

文章编号:1007-2780(XXXX)XX-0001-20

基于多特征匈牙利匹配的星图空间目标检测算法

牛海鹏, 黄亚伟*

(中国科学院 长春光学精密机械与物理研究所, 吉林 长春 130033)

摘要:传统匈牙利算法在星图空间目标检测中存在四方面局限性:缺乏运动预测、全局搜索冗余、匹配特征单一和固定权重缺乏适应性。在高低速目标共存、目标密集逼近、尺寸动态变化及低信噪比等复杂场景下,上述不足导致检测精度和身份一致性显著下降。本文提出一种基于多特征递进改进的匈牙利匹配算法,首先引入卡尔曼滤波器对目标位置和速度进行预测,以预测位置替代静态观测位置构造匹配代价;其次利用卡尔曼预测协方差矩阵构建马氏距离门控,将匈牙利匹配的搜索空间从全局约束为预测椭圆内的局部区域;然后设计多特征动态权重机制,根据位置、面积和长宽比的实时可靠性自适应调整各特征的代价贡献;最后引入异常惩罚机制,对面积和长宽比异常突变的候选匹配施加额外代价。在五种代表性仿真星图场景(多速度目标、目标密集逼近、多机制混合、高密度目标和低信噪比)下的实验表明,本文算法平均MOTA为88.3%,超出传统匈牙利算法(82.4%)5.9个百分点、PPMHT(64.6%)23.7个百分点和最近邻(82.3%)6.0个百分点;平均IDF1为65.8%,超出传统匈牙利算法(56.3%)9.5个百分点、PPMHT(50.0%)15.8个百分点;平均IDS为1.6次,低于传统匈牙利(3.9次)2.3次、低于最近邻(5.2次)3.6次;平均耗时为41.2ms/帧,满足实时性要求。消融实验表明,卡尔曼预测、马氏门控、动态权重和异常惩罚四项改进分别贡献MOTA增益8.8、6.5、3.2和1.2个百分点。本文算法通过四个维度递进改进框架,在检测精度、身份一致性和计算效率之间取得了有效平衡,为星图空间目标的可靠帧间关联提供了一种有效方案。

关键词:星图空间目标检测;匈牙利算法;多特征优化;卡尔曼滤波;马氏距离门控;动态权重

中图分类号:TP751.1;TP391.4 文献标识码:A doi:10.37188/CJLCD.2026-0099 CSTR:32172.14.CJLCD.2026-0099

Space target detection algorithm for star images based on multi-feature hungarian matching

NIU Haipeng, HUANG Yawei

(Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences,
Changchun 130033, China)

Abstract: Four major limitations exist when the conventional Hungarian algorithm is applied to space target detection in star images, including the lack of motion prediction, redundant global searching, single matching feature, and poor adaptability of fixed weights. In complex scenarios with coexisting high-speed and low-speed targets, densely distributed and closely approaching targets, dynamically varying target sizes, and low signal-to-noise ratios, the above drawbacks significantly degrade tracking accuracy and identity consistency. An improved Hungarian matching algorithm based on progressive multi-feature

收稿日期:2026-06-02;修订日期:2026-07-13.

基金项目:国家自然科学基金(No.62505316)

Supported by National Natural Science Foundation of China (No.62505316)

