

基于Transformer复杂运动辨识的机动星凸形扩展目标跟踪方法

陈辉^{*①} 边斌超^{*①} 连峰^② 韩崇昭^②

^①(兰州理工大学电气工程与信息工程学院 兰州 730050)

^②(西安交通大学自动化科学与工程学院 西安 710049)

摘要: 针对复杂的机动扩展目标跟踪问题, 利用Transformer网络设计了一种有效的星凸不规则形状机动扩展目标跟踪方法。首先, 该文研究利用alpha-shape算法建立了星凸形状的变化模型, 实现了静态场景下的星凸形扩展目标的形状估计。然后, 通过对目标状态转移矩阵进行重新设计, 结合Transformer网络对机动扩展目标运动状态转移矩阵进行实时估计, 实现了对复杂机动目标运动过程的精准跟踪。进一步地, 将估计得到的形状轮廓与运动状态进行融合, 最终实现了对星凸形机动扩展目标的实时跟踪。最后, 通过构造复杂的机动扩展目标跟踪场景, 利用多重性能指标测试算法对形状和运动状态的综合估计性能, 验证了算法的有效性。

关键词: 扩展目标跟踪; 机动目标; Transformer; 星凸形; 弗雷歇距离-面积误差

中图分类号: TP389.1

文献标识码: A

文章编号: 2095-283X(2024)03-0629-17

DOI: 10.12000/JR24031

引用格式: 陈辉, 边斌超, 连峰, 等. 基于Transformer复杂运动辨识的机动星凸形扩展目标跟踪方法[J]. 雷达学报(中英文), 2024, 13(3): 629-645. doi: 10.12000/JR24031.

Reference format: CHEN Hui, BIAN Binchao, LIAN Feng, *et al.* A novel method for tracking complex maneuvering star convex extended targets using transformer network[J]. *Journal of Radars*, 2024, 13(3): 629-645. doi: 10.12000/JR24031.

A Novel Method for Tracking Complex Maneuvering Star Convex Extended Targets Using Transformer Network

CHEN Hui^{*①} BIAN Binchao^{*①} LIAN Feng^② HAN Chongzhao^②

^①(School of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

^②(School of Automation Science and Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To address the challenges in tracking complex maneuvering extended targets, an effective maneuvering extended target tracking method was proposed for irregularly shaped star-convex using a Transformer network. Initially, the alpha-shape algorithm was used to model the variations in the star-convex shape. In addition, a recursive approach was proposed to estimate the irregular shape of an extended target by detailed derivation in the Bayesian filtering framework. This approach accurately estimated the shape of a static star convex extended target. Moreover, through the structural redesign of the target state transition matrix and the real-time estimation of the maneuvering extended target's state transition matrix using a

收稿日期: 2024-02-29; 改回日期: 2024-04-10; 网络出版: 2024-05-10

*通信作者: 陈辉 chenh@lut.edu.cn; 边斌超 bianbinchao@lut.edu.cn

*Corresponding Authors: CHEN Hui, chenh@lut.edu.cn; BIAN Binchao, bianbinchao@lut.edu.cn

基金项目: 国家自然科学基金(62163023, 61873116, 62173266, 62366031), 甘肃省教育厅产业支撑计划项目(2021CYZC-02), 2023年甘肃省军民融合发展专项资金项目, 2024年甘肃省重点人才项目资助

Foundation Items: The National Natural Science Foundation of China (62163023, 61873116, 62173266, 62366031), The Industrial Support Project of Education Department of Gansu Province (2021CYZC-02), The Special Funds Project for Civil-Military Integration Development of Gansu Province in 2023, The Key Talent Project of Gansu Province in 2024

责任编辑: 李天成 Corresponding Editor: LI Tiancheng

©The Author(s) 2024. This is an open access article under the CC-BY 4.0 License

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

transformer network, the accurate tracking of complex maneuvering targets was achieved. Furthermore, the real-time tracking of star convex maneuvering extended targets was achieved by fusing the estimated shape contours with motion states. This study focused on constructing certain complex maneuvering extended target tracking scenarios to assess the performance of the proposed method and the comprehensive estimation capabilities of the algorithm considering both shapes and motion states using multiple performance indicators.

Key words: Extended target tracking; Maneuvering target; Transformer; Star-convex shape; Frechet distance-area error

1 引言

传统的雷达目标跟踪基于“点目标或者小目标”假设,然而随着电子技术的不断发展,高分辨传感器可以通过目标上的多个散射点获得多个量测值,多源量测信息的获取使得目标多特征信息的认知已成为可能,如轮廓、方向等扩展信息,此类问题即是当下雷达目标跟踪领域公认的难点和热点问题,即扩展目标跟踪(Extended Target Tracking, ETT)问题^[1-3]。而针对该问题,已经有一些颇具针对性的ETT方法相继出现,其中一类方法是将目标轮廓按跟踪估计服务的最终目的假设为基本几何形状,比如椭圆或者矩形等^[4-6],另一类方法为了深度辨识和分类目标而估计得到更加细节化且真实的目标轮廓信息,将目标不规则轮廓用函数曲线拟合或者多个基本形状拼接而表征^[7-10]。与此同时,现代目标的机动性能也在不断增强,当目标的运动形式发生突变而难以用稳定的模型去刻画时,目标跟踪性能便会急剧下降而导致目标失去跟踪,虽然多学者建立了机动目标的众多行之有效的跟踪方法,但是当跟踪机动扩展目标时,这些方法便无法有效应对含形状信息在内的多特征信息的有效估计。

受限于雷达的稀疏量测集,此时,将目标轮廓假设为椭圆或者矩形轮廓可以满足大多数需求。Koch^[11]和Feldmann等人^[12]利用随机矩阵来描述椭圆轮廓特征,并取得了不错的效果,Zhang等人^[6]基于文献^[13]所提出的扩展目标量测模型,将扩展目标形状描述为矩形,不同之处在于矩形的描述方式可以更好地描述目标所处地空间范围。除此之外,文献^[14]也同样将目标轮廓描述为矩形。但是,在对形状轮廓的估计精度要求更高的应用场景下,简单的几何轮廓便不能满足要求,因此众多学者开始探索更为复杂的量测源建模方法来从稀疏量测集中建立更加贴近目标的不规则形状表现形式。Lan等人^[15,16]基于随机矩阵的方法利用多个椭圆来逼近目标不规则形状,不过该方法还是受限于有限子椭圆对轮廓细节的描述能力。Baum等人^[8,9]创新提出了用于星凸形扩展目标跟踪的方法,即随机超曲面模型(Random Hypersurface Model, RHM),

该方法利用径向函数实现了星凸形扩展目标的形状建模,之后利用有限阶傅里叶级数展开的方式实现了星凸形扩展目标的形状估计。Wahlstrom等人^[17]在随机超曲面模型的基础上提出了高斯过程回归模型(Gaussian Process Regression, GPR),进一步提升了星凸形目标轮廓表征的自适应性和准确性。但是当扩展目标具有高机动特性时,这些方法往往不能在准确估计目标形状的同时准确估计扩展目标的运动状态。

人工智能技术的快速发展为机动扩展目标的跟踪提供了新的思路,利用高精度雷达量测数据和神经网络可以端对端实现机动扩展目标运动状态和形状的联合估计。目前针对机动目标的跟踪已经对应了相应的网络模型认知方法,相较于传统贝叶斯递推估计方法^[18-22],利用神经网络的方法可以更好地对机动目标的运动状态进行估计。Liu等人^[23]通过利用长短期记忆网络(Long and Short Term Memory networks, LSTM),对重新设计的状态转移矩阵进行实时估计,实现了对机动目标运动状态的估计,Song等人^[24]同样利用LSTM网络对状态转移矩阵和不确定噪声进行了实时估计,同样实现了对机动目标的跟踪。Gao等人^[25]和Yu等人^[26]将目标的运动状态观测值处理为多个时间序列,分别在循环神经网络的基础上设计了不同的网络模型,从而实现了点目标的实时跟踪,并且取得了不错的效果。不过这些网络模型只是对机动目标的运动状态进行了实时估计,不能对目标形状进行估计^[27-29]。鉴于此,有学者开始利用神经网络对扩展目标进行实时状态和简单形态的估计。Nezhadarya等人^[30]建立了一个名为BoxNet的神经网络模型,该模型以边框回归为基础,通过将观测到的二维点云数据描述为矩形轮廓,实现了对目标空间范围的估计。Steuernagel等人^[31]通过将扩展目标的量测转化为双通道图像,以卷积神经网络模型为基础,设计了可以估计目标形状和运动状态的网络模型。但是,这些仅存的方法不能实现复杂不规则形状的准确估计^[32],因此建立一个能深度识别目标不规则外形轮廓且更加高效的机动扩展目标跟踪方法显得极为重要。

本文的主要创新点是针对星凸形机动扩展目标跟踪提出了新的方法。利用alpha-shape算法在贝叶斯滤波模型的框架下详细推导得到了静态场景下的扩展目标形状估计方法。然后，通过对目标运动状态转移矩阵结构化的重新设计，结合Transformer网络模型实现了对状态转移矩阵参数的精准估计，并利用容积卡尔曼滤波器实现了对目标的实时跟踪。最后，通过将所估计的目标轮廓和运动状态进行融合实现了对星凸形机动扩展目标的精确跟踪。为了进一步表明本文所提算法的优越性，通过设计不同的仿真场景验证了算法的有效性与可行性，且与其他方法相比，本文所提算法表现出更好的性能。

2 系统模型

在扩展目标跟踪中，目标的运动状态可表示为： $\mathbf{x}_k = [m \ \dot{m} \ \ddot{m}]$ ， m, \dot{m}, \ddot{m} 依次表示的参数为位置、速度和加速度，因此建立目标的运动模型为

$$\mathbf{x}_k = (\mathbf{F}_k \otimes \mathbf{I}_d) \mathbf{x}_{k-1} + \mathbf{q}_k \quad (1)$$

其中， \mathbf{F}_k 为状态转移矩阵， \mathbf{I}_d 为空间维度， \mathbf{q}_k 是协方差为 Q_k 的高斯白噪声， \otimes 为克罗内积。

