tracking using multi-frame integration[C]. 2019 International Conference on Control, Automation and Information Sciences, Chengdu, China, 2019: 1–6. doi: [10.1109/ICCAIS46528.2019.9074565](https://doi.org/10.1109/ICCAIS46528.2019.9074565).
- [21] XIONG Yan, PENG Jiaxiong, DING Mingyue, *et al.* An extended track-before-detect algorithm for infrared target detection[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1997, 33(3): 1087–1092. doi: [10.1109/7.599339](https://doi.org/10.1109/7.599339).
- [22] WANG Yizhou, JIANG Zhongyu, LI Yudong, *et al.* RODNet: A real-time radar object detection network cross-supervised by camera-radar fused object 3D localization[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2021, 15(4): 954–967. doi: [10.1109/JSTSP.2021.3058895](https://doi.org/10.1109/JSTSP.2021.3058895).
- [23] DECOURT C, VANRULLEN R, SALLE D, *et al.* DAROD: A deep automotive radar object detector on range-Doppler maps[C]. 2022 IEEE Intelligent Vehicles Symposium (IV), Aachen, Germany, 2022: 112–118. doi: [10.1109/IV51971.2022.9827281](https://doi.org/10.1109/IV51971.2022.9827281).
- [24] WU Yuanhang, ZHANG Chenyu, LIN Yiru, *et al.* CV-SAGAN: Complex-valued self-attention GAN on radar clutter suppression and target detection[C]. 2023 IEEE Radar Conference (RadarConf23), San Antonio, USA, 2023: 1–6. doi: [10.1109/RadarConf2351548.2023.10149701](https://doi.org/10.1109/RadarConf2351548.2023.10149701).
- [25] YATAKA R, CARDACE A, WANG Pu, *et al.* RETR: Multi-view radar detection transformer for indoor perception[C]. The 38th International Conference on Neural Information Processing Systems, Vancouver, Canada, 2024: 625.
- [26] DECOURT C, VANRULLEN R, SALLE D, *et al.* A recurrent CNN for online object detection on raw radar frames[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2024, 25(10): 13432–13441. doi: [10.1109/TITS.2024.3404076](https://doi.org/10.1109/TITS.2024.3404076).
- [27] ZHU Chuan, DENG Jie, LONG Xingyue, *et al.* DBU-Net based robust target detection for multi-frame track-before-detect method[C]. The 11th International Conference on Control, Automation and Information Sciences (ICCAIS), Hanoi, Vietnam, 2022: 412–418. doi: [10.1109/ICCAIS56082.2022.9990429](https://doi.org/10.1109/ICCAIS56082.2022.9990429).
- [28] SONG Fei, LI Yong, CHENG Wei, *et al.* An improved dynamic programming tracking-before-detection algorithm based on LSTM network[J]. *EURASIP Journal on Advances in Signal Processing*, 2023, 2023(1): 57. doi: [10.1186/s13634-023-01020-3](https://doi.org/10.1186/s13634-023-01020-3).
- [29] MOU Pan, MIAO Qing, ZHU Chuan, *et al.* Transformer architecture based multi-frame TBD algorithms for maneuvering targets[C]. The 12th International Conference on Control, Automation and Information Sciences (ICCAIS), Hanoi, Vietnam, 2023: 224–229. doi: [10.1109/ICCAIS59597.2023.10382246](https://doi.org/10.1109/ICCAIS59597.2023.10382246).
- [30] LEI Meng, WANG Yipeng, and ZHANG Ying. Highly maneuverable target recognition via contrastive-based time-frequency domain dynamic fusion[C]. IGARSS 2024 - 2024 IEEE International Geoscience and Remote Sensing Symposium, Athens, Greece, 2024: 9222–9226. doi: [10.1109/IGARSS53475.2024.10640849](https://doi.org/10.1109/IGARSS53475.2024.10640849).

作者简介

张顺生，研究员，主要研究方向为新体制雷达探测与成像、人工智能技术在雷达、电子战中的应用等。

刘晓凯，硕士生，主要研究方向为基于深度学习的雷达目标检测，检测前跟踪。

陈垣光，硕士生，主要研究方向为基于深度学习的雷达目标检测。

(责任编辑：于青)