*通信联系人, E-mail:niuhaipeng@ciomp.ac.cn

optimization is proposed. Firstly, a Kalman filter is introduced to predict the position and velocity of space targets, and predicted coordinates are adopted to construct matching costs instead of static observations. Secondly, a Mahalanobis distance gating mechanism is established using the covariance matrix derived from Kalman prediction, which constrains the matching search range from the global image to the local region within the predicted ellipsoid and reduces computational redundancy. Thirdly, a dynamic multi-feature weighting strategy is designed to adaptively adjust the cost contribution of position, area and aspect ratio according to their real-time reliability. Furthermore, an anomaly penalty term is added to impose extra costs on matching pairs with abrupt changes in area or aspect ratio to suppress false associations. Comparative experiments are carried out on five types of simulated star image scenes. The experimental results show that the average MOTA of the proposed algorithm reaches 88.3%, which is 5.9 percentage points higher than the conventional Hungarian algorithm, and 23.7 and 6.0 percentage points higher than PPMHT and the nearest neighbor method, respectively. Its average IDF1 is 65.8%, 9.5 percentage points higher than that of the conventional Hungarian algorithm. The average IDS is only 1.6, 2.3 and 3.6 lower than the conventional Hungarian algorithm and the nearest neighbor method, respectively. The average processing time per frame is 41.2 ms, which meets real-time operation requirements. Ablation experiments verify that the Kalman prediction module, Mahalanobis distance gating, dynamic weighting and anomaly penalty bring MOTA gains of 8.8, 6.5, 3.2 and 1.2 percentage points, respectively. The proposed four-module progressive optimization framework achieves an effective balance among tracking accuracy, identity consistency and computational efficiency, and provides a reliable solution for inter-frame association of space targets in star images. .

Key words: star image space target detection; hungarian algorithm; multi-feature optimization; kalman filter; mahalanobis distance gating; dynamic weight

1 引 言

随着航天发射活动日益频繁,空间目标数量持续增长。据统计全球可跟踪在轨编目空间目标数量已突破44 000个,并以每年约5%的速度递增^[1-2]。基于光学星图的目标检测通过从连续帧星图中提取并跟踪运动目标,为轨道确定和空间态势感知提供关键数据支撑,已成为保障航天安全的核心技术手段^[3-8]。

星图空间目标检测的核心挑战在于将暗弱运动目标从密集的恒星背景中可靠分离,并在帧间建立正确的关联。主要流程包括图像预处理(背景与恒星去除)和目标关联(帧间目标匹配)两个阶段,其中目标关联直接决定了跟踪轨迹的连续性和身份一致性。

目标关联方法可根据优化策略分为四类。第一类:最近邻(NN)方法以贪心策略逐一分配最近候选检测,实时性好但缺乏全局视野,在目标密集或交叉运动时易产生级联误匹配,导致轨

迹断裂。第二类:概率目标关联方法以联合概率目标关联(JPDA)^[9-10]为代表,枚举所有可行关联假设并计算联合后验概率,身份保持能力优于最近邻,但假设空间随目标数量指数增长,限制了大规模场景下的实用性。第三类:多假设跟踪(MHT)及其变体PPMHT^[11-13]:MHT维护轨迹假设树并延迟决策以获得理论最优解,但计算与存储开销较高;PPMHT以速度和角度约束替代假设枚举以提高效率,但固定阈值对不同运动模式的目标适应性不足。第四类:匈牙利算法^[14]将关联问题建模为二分图最小代价匹配,进而获得全局最优解。与贪心策略不同,匈牙利算法同时考虑所有可能的匹配组合,有效缓解局部最优导致的全局匹配误差,被广泛应用于SORT和DeepSORT等主流跟踪框架^[15-21],其在优化质量与计算效率之间的平衡使其成为当前最具工程实用价值的目标关联方案之一。

然而,标准的匈牙利匹配框架存在四方面局限。第一,缺乏运动预测能力。直接将上一帧观

测位置与当前帧检测位置计算欧氏距离,未利用目标运动历史信息进行位置预测。在目标高速运动或速度突变时,静态位置代价无法准确反映轨迹的真实运动趋势,导致匹配偏差累积。第二,全局搜索冗余。标准流程构造完整的 $m \times n$ 代价矩阵并执行全图分配,未对候选匹配的空间范围施加约束。星图预处理后每帧可能产生数十个候选目标,大量远距离无关候选对同等地参与代价计算,不仅引入冗余开销,还可能产生远距离噪声匹配。第三,匹配特征单一。现有方法普遍仅依赖位置距离作为唯一判别依据并采用固定权重组合。当候选目标在位置空间彼此接近时,如在密集星场或目标交叉运动场景,单一特征缺乏足够区分度,算法可能输出全局代价最低但局部错误的匹配方案。第四,固定权重缺乏适应性。固定特征权重无法根据检测场景变化自适应调整。当目标尺寸因距离或噪声波动时,固定的权重可能导致匹配代价失真。PPMHT等^[11-13]基于固定阈值的方法还需预设速度范围和角度范围等场景依赖参数,适应性更差。