假设每个由目标产生的量测均是由散布在扩展目标表面上的量测源产生的，对于给定的 l 个量测源 $\mathbf{y}_{k,l}$ ，相应目标产生的量测 $\mathbf{z}_{k,l}$ 为

$$\mathbf{z}_{k,l} = \mathbf{y}_{k,l} + \mathbf{v}_{k,l} \quad (2)$$

其中， $\mathbf{y}_{k,l} = h_{k,l}(\mathbf{x}_k)$ 表示观测到的运动状态值， $\mathbf{v}_{k,l}$ 是协方差为 R_k 的高斯白噪声。

k 时刻的量测集

$$\mathbf{Z}_k = \{\mathbf{z}_{k,l}\}_{l=1}^{N_{z,k}} \quad (3)$$

在上述的系统模型中，量测点会出现在目标的表面及边界，如图1所示。

3 基于alpha-shape的目标轮廓估计方法

本节将针对星凸形目标轮廓进行估计，采用alpha-shape算法对目标轮廓进行提取。alpha-shape算法中首先需要定义一个合适大小的圆作为外围轮廓提取的基础条件，通过该圆不断的移动，获得当前时刻的目标轮廓形状^[33,34]。




图1 产生的目标量测点

Fig. 1 Generated target measurements

首先对于 k 时刻的量测集，计算其量测均值：

$$\bar{\mathbf{z}}_k = \frac{1}{l} \sum_{i=1}^l \mathbf{z}_{k,i} \quad (4)$$

此时，相对于坐标原点的量测集为

$$\tilde{\mathbf{Z}}_k = \{\tilde{\mathbf{z}}_{k,l}\} \quad (5)$$

其中， $\tilde{\mathbf{z}}_{k,l} = \mathbf{z}_{k,l} - \bar{\mathbf{z}}_k$ 。

之后利用alpha-shape算法得到当前时刻目标的大致轮廓点集为 \mathbf{C}_k ：

$$\mathbf{C}_k = \text{as}(a, \tilde{\mathbf{Z}}_k) \quad (6)$$

其中， $\text{as}(\cdot)$ 表示alpha-shape算法， a 表示算法中所选取的合适的圆半径。

选取合适的 a 值是算法发挥效能的关键，根据李世林等人^[35]的研究，可以采用平均K近邻距离(Average K-Nearest Neighbor, AKNN)作为外围圆的半径，但是考虑到在扩展目标跟踪过程中，在每个时刻会产生不同的量测，若是在每个时刻都计算其AKNN将会严重影响算法的运行速度，因此，只在得到第1个时刻的量测之后计算其AKNN值作为 a 值，则可以保证计算速度，其中AKNN的取值如下：

$$a = \text{AKNN} = \frac{1}{l} \sum_{i=1}^l \frac{1}{K} \sum_{j=1}^K d_{i,j} \quad (7)$$

其中， K 为所要采样的平均点的个数，计算如下：

$$K = \left\lceil \frac{1}{l} \left| \max(\mathbf{Z}_k) - \min(\mathbf{Z}_k) \right| \right\rceil \quad (8)$$

如图2所示，当选取到合适的外圆半径时将会得到贴近真实形状的轮廓。

在得到轮廓点集 \mathbf{C}_k 之后，需要对形状进行滤波优化，使得形状更加符合真实形状。在此之前先对轮廓点集进行有序处理：

$$\mathbf{Z}^k = \text{s}(\mathbf{C}_k) \quad (9)$$

其中， \mathbf{Z}^k 是 k 时刻形状信息， $\text{s}(\cdot)$ 是轮廓点集有序排列。

扩展目标跟踪中，目标的形状在一定时间内符合自回归过程，因此，可以将目标轮廓建立为自回归过程。在建立自回归模型之前，需要先确定模型的阶数，在此选定二阶自回归模型，相较于一阶自回归模型，二阶自回归模型可以更好地利用历史信息，从而更好地实现对形状的估计。

假设 k 时刻目标的真实形状为 \mathbf{X}_k ，真实形状均值为 $\bar{\mathbf{X}}_k$ ，二阶自回归模型如下：

$$\begin{aligned} \mathbf{X}_k - \bar{\mathbf{X}}_k \\ = A_2(\mathbf{X}_{k-2} - \bar{\mathbf{X}}_k) + A_1(\mathbf{X}_{k-1} - \bar{\mathbf{X}}_k) + \mathbf{w}_k \end{aligned} \quad (10)$$




图2 利用alpha-shape算法提取目标形状

Fig. 2 Target shape extraction using alpha-shape algorithm

更进一步, 做如下定义:

$$\mathcal{X}_k = \begin{bmatrix} \mathbf{X}_{k-1} \\ \mathbf{X}_k \end{bmatrix} \quad (11)$$

式(10)可以重写为

$$\mathcal{X}_k - \bar{\mathcal{X}}_k = \mathbf{A}(\mathcal{X}_{k-1} - \bar{\mathcal{X}}_k) + \mathbf{w}_k \quad (12)$$

其中,

$$\mathbf{A} = \begin{bmatrix} 0 & \mathbf{I} \\ \mathbf{A}_2 & \mathbf{A}_1 \end{bmatrix}, \bar{\mathcal{X}}_k = \begin{bmatrix} \bar{\mathbf{X}}_{1:k-1} \\ \bar{\mathbf{X}}_{1:k} \end{bmatrix}$$

$\bar{\mathcal{X}}_k$ 是目标形状均值, \mathbf{A}_2 和 \mathbf{A}_1 是二阶模型的权值, \mathbf{w}_k 是采样过程中对形状信息的干扰噪声, 为均值为0, 协方差为 \mathbf{W}_k 的高斯白噪声。

在此建模下, k 时刻的形状信息 \mathbf{Z}^k 即可看作如下:

$$\mathbf{Z}^k = \mathbf{H}(\mathcal{X}_k - \bar{\mathcal{X}}_k) + \mathbf{u}_k \quad (13)$$

其中, $\mathbf{H} = [\mathbf{0}, \mathbf{I}]$ 为观测矩阵, \mathbf{u}_k 为均值为0, 协方差为 \mathbf{U}_k 的高斯白噪声。

在实际应用中, $\bar{\mathcal{X}}_k$ 包含了 k 时刻之前的所有历史信息, 但这并不符合实际情况, 所以需要为历史平均形状 $\bar{\mathcal{X}}_k$ 设置迭代步长。根据式(7)的计算结果来得到迭代步长 Ite :

$$\text{Ite} = \lceil e^{\text{AKNN}} \rceil \quad (14)$$

在获得 k 时刻的目标轮廓信息之后, 对轮廓值进行滤波优化, 根据贝叶斯密度公式, 后验概率密度可以表示为一个先验概率密度和观测概率密度的乘积, 即

$$p(\mathcal{X}_k | \mathbf{Z}^k) \propto p(\mathbf{Z}^k | \mathcal{X}_k) p(\mathcal{X}_k) \quad (15)$$

扩展目标的形状估计, 是迭代计算后验概率密度 $p(\mathcal{X}_k | \mathbf{Z}^k)$, 通常由预测步和更新步来实现。

3.1 预测步

在更新形状信息之前, 通常由预测步先对形状信息进行预测, 即

$$p(\mathcal{X}_{k-1} | \mathbf{Z}^{k-1}) \rightarrow p(\mathcal{X}_k | \mathbf{Z}^{k-1}) \quad (16)$$

预测步的概率密度计算如下:

$$\begin{aligned} p(\mathcal{X}_k | \mathbf{Z}^{k-1}) \\ = \int p(\mathcal{X}_k | \mathcal{X}_{k-1}, \mathbf{Z}^{1:k-1}) p(\mathcal{X}_{k-1} | \mathbf{Z}^{1:k-1}) d(\mathcal{X}_{k-1}) \end{aligned} \quad (17)$$

在此, 根据贝叶斯滤波推导可以得到:

$$\mathcal{X}_k^- - \bar{\mathcal{X}}_k = \mathbf{A}(\mathcal{X}_{k-1}^- - \bar{\mathcal{X}}_k) \quad (18)$$

$$\mathbf{P}_k^- = \mathbf{A} \mathbf{P}_k \mathbf{A}^T + \mathbf{W}_k \mathbf{W}_k^T \quad (19)$$

3.2 更新步

得到 k 时刻的量测信息之后, 结合预测步的形状信息对当前时刻的形状进行优化, 即更新步:

$$p(\mathcal{X}_k | \mathbf{Z}^{k-1}) \rightarrow p(\mathcal{X}_k | \mathbf{Z}^k) \quad (20)$$

更新步的概率密度计算如下:

$$\begin{aligned} p(\mathcal{X}_k | \mathbf{Z}^k) \\ = \frac{p(\mathbf{Z}^k | \mathbf{Z}^{1:k-1}, \mathcal{X}_k) p(\mathcal{X}_k | \mathbf{Z}^{1:k-1})}{p(\mathbf{Z}^k | \mathbf{Z}^{1:k-1})} \end{aligned} \quad (21)$$

同样地, 在贝叶斯滤波推导下有

$$\mathbf{K}_k = \mathbf{P}_k^- \mathbf{H}^T (\mathbf{S}_k \mathbf{H} \mathbf{P}_k^- \mathbf{H}^T + \mathbf{I})^{-1} \quad (22)$$

$$\hat{\mathcal{X}}_k = \mathcal{X}_k^- + \mathbf{K}_k \mathbf{Z}^k \quad (23)$$

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{S}_k \mathbf{H}) \mathbf{P}_k^- \quad (24)$$

其中,

$$\mathbf{S}_k = \mathbf{H} \mathbf{P}_k^- + \mathbf{U}_k \quad (25)$$

3.3 静态验证

在完成机动目标跟踪研究之前, 在静态场景下测试上述算法对于扩展目标形状估计的适用性。

图3在静态场景下验证了从三角形到较为复杂的五角形的形状估计, 初始形状均设定为正方形,

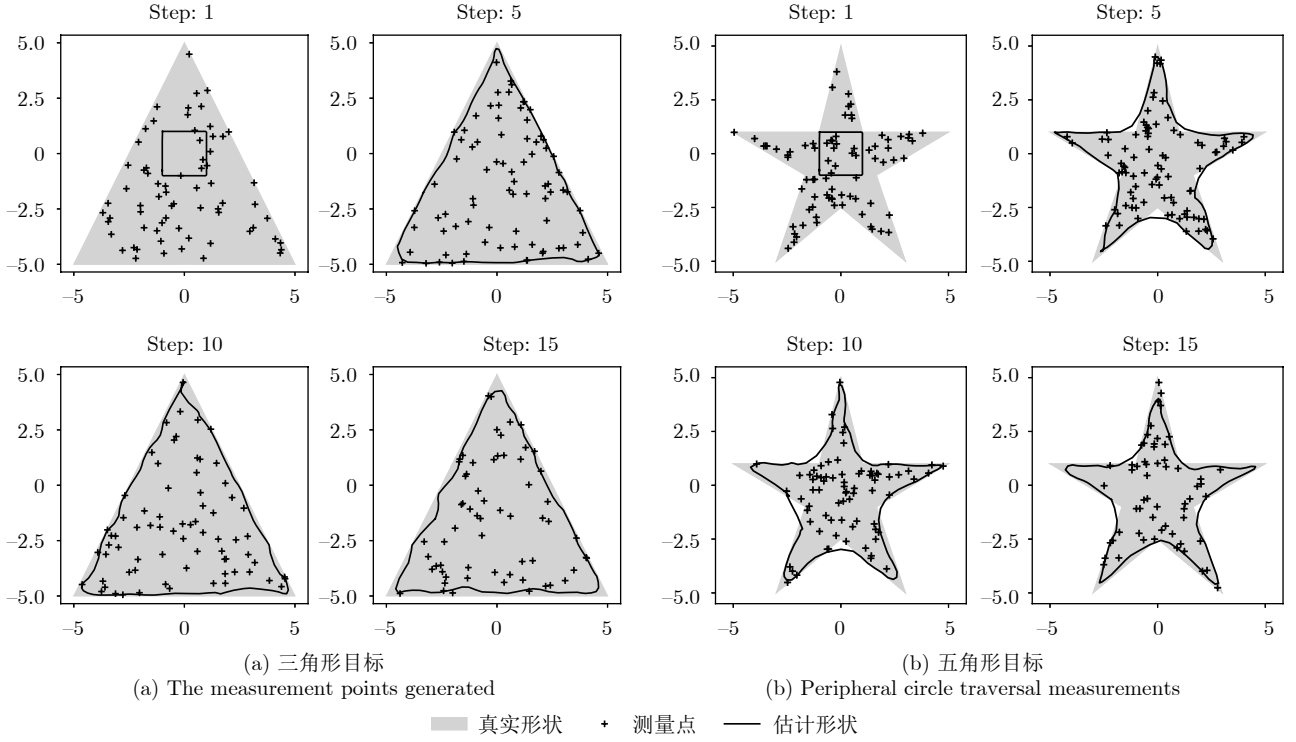


图3 静态场景下的轮廓估计

Fig. 3 Contour estimation in static scenes

经过测试，在3个采样周期内可以较为准确地估计到目标形状。接下来，将针对目标的运动特性进行跟踪，最终以完成对星凸形机动扩展目标的跟踪。

4 机动目标跟踪模型设计

目标在运动过程往往会呈现出复杂的机动特性，而最常见的运动模式有恒速运动模型、恒加速运动模型以及恒定转弯速率运动模型。

在二维平面内，恒速运动模型(Constant Velocity Model, CV)为

$$F_{CV} = \begin{bmatrix} 1 & 0 & \Delta t & 0 \\ 0 & 1 & 0 & \Delta t \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (26)$$

$$\mathbf{x} = [p_x \ p_y \ v_x \ v_y]^T \quad (27)$$

恒加速运动模型(Constant Acceleration Model, CA)为

$$F_{CA} = \begin{bmatrix} 1 & 0 & \Delta t & 0 & \frac{\Delta t^2}{2} & 0 \\ 0 & 1 & 0 & \Delta t & 0 & \frac{\Delta t^2}{2} \\ 0 & 0 & 1 & 0 & \Delta t & 0 \\ 0 & 0 & 0 & 1 & 0 & \Delta t \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (28)$$

$$\mathbf{x} = [p_x \ p_y \ v_x \ v_y \ a_x \ a_y]^T \quad (29)$$

恒转弯速率模型(Constant Turning Model, CT)为

$$F_{CT} = \begin{bmatrix} 1 & 0 & \frac{\sin \Omega_i \Delta t}{\Omega_i} & -\frac{1 - \cos \Omega_i \Delta t}{\Omega_i} \\ 0 & 1 & \frac{1 - \cos \Omega_i \Delta t}{\Omega_i} & \frac{\sin \Omega_i \Delta t}{\Omega_i} \\ 0 & 0 & \cos \Omega_i \Delta t & -\sin \Omega_i \Delta t \\ 0 & 0 & \sin \Omega_i \Delta t & \cos \Omega_i \Delta t \end{bmatrix} \quad (30)$$

$$\mathbf{x} = [p_x \ p_y \ v_x \ v_y]^T \quad (31)$$

从以上常见的3种模型中其实也不难发现，CT模型可以拟合常见的模型，通过对式(30)中第3列的数据进行合理的取值即可实现对任意轨迹的拟合。在此只使用目标的位置分量和速度分量对目标状态进行估计，因此，根据Liu等人^[23]的研究，可以将状态转移矩阵改写为

$$F = \begin{bmatrix} 1 & 0 & L & -M \\ 0 & 1 & M & L \\ 0 & 0 & N & -O \\ 0 & 0 & O & N \end{bmatrix} \quad (32)$$

此时，目标在k时刻的运动状态为

$$\mathbf{x}_k = [p_{x,k}, p_{y,k}, v_{x,k}, v_{y,k}]^T \quad (33)$$

由此，k时刻的运动状态分量值如下：

$$p_{x,k} = p_{x,k-1} + Lv_{x,k-1} - Mv_{y,k-1} \quad (34)$$

$$p_{y,k} = p_{y,k-1} + Mv_{x,k-1} + Lv_{y,k-1} \quad (35)$$

$$v_{x,k} = Nv_{x,k-1} - Ov_{y,k-1} \quad (36)$$

$$v_{y,k} = Ov_{x,k-1} + Nv_{y,k-1} \quad (37)$$

通过对 L, M, N, O 参数的估计可以实现对任意轨迹的拟合, 具体而言, 在二维平面内两个方向上的位移增量由 L, M 两个参数决定, 两个方向上的速度值由 N, O 两个参数决定。

接下来将详细阐述如何设计神经网络模型, 并将结合前述的形状估计部分完成星凸形机动扩展目标跟踪。

4.1 神经网络模型设计

首先, 整体的网络架构如图4所示。

该网络结构的输入信息是量测均值 \bar{z}_k , 一般是由二维坐标构成的, 因此首先经过二维卷积层实现量测信息的特征提取, 之后又经过一维卷积层实现对前层信息的二次提取, 在此提取的信息是按照维度进行的, 即分别对不同维度坐标信息进行提取, 最终在得到关于不同维度的特征信息之后, 为了更好的寻找不同维度坐标中所含有的信息, 对提取得到地特征信息进行编码处理。之后再经过全连接层实现对状态转移矩阵的状态估计。接下来将对各模块进行详细阐述。

(1) 特征信息提取

在扩展目标跟踪中, 量测信息中包含着大量的目标运动信息, 但是若直接对这些信息进行处理可能比较繁琐, 同时这些信息中存在较多的冗余信息。因此, 在对扩展目标的位置进行处理之前需要先对量测信息进行特征提取, 在众多神经网络模型中, 特征提取最有效的方法是卷积处理, 所以这一部分将以卷积处理为基础对量测信息进行特征提取^[36,37]。

对于卷积处理, 通常有如下定义:

$$h \cdot g(n) = \sum_{\tau=-\infty}^{+\infty} h(\tau)g(n - \tau) \quad (38)$$

而更进一步卷积处理过程可以写为

$$\begin{aligned} E(i, j) &= (\text{Ker} \cdot \text{In})(i, j) \\ &= \sum_m \sum_n \text{In}(i + m, j + n) \text{Ker}(m, n) \end{aligned} \quad (39)$$

其中, $E(i, j)$ 表示输出矩阵中 (i, j) 位置的元素, In 和 Ker 分别为输入矩阵和核矩阵, 核矩阵的形状为 $m \times n$ 。




图4 神经网络模型整体结构

Fig. 4 Overall structure of the neural network model

量测信息的特征信息提取是分别通过二维卷积和一维卷积实现的，其中二维卷积在二维量测信息上进行特征提取，即同时在坐标间进行卷积处理。一维卷积是在各维度上进行卷积处理，进一步提取同一维度之间的关系^[38]。两种卷积处理过程如图5和图6所示。

(2) 信息处理

在完成对各维度的特征信息提取之后，需要更进一步地寻找各维度之间的关联，因此，需要将特征信息进行位置编码以建立各维度之间的关系^[39,40]。

在实现位置编码时，将遵从以下原则：

1) 在每一个采样时刻，量测信息应当输出唯一的编码；

2) 编码的值应该是有界的，即不同批次的量测信息有相同范围的输出编码。

因此，对于任意时刻输入的量测信息，用 t 表

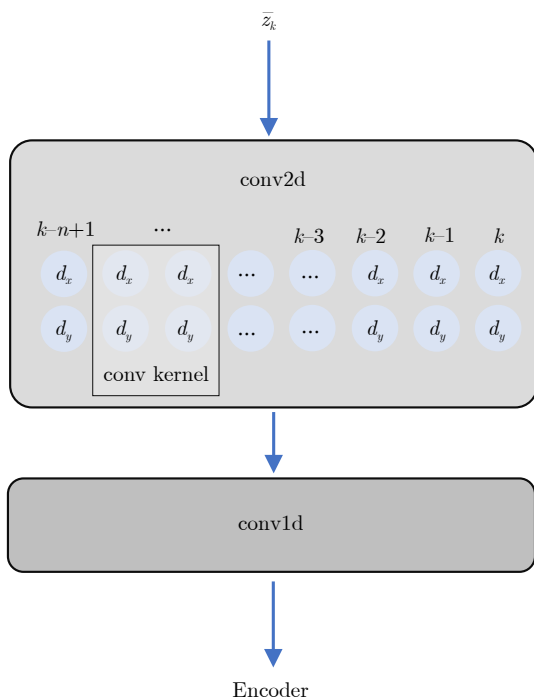


图5 一维特征信息提取

Fig. 5 1-D feature information extraction




图6 特征信息提取结构

Fig. 6 Feature information extraction structure

示当前量测信息在序列中的位置， p_t 表示位置 t 对应的向量， f_p 是生成向量 p_t 的函数，故

$$p_t^{(i)} = f_p(t)^{(i)} = \begin{cases} \sin(\omega_i \cdot t), & i = 2k \\ \cos(\omega_i \cdot t), & i = 2k + 1 \end{cases} \quad (40)$$

在将目标轨迹信息进行位置编码处理后，此时的轨迹序列成为含有位置信息的矩阵，并且矩阵中每一个位置在经过权值学习后会得到不同的参数，更进一步，为了更好地学习位置矩阵中所含有的隐藏信息，需要对位置矩阵进行解码处理。在此使用的解码层是Transformer结构中的Decoder层^[41-43]。

在经过前述几层网络模型的不断处理之后，最终需要对输出参数进行拟合，在此使用全连接层，全连接层的结构如图7所示，共有3层全连接层，最终输出 L, M, N, O 共4个值。