针对上述问题,本文提出一种基于多特征匈牙利匹配的星图空间目标检测算法。该算法以匈牙利匹配为基础框架,从四个维度进行递进式增强:首先引入卡尔曼滤波运动预测,以预测位置替代静态观测位置构造匹配代价;其次使用马氏距离门控局部搜索,利用预测协方差构建自适应搜索半径,替代固定速度阈值;然后设计多特征动态权重,根据位置、面积和长宽比的实时可靠性自适应分配各特征代价;最后加入异常惩罚,对面积突变等异常匹配施加额外代价,实现对复杂星图场景下空间目标运动轨迹的鲁棒关联。

2 匈牙利算法原理

匈牙利算法由 Kuhn 于 1955 年提出^[14],后经 Munkres 改进^[19]为 $O(n^3)$ 时间复杂度的组合优化算法,是求解指派问题 (Assignment Problem) 的经典方法。空间目标帧间关联可建模为二分图最小代价匹配问题,设第 $k-1$ 帧已建立 m 条跟踪轨迹 $T = \{T_1, T_2, \dots, T_m\}$, 第 k 帧检测到 n 个候选目标 $D = \{D_1, D_2, \dots, D_n\}$ 。 T_i 与 D_j 之间的匹配代价 c_{ij} 表示两者为同一目标所需的"花费代价",代价越小代表属于同一目标的概率越高。

所有成对代价构成 $m \times n$ 代价矩阵 $C \in \mathbb{R}^{m \times n}$ 如公式(1)所示

$$C = \begin{bmatrix} c_{11} & c_{12} & \cdots & c_{1n} \\ c_{21} & c_{22} & \cdots & c_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ c_{m1} & c_{m2} & \cdots & c_{mn} \end{bmatrix}. \quad (1)$$

匈牙利算法通过行简约、列简约、最小覆盖线、矩阵调整四步迭代求解,求解一对一匹配关系 $\sigma: \{1, \dots, m\} \rightarrow \{1, \dots, n\}$, 满足单轨迹至多匹配一个检测、无重复匹配,使得总代价 $\sum_{i=1}^m c_{i, \sigma(i)}$ 最小,实现全局最优匹配。

3 本文算法

3.1 算法总体框架

本文提出了一种基于多特征改进匈牙利匹配的星图空间目标检测算法,算法流程如图1所示。输入为连续帧序列星图,首先经过形态学背景去除、自适应阈值二值化、中值帧去除恒星




图1 本文目标检测算法流程图

Fig. 1 Flowchart of the proposed target detection algorithm

成预处理;再经目标特征提取、卡尔曼运动预测、马氏距离门控、多特征动态权重代价计算、异常匹配惩罚、轨迹管理,最终输出稳定目标关联结果。

3.2 预处理

3.2.1 星图成像特性分析

一幅星空背景的光学图像可由公式(2)表示:

$$f(i, j) = B(i, j) + T(i, j) + S(i, j) + n(i, j), \quad (2)$$

其中 f 为 $m \times n$ 的图像, (i, j) 为像素坐标, $B(i, j)$ 为背景, $T(i, j)$ 为目标, $S(i, j)$ 为恒星, $n(i, j)$ 为噪声。图像背景亮度分布不均、噪声基底较高,直接阈值分割会产生大量虚警;同时,恒星在图像上呈点状分布,成像特性与空间目标相似,容易造成目标误识别。两类干扰共同影响检测性能,因此必须通过预处理去除背景和恒星干扰。