在全连接层中，每一层的输出经由前一层的权值和偏置决定，即

$$z_{fc} = W_{fc}x_{fc} + b_{fc} \quad (41)$$

其中， W_{fc} 为权值， b_{fc} 为偏置量。

(3) 网络训练

在模型训练过程中，所使用的损失函数均方差损失函数(Mean Square Error, MSE)是^[44]

$$MSE = \frac{1}{n} \sum_{i=1}^b (Y_i - \hat{Y}_i)^2 \quad (42)$$

其中， Y_i 为数据实际值， \hat{Y}_i 为网络模型估计值。训练过程中的损失值变化情况如图8所示。

神经网络模型的最终效果在一定程度上取决于模型训练。在本次的模型训练过程中，所使用的训练数据是模拟半径为10 km区域内所量测的数据。如图9所示，图中的轨迹即为目标的运动轨迹。

4.2 机动目标跟踪滤波器

在4.1节通过利用神经网络实现了对状态转移

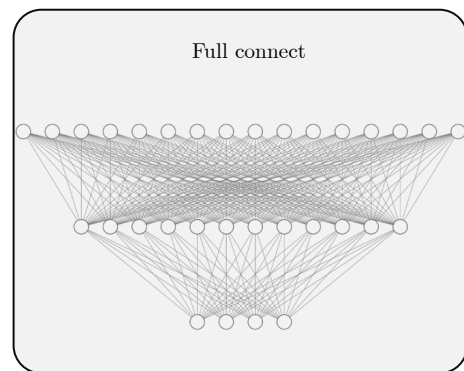


图7 全连接层结构

Fig. 7 Full connect layer




图8 训练过程中损失值变化情况

Fig. 8 Changes in loss values during training

矩阵的参数估计, 即式(28)中所涉及的参数计算, 之后则需要根据模型所估计的状态转移矩阵对机动目标的位置进行实时滤波和跟踪。

在前序部分中已经获得了每个时刻的状态转移矩阵 \mathbf{F}_k 以及目标的状态 \mathbf{z}_k , 在此称本文所设计的方法为基于Transformer的机动扩展目标跟踪方法 (Transformer For Maneuvering Extended Target Tracking, TFMETT), 其中:

$$\mathbf{F}_k = \text{TFMETT}(\mathbf{z}_k) \quad (43)$$

接下来通过结合容积卡尔曼滤波来实现状态估计。

(1) 预测步:

计算容积点 χ_{k-1} :

$$\mathbf{S}_{k-1}^{\text{cap}} = \sqrt{\mathbf{P}_{k-1}^{\text{cap}}} \quad (44)$$

$$\chi_{k-1}^j = \hat{\mathbf{x}}_{k-1} + \mathbf{S}_{k-1}^{\text{cap}} \xi_j \quad (45)$$

其中, $j = 1, 2, \dots, m$ 。

容积点状态预测:

$$\chi_{k|k-1}^j = \mathbf{F}_k \chi_{k-1}^j \quad (46)$$

目标状态预测:

$$\mathbf{x}_{k|k-1} = \frac{1}{m} \sum_{j=1}^m \chi_{k|k-1}^j \quad (47)$$

预测协方差:

$$\mathbf{P}_{k|k-1}^{\text{cap}} = \frac{1}{m} \sum_{j=1}^m (\chi_{k|k-1}^j - \mathbf{x}_{k|k-1}) \cdot (\chi_{k|k-1}^j - \mathbf{x}_{k|k-1})^T + \mathbf{Q}_{k-1} \quad (48)$$

(2) 更新步

计算容积点:

$$\mathbf{S}_k^{\text{cap}} = \sqrt{\mathbf{P}_{k|k-1}^{\text{cap}}} \quad (49)$$

$$\chi_k^j = \mathbf{x}_{k|k-1} + \mathbf{S}_{k|k-1}^{\text{cap}} \xi_j \quad (50)$$

容积点量测预测:

$$\mathbf{Z}_{k|k-1}^j = \mathbf{H}_k^{\text{cap}} (\chi_k^j) \quad (51)$$

目标量测预测:

$$\mathbf{z}_{k|k-1} = \frac{1}{m} \sum_{j=1}^m \mathbf{Z}_{k|k-1}^j \quad (52)$$

量测协方差:

$$\mathbf{S}_k^{\text{cap}} = \frac{1}{m} \sum_{j=1}^m (\mathbf{Z}_{k|k-1}^j - \mathbf{z}_{k|k-1}) \cdot (\mathbf{Z}_{k|k-1}^j - \mathbf{z}_{k|k-1})^T + \mathbf{R}_k \quad (53)$$

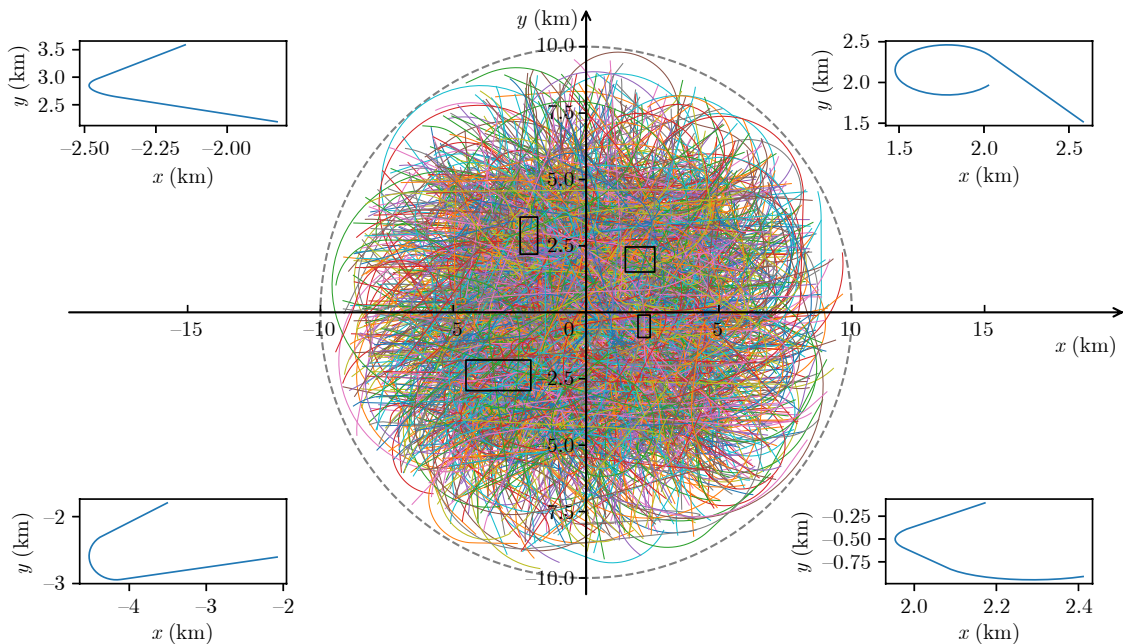


图9 网络模型训练所用的数据集

Fig. 9 Dataset used for network model training

状态量测协方差:

$$\mathbf{C}_k^{\text{cap}} = \frac{1}{m} \sum_{j=1}^m (\mathcal{X}_k^j - \mathbf{x}_{k|k-1})(\mathbf{Z}_{k|k-1}^j - \mathbf{z}_{k|k-1})^T \quad (54)$$

卡尔曼增益:

$$\mathbf{K}_k^{\text{cap}} = \mathbf{C}_k^{\text{cap}} (\mathbf{S}_k^{\text{cap}})^{-1} \quad (55)$$

(3) 估计

状态估计:

$$\hat{\mathbf{x}}_k = \mathbf{x}_{k|k-1} + \mathbf{K}_k^{\text{cap}} (\bar{\mathbf{z}}_k - \mathbf{z}_{k|k-1}) \quad (56)$$

协方差估计:

$$\mathbf{P}_k^{\text{cap}} = \mathbf{P}_{k|k-1}^{\text{cap}} - \mathbf{K}_k^{\text{cap}} \mathbf{S}_k^{\text{cap}} (\mathbf{K}_k^{\text{cap}})^T \quad (57)$$

TFMETT模型结合容积卡尔曼滤波最终实现了扩展目标的运动状态的估计。

4.3 机动扩展目标跟踪滤波器设计

经过前面部分的研究, 已经完成了扩展目标的形状估计和状态估计, 接下来对两部分进行有机融合以最终实现扩展目标的跟踪。

式(18)、式(19)、式(22)一式(24)完成了静态形状的预测和更新, 之后利用TFMETT模型实现了实时的状态转移矩阵的估计。接下来对静态形状和运动状态估计进行合理的结合以最终实现星凸形机动扩展目标跟踪。

(1) 预测步

式(18)、式(19)与式(44)一式(48)共同构成形态估计的预测步, 最终形态的预测即为

$$\mathcal{X}_{k,s}^- = \mathcal{X}_k^- + \mathbf{x}_{k|k-1} \quad (58)$$

(2) 更新步

式(22)、式(24)与式(49)一式(57)共同构成了形态估计的跟新步, 最终形态的更新即为

$$\hat{\mathcal{X}}_{k,s} = \hat{\mathcal{X}}_k + \hat{\mathbf{x}}_k \quad (59)$$

整体滤波器的设计如图10所示。

机动扩展目标跟踪方法的伪代码如算法1所示。

5 实验论证

本节将会对所设计的扩展目标跟踪算法(TFMETT)进行验证, 为进一步体现本文所提算法的有效性, 将选取随机超曲面模型(RHM)^[8]和高斯过程回归模型(GPR)^[17]对星凸形目标形状进行对比验证。

5.1 算法可行性测试

5.1.1 场景构建

在本场景下五角星目标在200个采样时刻分别在4个时间段内依次按照匀速转弯、匀速运动的运动模型交替进行, 目标尺寸范围为5 m×5 m, 在每个采样周期内产生的量测数量服从 $\lambda=50$ 的泊松分布, 采样时间在匀速转弯过程中为 $T=0.4$ s, 在匀速运动过程中为 $T=1.0$ s, 过程噪声为均值为0、方差为 $q=0.001$ 的高斯白噪声, 量测噪声为均值为0、方差为2.0的高斯白噪声。

目标的初始运动状态为

$$\mathbf{x}_0 = [p_{x,0}, p_{y,0}, v_{x,0}, v_{y,0}]^T = [0, 0, 10, 20]^T \quad (60)$$

目标在匀速转弯运动阶段, 过程噪声如下:

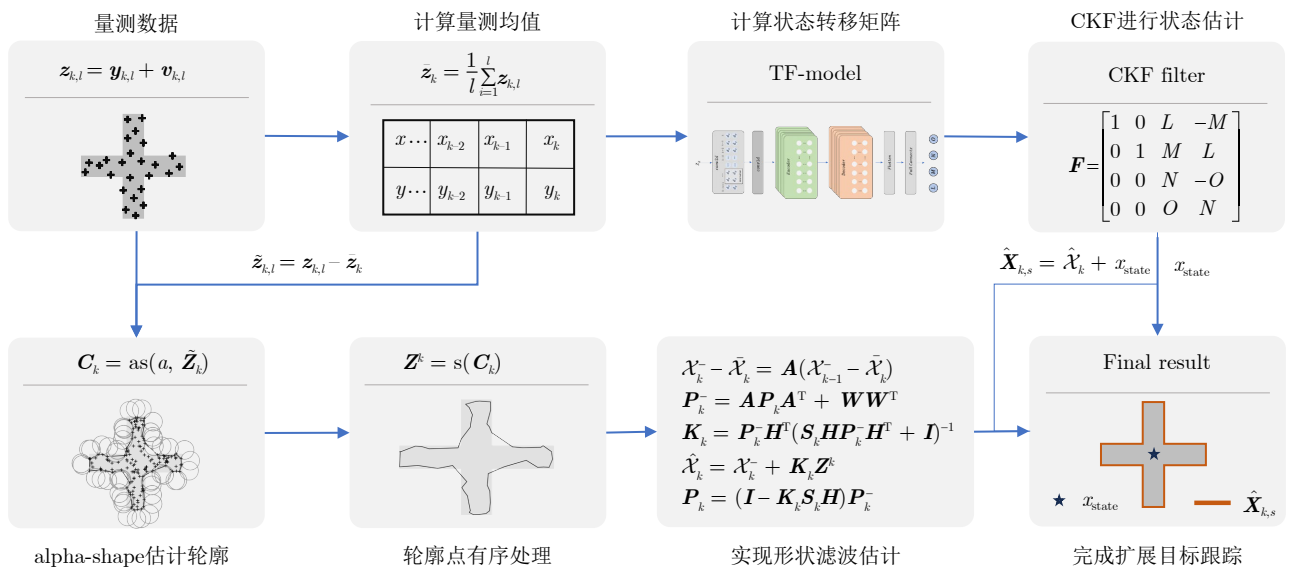


图 10 星凸形机动扩展目标跟踪方法

Fig. 10 Star convex maneuvering extended target tracking

算法 1 结合Transformer的星凸形机动扩展目标跟踪部分伪代码
Alg. 1 The pseudo-code of star convex maneuvering extended target tracking using Transformer algorithm

输入: $A_1, A_2, x_0, P_0, W_k, U_k, Q_k, R_k, P_0^{\text{cap}}$

步骤1: 预测

for $k = 1$: steps

% 量测集处理与形状初步处理

$$\bar{z}_k = \frac{1}{l} \sum_{i=1}^l z_{k,i}$$

$$\bar{Z}_k = \{\bar{z}_{k,i}\}$$

$$C_k = \text{as}(a, \bar{Z}_k)$$

$$Z^k = \text{s}(C_k)$$

% 静态形状预测

$$\mathcal{X}_k^- - \bar{\mathcal{X}}_k = \mathbf{A}(\mathcal{X}_{k-1}^- - \bar{\mathcal{X}}_k)$$

$$P_k^- = \mathbf{A}P_k \mathbf{A}^T + W_k W_k^T$$

% 运动状态预测

$$\hat{\mathcal{X}}_{k-1}^j = F_k^i \mathcal{X}_{k-1}^j$$

$$\mathbf{x}_{k|k-1} = \frac{1}{m} \sum_{j=1}^m \hat{\mathcal{X}}_{k-1}^j$$

% 形态预测

$$\mathcal{X}_{k,s}^- = \mathcal{X}_k^- + \mathbf{x}_{k|k-1}$$

end

步骤2: 更新

for $k = 1$: steps

% 静态形状更新

$$K_k = P_k^- \mathbf{H}^T (\mathbf{S}_k \mathbf{H} P_k^- \mathbf{H}^T + \mathbf{I})^{-1}$$

$$\hat{\mathcal{X}}_k = \mathcal{X}_k^- + K_k Z^k$$

$$P_k = (\mathbf{I} - K_k \mathbf{S}_k \mathbf{H}) P_k^-$$

% 状态转移矩阵更新

$$F_k = \text{TFMETT}(\bar{z}_k)$$

% 运动状态更新

$$\hat{\mathbf{x}}_k = \mathbf{x}_{k|k-1} + K_k^{\text{cap}} (\bar{z}_k - \mathbf{z}_{k|k-1})$$

$$P_k^{\text{cap}} = P_{k|k-1}^{\text{cap}} - K_k^{\text{cap}} \mathbf{S}_k^{\text{cap}} (K_k^{\text{cap}})^T$$

% 形态更新

$$\hat{\mathcal{X}}_{k,s} = \hat{\mathcal{X}}_k + \hat{\mathbf{x}}_k$$

end

输出: $\hat{\mathcal{X}}_{k,s}$

$$\mathbf{w}_k = \begin{bmatrix} qT^3/3 & qT^2/2 & 0 & 0 \\ qT^2/2 & qT & 0 & 0 \\ 0 & 0 & qT^3/3 & qT^2/2 \\ 0 & 0 & qT^2/2 & qT \end{bmatrix} \quad (61)$$

在匀速运动阶段, 过程噪声如下:

$$\mathbf{w}_k = \begin{bmatrix} qT^3/3 & 0 & qT^2/2 & 0 \\ 0 & qT^3/3 & 0 & qT^2/2 \\ qT^2/2 & 0 & T & 0 \\ 0 & qT^2/2 & 0 & T \end{bmatrix} \quad (62)$$

选用对比的方法RHM和GPR的尺度因子服从均值为0.5, 方差为0.002的高斯分布, 其中RHM形状先验参数为外接半径为3.8的圆形。TFMETT的参数设置为 $A_2=0.1$, $A_1=0.01$, $P_0=P_0^{\text{cap}}=100 \times \text{eye}(4)$, W_0 和 U_0 分别为

$$W_0 = \begin{bmatrix} 1 & 0 & 5 & -5 \\ 0 & 1 & -5 & 5 \end{bmatrix}, \quad U_0 = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

根据所设计的场景, 对TFMETT模型的跟踪效果进行测试, 同时与RHM和GPR进行了对比, 跟踪的效果如图11所示。

5.1.2 结果分析

图11展示了跟踪过程中的局部细节, 接下来对该场景下的跟踪效果进行进一步分析。

首先是算法形状估计的准确性分析, 扩展目标跟踪算法的首要条件是对形状的估计是否准确, 所以先对估计的形状进行误差分析, 在此计算不同算法的面积误差, 结果如图12所示。

在面积误差的对比中, 可以发现本文所提方法在形状估计方面好于其他两种方法, 因此, 估计方面, TFMETT算法可以更好地适用于形状估计。

在目标的运动过程中, 对目标的运动状态的估计同样至关重要, 因此需要对目标形状和运动状态的估计结果进行综合评价。此处采用交并比(Intersection Over Union, IOU)进行分析, 性能指标如图13所示。

更进一步地, 考虑到IOU在评价形状估计的同时对形状的敏感度并不高, 即估计形状并非接近真实形状, 但是重叠面积较大时也可能给出较好的评价结果。因此, 为更好地验证本文所提方法的有效性, 在此采用弗雷歇距离-面积误差(Frechet Distance Area error, FDA)评价指标。该指标实现了不规则形状之间的相似性评价, 实际形状 A 与估计形状 B 之间的相似度为^[45]

$$\omega_D = 0.7 \cdot \delta_D(A, B) + 0.3 \cdot \frac{\|B \Delta A\|}{\|A\|} \quad (63)$$

其中,

$$\delta_D(A, B) = \frac{\inf_{\alpha, \beta} \max_{t \in [0, 1]} \|A(\alpha(t)) - B(\beta(t))\|}{\sup_{\alpha, \beta} \max_{t \in [0, 1]} \|A(\alpha(t)) - B(\beta(t))\|} \quad (64)$$