3.2.2 形态学处理去除背景

本文采用形态学顶帽变换(Top-Hat Transform)进行背景去除,其核心思想是先用形态学运算估计背景分量,再从原图中减去该背景分量,实现背景校正与目标增强。




图2 形态学使用结构元素核。(a)膨胀核 K_{dilate} (b)腐蚀核 K_{erode}

Fig. 2 Structural element kernels used in morphology.
(a) Dilation kernel K_{dilate} (b) Erosion kernel K_{erode} .

顶帽变换主要包含两步操作,第一步为形态学膨胀操作,使用如图2(a)所示尺寸为 $d \times d$ 的空心膨胀核 K_{dilate} (d 为奇数, $c=1$,核边缘像素值为1,内部像素值为0)进行膨胀操作,膨胀操作定义如公式(3)所示,式中 p 和 q 表示核中所有值为1的位置相对于核中心的偏移量。

$$I_{dilate}(i, j) = \max_{(p, q) \in K_{dilate}} f(i + p, j + q). \quad (3)$$

第二步为形态学腐蚀操作,使用如图2(b)所

示尺寸为 $e \times e$ 的实心正方形(e 为奇数)腐蚀核 K_{erode} 对膨胀结果进行腐蚀,腐蚀操作定义如公式(4)所示,式中 p 和 q 表示核中所有值为1的位置相对于核中心的偏移量。

$$I_{bg}(i, j) = \min_{(p, q) \in K_{erode}} I_{dilate}(i + p, j + q). \quad (4)$$

膨胀-腐蚀组合(即形态学闭运算)得到背景估计图像 I_{bg} ,顶帽变换如公式(5)所示,结果 I_{th} 为原图减去背景估计图像 I_{bg} 后含有目标和恒星的图像。

$$I_{th}(i, j) = f(i, j) - I_{bg}(i, j). \quad (5)$$

3.2.3 自适应阈值二值化

顶帽变换后的图像采用自适应阈值进行二值化,此方法在星图弱小目标检测中已被广泛采用^[22-23]。阈值 T 的计算方式如公式(6)所示:

$$T = \mu + \alpha \cdot \sigma, \quad (6)$$

其中 μ 为顶帽变换后图像的均值, σ 为标准差, α 为自适应阈值系数。二值化后的图像 I_{bin} 定义如公式(7)所示。

$$I_{bin}(i, j) = \begin{cases} 255, & I_{th}(i, j) \geq T \\ 0, & I_{th}(i, j) < T \end{cases}. \quad (7)$$

3.2.4 中值帧去恒星

利用恒星静止和目标运动的特性,采用时序中值背景建模方法实现恒星去除。设连续输入的 N 帧二值星图图像序列为 $I_{bin_t}(i, j)$,其中 $t=1, 2, \dots, N$ 为帧序号, (i, j) 为图像像素坐标,二值图像像素满足 $I_{bin_t}(i, j) \in \{0, 255\}$,对同一像素位置沿时间维度求取中值,得到恒星图像如公式(8)所示。

$$M(i, j) = \text{median}_{1 \leq t \leq N} (I_{bin_t}(i, j)). \quad (8)$$

将每一帧原始二值图像与恒星图像做差分运算,通过阈值分割去除静止恒星干扰,最终得到去恒星后的目标二值图像 $F_t(i, j)$ 如公式(9)所示。

$$F_t(i, j) = \begin{cases} 255, & I_{bin_t}(i, j) - M(i, j) > 0 \\ 0, & \text{其他} \end{cases}. \quad (9)$$

3.2.4 预处理结果

如图3所示,以一帧典型仿真星图为例,展示了从原始输入到目标提取的完整流程。图3(a)为原始星图,图中密集的恒星背景与暗弱运动目标共存,直接进行目标检测将产生大量虚警。经形态学顶帽变换后得到图3(b),不均匀背景被有效去除,恒星和目标的对比度得到增强。经自适