式中, $\delta_D \in [0, 1]$ 是将弗雷歇距离 δ_D 标准化为 $[0, 1]$, 更方便对比曲线之间的相似程度。

采用弗雷歇距离-面积误差(FDA)对算法的可行性及性能进行分析评价, 结果如图14所示。

通过可行性实验的测试验证, 本文所提算法TFMETT能够对扩展目标的形状和状态进行估计,

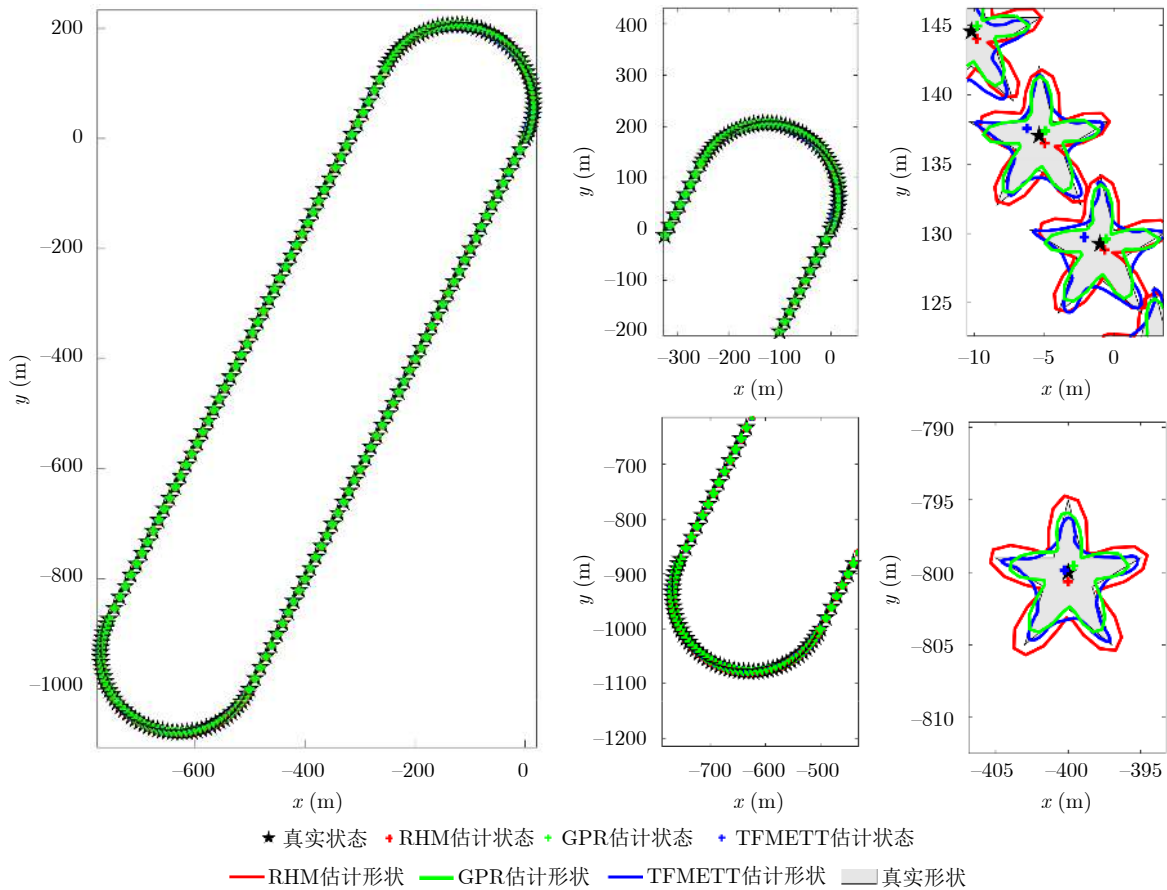


图 11 算法可行性测试

Fig. 11 Algorithm feasibility testing

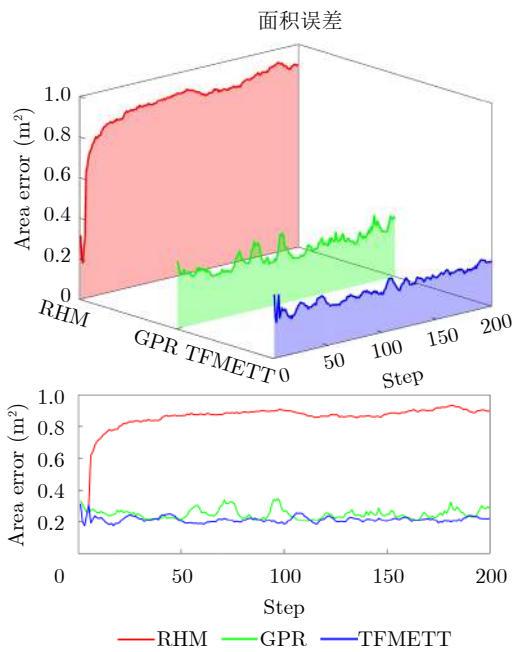


图 12 可行性测试的面积误差对比

Fig. 12 Comparison of area errors in feasibility tests




图 13 可行性测试的IOU对比

Fig. 13 Comparison of IOU in feasibility tests

并且其性能好于随机超曲面模型和高斯过程回归模型。而且在跟踪过程中通过使用神经网络模型可以

有效地对机动目标的状态转移矩阵进行估计，在目标运动模式和机动水平先验未知时，本文所提

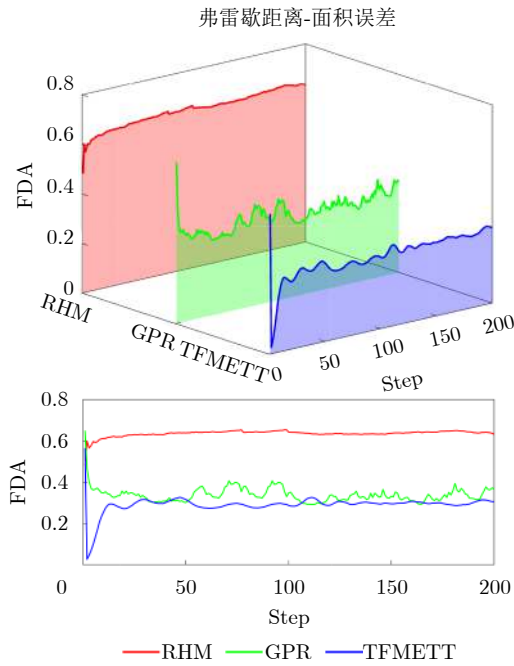


图 14 可行性测试中的FDA对比

Fig. 14 Comparison of FDA in feasibility tests

方法可以有效地解决这一问题，实现对机动目标的跟踪。

5.2 形状自适应性测试

5.2.1 场景构建

在本场景下目标在90个采样时刻中每30个采样时刻为一个运动模型，依次为匀速、匀转弯速率、匀速运动，目标形状依次为五角星、十字形以及三角形，在匀速运动过程中采样时刻为0.5 s，在匀转弯速率运动过程中采样时刻为1.0 s，在每个采样周期内产生的量测数量服从 $\lambda = 50$ 的泊松分布，其余参数设置同前所述。目标的初始运动状态为

$$\mathbf{x}_0 = [p_{x,0}, p_{y,0}, v_{x,0}, v_{y,0}]^T = [0, 0, 10, 10]^T \quad (65)$$

5.2.2 结果分析

在此场景下目标的算法的测试结果如图15所示。通过对比可以看出，本文所提方法TFMETT

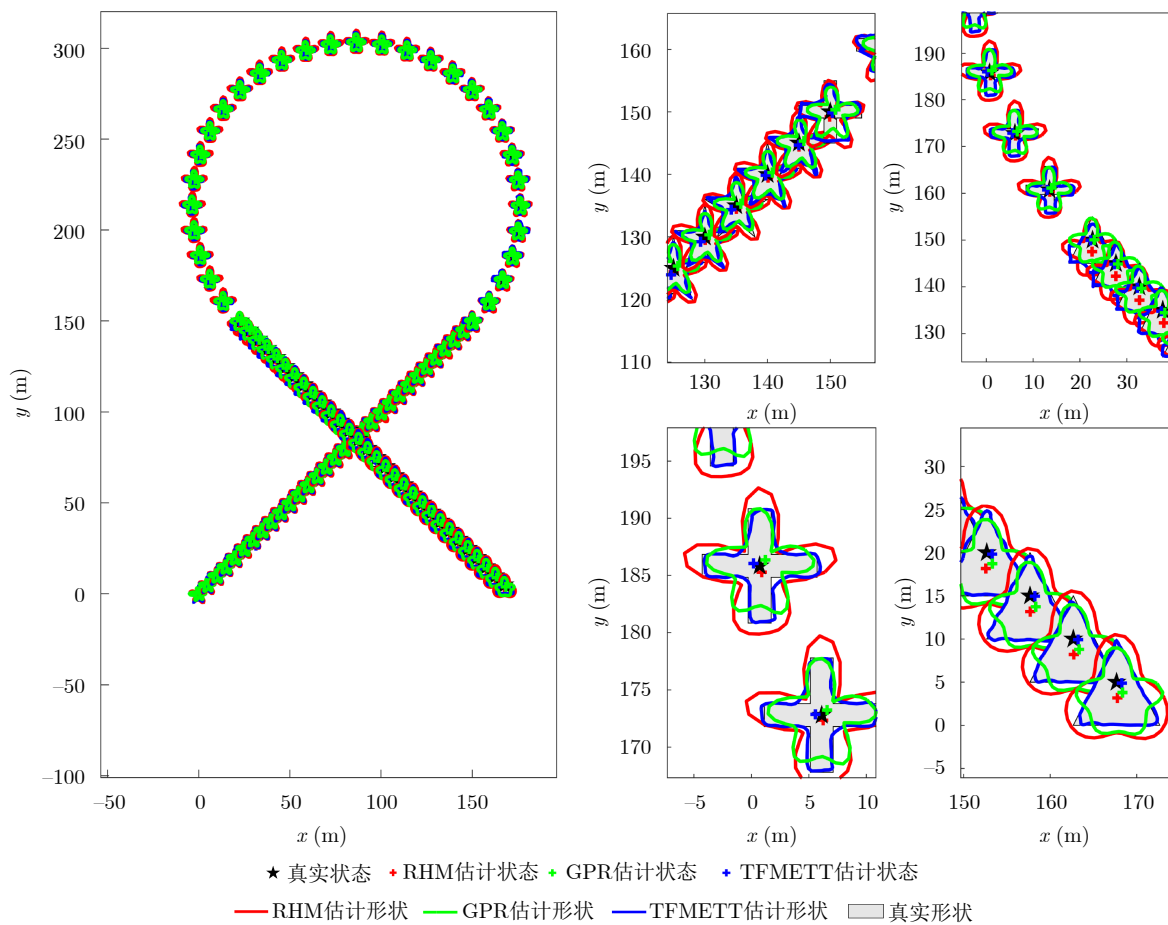


图 15 形状自适应性测试结果

Fig. 15 Shape adaptability test results

在整个目标运动过程中能够比较准确地估计出目标的轮廓，并且在目标形状发生变化后，也能在较短的时间步内实现对形状的自适应估计；随即超曲面模型和高斯过程回归模型因为需要预先对形状变化的尺度因子进行设置，在目标运动过程中，这两种算法对最先出现的五角星目标形状估计结果较好，但当目标形状发生变化之后，在没有对尺度因子的均值和协方差进行重新设置的情况下，对突变后的形状估计会出现较大误差；而本文所提算法，在形状突变后的一定时间步内可以有效地对变化形状作出自适应调整，估计效果较好。

进一步对各个算法在此场景下的性能指标进行参数化计算，各算法估计结果的面积误差，交并比以及弗雷歇距离-面积误差如图16-图18所示。

以上3个评价指标下，在第1~30个采样时刻，目标的形状为五角星，此时3种算法均可以估计出五角星的轮廓形状，因此无论是RHM, GPR还是本文所提出的TFMETT方法，都可以大致估计出五角星形状；在第31~60个采样时刻，此时目标的形状为十字形，因为目标的形状突然发生了变化，

在此情况下由于未对RHM和GPR中所使用的尺度因子的均值和协方差进行重新设定，导致RHM和GPR未能正确估计出目标的形状；当目标形状突变为三角形时也是同样的状况，但是本文所提的TFMETT算法在目标形状发生突变的情况下依然能够正确估计出目标形状，显示了本文算法在复杂跟踪环境下的鲁棒性和自适应性。

5.3 鲁棒性测试

5.3.1 场景构建

5.1节与5.2节分别验证了算法有效性和自适应性，而在实际情况中，算法可能会面对更为复杂的环境，因此鲁棒性也是一个算法的重要特性。在本小节中，将分别从运行时间，量测点的数量以及量测噪声上对本文所提算法进行测试。

在扩展目标跟踪领域中，算法的运行时间将会对跟踪效果产生较大影响，若算法的运行时间超过采样周期的时间，在跟踪过程中将会严重影响到后续任务的继续，因此算法的运行速度也是至关重要的特性，为此在场景一的条件，进行了50次蒙特卡罗仿真测试，程序运行在CPU为Intel(R) Core(TM) i5-8250U CPU@1.60 GHz 1.80 GHz, GPU为NVIDAN GeForce MX150的计算机上，单步运行时间结果如图19和表1所示。接下来是不同量测点数量和不同量测噪声下的测试。

首先是量测点数目对性能的影响，在此目标形状为五角形，目标范围设置为5 m×5 m，其中有所不同的是λ的取值，依次从20自增5到75，其余参数设置如同场景一。测试结果如图20(a)所示。