应阈值二值化(公式取值为 $T = \mu + 0.5\sigma$)得到二值图像图 3(c),恒星和目标均被保留。图 3(d)为对连续 10 帧二值图像逐像素求取时序中值得

到的恒星模板。将二值化结果图 3(c)与恒星模板图 3(d)做差分并经过阈值分割,得到去恒星后的预处理结果图 3(e)。




图 3 星图预处理流程。(a)原始星图;(b)顶帽变换结果;(c)二值化结果;(d)恒星模板;(e)预处理最终结果。

Fig. 3 Star image preprocessing pipeline. (a) Original star image; (b) Top-hat transform result; (c) Binarization result; (d) Star template; (e) Final preprocessing result.

3.3 目标关联

3.3.1 特征提取

对 3.2 节预处理后的目标提取三类关键特征:

(1)质心坐标

采用图像矩计算目标质心 (x_j, y_j) ,用于表征目标空间位置,作为运动预测与位置匹配的依据,目标质心 (x_j, y_j) 计算公式如公式(10)-(14)所示,其中 M_{00} 为零阶矩, M_{01} 和 M_{10} 为一阶矩。

$$M_{00} = \sum_i \sum_j F_t(i, j), \quad (10)$$

$$M_{01} = \sum_i \sum_j j \cdot F_t(i, j), \quad (11)$$

$$M_{10} = \sum_i \sum_j i \cdot F_t(i, j), \quad (12)$$

$$x_j = \frac{M_{10}}{M_{00}}, \quad (13)$$

$$y_j = \frac{M_{01}}{M_{00}}. \quad (14)$$

(2)目标面积

统计各个候选目标连通域内有效像素总数,得到目标面积 A_j ,计算公式如公式(15)所示,反映目标成像尺寸的变化规律。

$$A_j = M_{00}. \quad (15)$$

(3)长宽比

提取目标最小外接矩形的宽度 W 与高度 H ,计算长宽比,计算公式如公式(16)所示,用于描述目标形状特征。

$$\rho_j = \frac{W}{H}. \quad (16)$$

经特征提取后,每一帧候选目标可表示为 (x_j, y_j, A_j, ρ_j) ,包含位置、面积、长宽比的特征向量,将作为卡尔曼滤波预测、马氏距离门控与多特征代价计算的基础输入。

3.3.2 卡尔曼滤波运动预测

传统匈牙利匹配采用上一帧目标位置为基准,缺乏运动预测能力^[24],本文通过卡尔曼滤波对目标位置进行预测,采用匀速运动模型作为卡尔曼滤波的基础,状态转移方程如公式(17)所示,定义目标状态向量为 $\mathbf{x} = [x, y, v_x, v_y]^T$,其中 (x, y) 为位置, (v_x, v_y) 为速度分量。

$$\mathbf{x}_k = \mathbf{F}\mathbf{x}_{k-1} + \mathbf{w}_{k-1}, \quad \mathbf{w}_{k-1} \sim N(0, \mathbf{Q}), \quad (17)$$

其中状态转移矩阵 $\mathbf{F}$ 和过程噪声协方差 $\mathbf{Q}$ 如公式(18)和公式(19)所示:

$$\mathbf{F} = \begin{bmatrix} 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad (18)$$

$$\mathbf{Q} = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & \sigma_q^2 & 0 \\ 0 & 0 & 0 & \sigma_q^2 \end{bmatrix}, \quad (19)$$

其中 σ_q 为过程噪声标准差。过程噪声仅作用于速度分量,反映了目标运动的微小不确定性。观测模型如公式(20)所示:

$$\mathbf{z}_k = \mathbf{H}\mathbf{x}_k + \mathbf{v}_k, \quad \mathbf{v}_k \sim N(0, \mathbf{R}). \quad (20)$$