之后是量测噪声对性能的影响，在此过程中，目标形状为五角形，目标范围设置为5 m×5 m，噪声取值从0.5自增0.5到6.0，λ=35，其余参数设置如同场景一，测试结果如图20(b)所示。

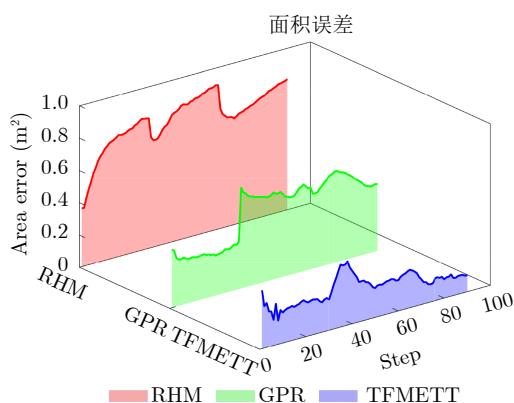


图 16 形状自适应性测试的面积误差对比

Fig. 16 Comparison of area errors for the shape adaptation tests

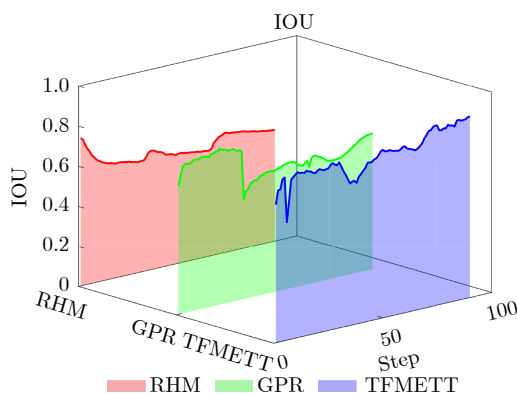


图 17 形状自适应性测试的IOU对比

Fig. 17 IOU comparison for shape adaptation tests




图 18 形状自适应性测试的FDA对比

Fig. 18 FDA comparison for shape adaptation tests




图 19 不同算法的单步运行时间对比

Fig. 19 Comparison of single-step running time for different algorithms

表 1 50次蒙特卡罗仿真测试中各种算法的平均单步运行时间

Tab. 1 Average single-step running time of various algorithms in 50 Monte Carlo simulation tests

算法	平均单步运行时间(s)
RHM	0.38
GPR	0.41
TFMETT	0.26

5.3.2 结果分析

在表1平均单步时间运行的测试中, 本文在所提算法是部分运行在GPU上, 相较于其他两种算

法, 运行时间较其他两种算法运行速度较快, 能够满足目标跟踪的需求。

在图20(a)中进行了12次不同取值的测试, 最终利用插值的方式将其绘制为平滑的曲线, 不难发现随着取值的增大, 量测点的密度增大, 各种算法的误差开始有所下降。

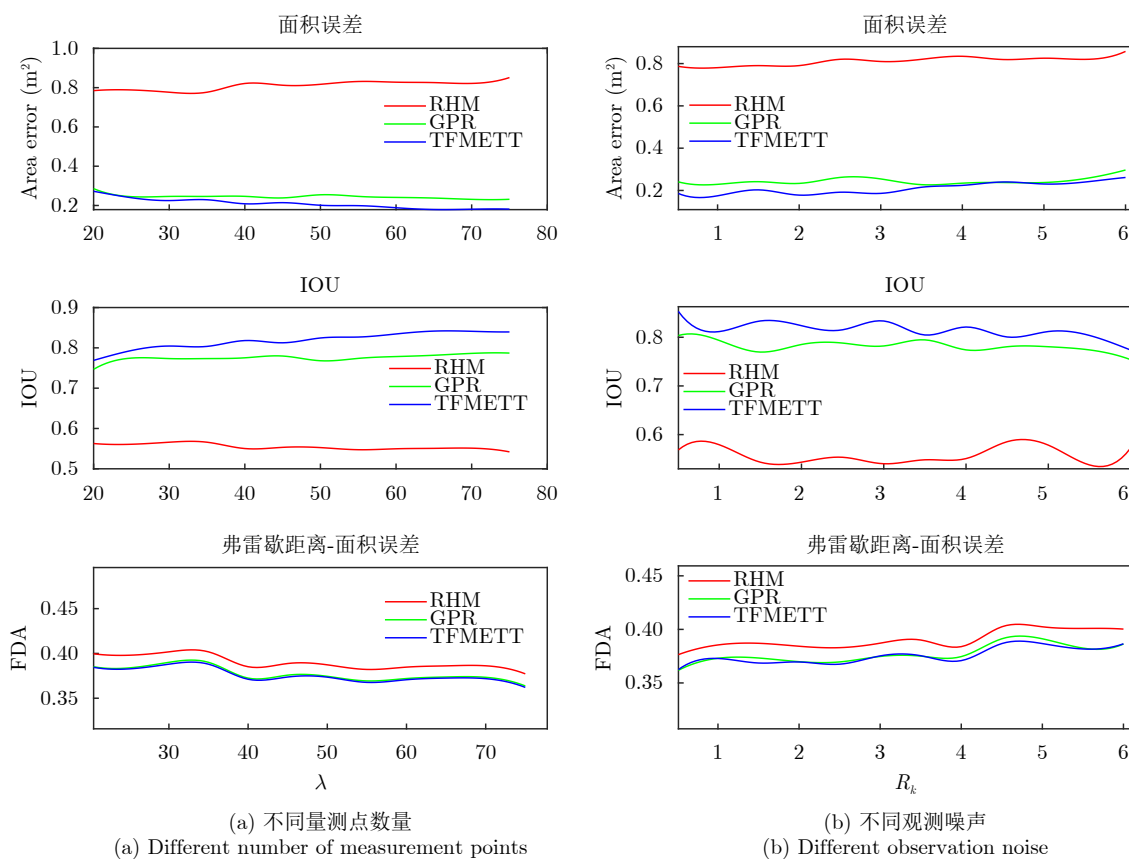
在图20(b)中进行了12次不同量测噪声的取值, 从最开始的0.5增加到6.0, 同样也利用插值的方式将其绘制为平滑的曲线, 可以明显地看到, 随着噪声的增大, 性能均有所下降。

通过以上测试不难发现, 本文所提算法在稳定性方面较其他两种方法也有不小的改善。

6 结语

本文创新点是针对复杂的星凸形机动扩展目标跟踪中对形态和运动状态估计不够准确的问题所提出的一种新的跟踪方法。

该方法结合Transformer网络模型实现了对机动运动模式的认知估计, 同时通过对扩展目标的形状轮廓建立了新的模型实现对扩展目标形状的估计, 然后通过对两者的深度融合实现了星凸形机动扩展目标的状态和形态的估计。通过第5节的实验



(a) Different number of measurement points

(b) Different observation noise

图 20 鲁棒性测试

Fig. 20 Robustness test

仿真验证了本文所提算法的有效性, 分析可以看出, 本文所提算法能够准确在运动机动且形状突变的复杂机动扩展目标跟踪环境下估计出星凸形机动扩展目标的形态, 并且相较于传统算法有着更好的性能。

在本文所提出的方法只能适用于二维平面场景, 但三维场景下的扩展目标跟踪仍有不小的应用前景, 因此在未来的工作中可以将本文所提方法推广至三维场景下以实现更广泛的应用。

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] GRANSTRÖM K and BAUM M. A tutorial on multiple extended object tracking[EB/OL]. <https://www.techrxiv.org/doi/full/10.36227/techrxiv.19115858.v1>, 2022.
- [2] LAN Jian. Extended object tracking using random matrix with extension-dependent measurement numbers[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2023, 59(04): 4464–4477. doi: [10.1109/TAES.2023.3241888](https://doi.org/10.1109/TAES.2023.3241888).
- [3] MANNARI P, THARMARASA R, and KIRUBARAJAN T. Extended target tracking under multitarget tracking framework for convex polytope shapes[J]. *Signal Processing*, 2024, 217: 109321. doi: [10.1016/j.sigpro.2023.109321](https://doi.org/10.1016/j.sigpro.2023.109321).
- [4] TAN Jintao, QI Guoqing, QI Junjie, *et al.* Model parameter adaptive approach of extended object tracking using random matrix and identification[C]. 2022 International Conference on Cyber-Physical Social Intelligence, Nanjing, China, 2022: 91–97. doi: [10.1109/ICCSI55536.2022.9970662](https://doi.org/10.1109/ICCSI55536.2022.9970662).
- [5] BAUR T, REUTER J, ZEA A, *et al.* Extent estimation of sailing boats applying elliptic cones to 3D LiDAR data[C]. 2022 25th International Conference on Information Fusion (FUSION), Linköping, Sweden, 2022: 1–8. doi: [10.23919/FUSION49751.2022.9841265](https://doi.org/10.23919/FUSION49751.2022.9841265).
- [6] ZHANG Yongquan, JI Hongbing, and HU Qi. A box-particle implementation of standard PHD filter for extended target tracking[J]. *Information Fusion*, 2017, 34: 55–69. doi: [10.1016/j.inffus.2016.06.007](https://doi.org/10.1016/j.inffus.2016.06.007).
- [7] ZHANG Xiaoxiao and LAN Jian. Measurement combination estimator for multisensor extended object tracking using random matrix[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2024, 60(1): 698–715. doi: [10.1109/TAES.2023.3329075](https://doi.org/10.1109/TAES.2023.3329075).
- [8] BAUM M and HANEBECK U D. Random hypersurface models for extended object tracking[C]. 2009 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT), Ajman, UAE, 2009: 178–183. doi: [10.1109/ISSPIT.2009.5407526](https://doi.org/10.1109/ISSPIT.2009.5407526).
- [9] BAUM M and HANEBECK U D. Shape tracking of extended objects and group targets with star-convex RHMs[C]. 14th International Conference on Information Fusion, Chicago, USA, 2011: 1–8.
- [10] YANG Jinlong, LI Peng, and GE Hongwei. Extended target shape estimation by fitting B-spline curve[J]. *Journal of Applied Mathematics*, 2014, 2014: 741892. doi: [10.1155/2014/741892](https://doi.org/10.1155/2014/741892).
- [11] KOCH J W. Bayesian approach to extended object and cluster tracking using random matrices[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2008, 44(3): 1042–1059. doi: [10.1109/TAES.2008.4655362](https://doi.org/10.1109/TAES.2008.4655362).
- [12] FELDMANN M, FRÄNKEN D, and KOCH W. Tracking of extended objects and group targets using random matrices[J]. *IEEE Transactions on Signal Processing*, 2011, 59(4): 1409–1420. doi: [10.1109/TSP.2010.2101064](https://doi.org/10.1109/TSP.2010.2101064).
- [13] SWAIN A and CLARK D. Extended object filtering using spatial independent cluster processes[C]. 2010 13th International Conference on Information Fusion, Edinburgh, UK, 2010: 1–8. doi: [10.1109/ICIF.2010.5711886](https://doi.org/10.1109/ICIF.2010.5711886).
- [14] ABDALLAH F, GNING A, and BONNIFAIT P. Box particle filtering for nonlinear state estimation using interval analysis[J]. *Automatica*, 2008, 44(3): 807–815. doi: [10.1016/j.automatica.2007.07.024](https://doi.org/10.1016/j.automatica.2007.07.024).
- [15] LAN Jian and LI Xiaorong. Tracking of maneuvering non-ellipsoidal extended object or target group using random matrix[J]. *IEEE Transactions on Signal Processing*, 2014, 62(9): 2450–2463. doi: [10.1109/TSP.2014.2309561](https://doi.org/10.1109/TSP.2014.2309561).
- [16] LAN Jian and LI Xiaorong. Tracking of extended object or target group using random matrix—part I: New model and approach[C]. 2012 15th International Conference on Information Fusion, Singapore, Singapore, 2012: 2177–2184.
- [17] WAHLSTROM N and ÖZKAN E. Extended target tracking using Gaussian processes[J]. *IEEE Transactions on Signal Processing*, 2015, 63(16): 4165–4178. doi: [10.1109/TSP.2015.2424194](https://doi.org/10.1109/TSP.2015.2424194).
- [18] LI Xiaorong and ZHANG Youmin. Multiple-model estimation with variable structure. V. Likely-model set algorithm[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2000, 36(2): 448–466. doi: [10.1109/7.845222](https://doi.org/10.1109/7.845222).
- [19] LI Xiaorong, ZWI X, and ZWANG Y. Multiple-model estimation with variable structure. III. Model-group switching algorithm[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1999, 35(1): 225–241. doi: [10.1109/7.745694](https://doi.org/10.1109/7.745694).
- [20] JILKOV V P, ANGELOVA D S, and SEMERDJIEV T A. Design and comparison of mode-set adaptive IMM algorithms for maneuvering target tracking[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1999,

- 35(1): 343–350. doi: [10.1109/7.745704](https://doi.org/10.1109/7.745704).
- [21] 王昱淇, 卢宙, 蔡云泽. 基于一致性的分布式变结构多模型方法[J]. 自动化学报, 2021, 47(7): 1548–1557. doi: [10.16383/j.aas.c190091](https://doi.org/10.16383/j.aas.c190091).
WANG Yuqi, LU Zhou, and CAI Yunze. Consensus-based distributed variable structure multiple model[J]. *Acta Automatica Sinica*, 2021, 47(7): 1548–1557. doi: [10.16383/j.aas.c190091](https://doi.org/10.16383/j.aas.c190091).
- [22] 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. doi: [10.16798/j.issn.1003-0530.2021.05.005](https://doi.org/10.16798/j.issn.1003-0530.2021.05.005).
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. doi: [10.16798/j.issn.1003-0530.2021.05.005](https://doi.org/10.16798/j.issn.1003-0530.2021.05.005).
- [23] LIU Jingxian, YANG Shuhong, and YANG Fan. A cross-and-dot-product neural network based filtering for maneuvering-target tracking[J]. *Neural Computing and Applications*, 2022, 34(17): 14929–14944. doi: [10.1007/s00521-022-07338-7](https://doi.org/10.1007/s00521-022-07338-7).
- [24] SONG Fei, LI Yong, CHENG Wei, *et al.* An improved Kalman filter based on long short-memory recurrent neural network for nonlinear radar target tracking[J]. *Wireless Communications and Mobile Computing*, 2022, 2022: 8280428. doi: [10.1155/2022/8280428](https://doi.org/10.1155/2022/8280428).
- [25] GAO Chang, LIU Hongwei, ZHOU Shenghua, *et al.* Maneuvering target tracking with recurrent neural networks for radar application[C]. 2018 International Conference on Radar (RADAR), Brisbane, Australia, 2018: 1–5. doi: [10.1109/RADAR.2018.8557284](https://doi.org/10.1109/RADAR.2018.8557284).
- [26] YU Wanting, YU Hongyi, DU Jianping, *et al.* DeepGTT: A general trajectory tracking deep learning algorithm based on dynamic law learning[J]. *IET Radar, Sonar & Navigation*, 2021, 15(9): 1125–1150. doi: [10.1049/rsn2.12111](https://doi.org/10.1049/rsn2.12111).
- [27] LIU Jingxian, WANG Zulin, and XU Mai. DeepMTT: A deep learning maneuvering target-tracking algorithm based on bidirectional LSTM network[J]. *Information Fusion*, 2020, 53: 289–304. doi: [10.1016/j.inffus.2019.06.012](https://doi.org/10.1016/j.inffus.2019.06.012).
- [28] JOUABER S, BONNABEL S, VELASCO-FORERO S, *et al.* NNAKF: A neural network adapted Kalman filter for target tracking[C]. ICASSP 2021–2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Toronto, Canada, 2021: 4075–4079. doi: [10.1109/ICASSP39728.2021.9414681](https://doi.org/10.1109/ICASSP39728.2021.9414681).
- [29] AFTAB W and MIHAYLOVA L. A learning Gaussian process approach for maneuvering target tracking and smoothing[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2021, 57(1): 278–292. doi: [10.1109/TAES.2020.3021220](https://doi.org/10.1109/TAES.2020.3021220).
- [30] NEZHADARYA E, LIU Yang, and LIU Bingbing. BoxNet: A deep learning method for 2d bounding box estimation from bird’s-eye view point cloud[C]. 2019 IEEE Intelligent Vehicles Symposium (IV), Paris, France, 2019: 1557–1564. doi: [10.1109/IVS.2019.8814058](https://doi.org/10.1109/IVS.2019.8814058).
- [31] STEUERNAGEL S, THORMANN K, and BAUM M. CNN-based shape estimation for extended object tracking using point cloud measurements[C]. 2022 25th International Conference on Information Fusion (FUSION), Linköping, Sweden, 2022: 1–8. doi: [10.23919/FUSION49751.2022.9841254](https://doi.org/10.23919/FUSION49751.2022.9841254).
- [32] BARINGOLTS T V, DOMIN D V, ZHUK S Y, *et al.* Adaptive algorithm of maneuvering target tracking in complex jamming situation for multifunctional radar with phased antenna array[J]. *Radioelectronics and Communications Systems*, 2019, 62(7): 342–355. doi: [10.3103/S0735272719070021](https://doi.org/10.3103/S0735272719070021).
- [33] XU Xiaolong and HARADA K. Automatic surface reconstruction with alpha-shape method[J]. *The Visual Computer*, 2003, 19(7): 431–443. doi: [10.1007/s00371-003-0207-1](https://doi.org/10.1007/s00371-003-0207-1).
- [34] EDELSBRUNNER H, KIRKPATRICK D, and SEIDEL R. On the shape of a set of points in the plane[J]. *IEEE Transactions on Information Theory*, 1983, 29(4): 551–559. doi: [10.1109/TIT.1983.1056714](https://doi.org/10.1109/TIT.1983.1056714).
- [35] 李世林, 李红军. 自适应步长的Alpha-shape表面重建算法[J]. 数据采集与处理, 2019, 34(3): 491–499. doi: [10.16337/j.1004-9037.2019.03.012](https://doi.org/10.16337/j.1004-9037.2019.03.012).
LI Shilin and LI Hongjun. Surface reconstruction algorithm using self-adaptive step Alpha-shape[J]. *Journal of Data Acquisition and Processing*, 2019, 34(3): 491–499. doi: [10.16337/j.1004-9037.2019.03.012](https://doi.org/10.16337/j.1004-9037.2019.03.012).
- [36] LÜTKEPOHL H. Vector Autoregressive Models[M]. HASHIMZADE N and THORNTON M A. Handbook of Research Methods and Applications in Empirical Macroeconomics. Cheltenham: Edward Elgar, 2013: 139–164. doi: [10.4337/9780857931023.00012](https://doi.org/10.4337/9780857931023.00012).
- [37] GHIASI G, LIN T Y, and LE Q V. DropBlock: A regularization method for convolutional networks[C]. The 32nd International Conference on Neural Information Processing Systems, Montréal, Canada, 2018: 10750–10760.
- [38] BAI Shaojie, KOLTER J Z, and KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[EB/OL]. <https://arxiv.org/abs/1803.01271>, 2018.
- [39] LUO Yi and MESGARANI N. Conv-TasNet: Surpassing ideal time-frequency magnitude masking for speech separation[J]. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2019, 27(8): 1256–1266. doi: [10.1109/TAAS.2019.2923632](https://doi.org/10.1109/TAAS.2019.2923632).

- [1109/TASLP.2019.2915167](#).
- [40] BADRINARAYANAN V, KENDALL A, and CIPOLLA R. SegNet: A deep convolutional encoder-decoder architecture for image segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(12): 2481–2495. doi: [10.1109/TPAMI.2016.2644615](#).
- [41] CHO K, VAN MERRIËNBOER B, BAHDANAU D, *et al.* On the properties of neural machine translation: Encoder-decoder approaches[C]. Eighth Workshop on Syntax, Semantics and Structure in Statistical Translation, Doha, Qatar, 2014: 103–111. doi: [10.3115/v1/W14-4012](#).
- [42] VASWANI A, SHAZEER N, PARMAR N, *et al.* Attention is all you need[C]. The 31st International Conference on Neural Information Processing Systems, Long Beach, USA, 2017: 6000–6010.
- [43] SUBAKAN C, RAVANELLI M, CORNELL S, *et al.* Attention is all you need in speech separation[C]. ICASSP 2021–2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Toronto, Canada, 2021: 21–25. doi: [10.1109/ICASSP39728.2021.9413901](#).
- [44] BARRON J T. A general and adaptive robust loss function[C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Long Beach, USA, 2019: 4326–4334. doi: [10.1109/CVPR.2019.00446](#).
- [45] ALT H and GODAU M. Computing the Fréchet distance between two polygonal curves[J]. *International Journal of Computational Geometry & Applications*, 1995, 5(1/2): 75–91. doi: [10.1142/S0218195995000064](#).

作者简介

陈辉，教授，博士生导师，主要研究方向为数据融合、统计信号处理、机器学习和智能决策。

边斌超，硕士生，主要研究方向为神经网络和扩展目标跟踪。

连峰，教授，博士生导师，主要研究方向为多源信息融合、滤波与估计算法、气动融合算法。

韩崇昭，教授，博士生导师，主要研究方向为数据融合、电子对抗、雷达目标跟踪等。

(责任编辑：于青)