观测矩阵 $\mathbf{H}$ 仅提取位置分量,观测矩阵 $\mathbf{H}$ 如公式(21)所示:

$$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}. \quad (21)$$

观测噪声协方差 $\mathbf{R} = \text{diag}(\sigma_r^2, \sigma_r^2)$, σ_r 为观测噪声标准差。

卡尔曼滤波的递推包含两个阶段。预测阶段输出预测状态和预测协方差如公式(22)和公式(23)所示：

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{F} \hat{\mathbf{x}}_{k-1|k-1}, \quad (22)$$

$$\mathbf{P}_{k|k-1} = \mathbf{F} \mathbf{P}_{k-1|k-1} \mathbf{F}^T + \mathbf{Q}, \quad (23)$$

其中 $\mathbf{P}$ 为状态估计误差协方差矩阵, 其对角线元素 σ_x^2 , σ_y^2 , $\sigma_{v_x}^2$, $\sigma_{v_y}^2$ 分别为位置和速度分量的估计方差。

更新阶段修正过程如公式(24)-(26)所示：

$$\mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{H}^T (\mathbf{H} \mathbf{P}_{k|k-1} \mathbf{H}^T + \mathbf{R})^{-1}, \quad (24)$$

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k (\mathbf{z}_k - \mathbf{H} \hat{\mathbf{x}}_{k|k-1}), \quad (25)$$

$$\mathbf{P}_{k|k} = (\mathbf{I} - \mathbf{K}_k \mathbf{H}) \mathbf{P}_{k|k-1}. \quad (26)$$

卡尔曼增益 $\mathbf{K}_k$ 在预测不确定性与测量噪声之间动态平衡： $\mathbf{P}$ 较大时赋予观测更大权重以快速收敛， $\mathbf{P}$ 收敛后更多依赖模型预测。观测 $\mathbf{z}_k$ 是经马氏门控(3.3.3节)、多特征代价计算(3.3.4节)和异常惩罚(3.3.5节)后，由匈牙利算法最终确定与轨迹关联的检测点，此处为保持叙述完整性，先将卡尔曼递推公式完整列出。

为直观展示卡尔曼滤波迭代过程，选取一帧典型仿真星图一典型运动目标作为分析样本。目标在帧1~3以约40像素/帧高速运动，帧4起减速至约20像素/帧进入目标密集交汇区域。

表1 卡尔曼滤波矩阵参数汇总

Tab. 1 Summary of Matrix parameters for kalman filter

参数	取值/公式	说明
状态向量	$\mathbf{x} = [x, y, v_x, v_y]^T$	位置+速度
初始状态	$\mathbf{x}_0 = [x_{\text{obs}}, y_{\text{obs}}, 0, 0]^T$	首帧观测位置, 速度设零
状态转移矩阵	$\mathbf{F} = \begin{bmatrix} 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \Delta t = 1$	匀速运动模型, $\Delta t = 1$
观测矩阵	$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}$	仅提取位置分量
过程噪声协方差	$\mathbf{Q} = \text{diag}(0, 0, \sigma_q^2, \sigma_q^2), \sigma_q = 0.03$	仅速度分量有噪声
观测噪声协方差	$\mathbf{R} = \text{diag}(\sigma_r^2, \sigma_r^2), \sigma_r = 3.0$	位置观测噪声3像素
初始协方差	$\mathbf{P}_0 = \text{diag}(25, 25, 4, 4)$	位置方差25, 速度方差4
卡尔曼增益	$\mathbf{K}_k = \mathbf{P}_{k k-1} \mathbf{H}^T (\mathbf{H} \mathbf{P}_{k k-1} \mathbf{H}^T + \mathbf{R})^{-1}$	每帧动态计算

表1汇总了卡尔曼滤波涉及的全部矩阵参数及其取值。除卡尔曼增益 $\mathbf{K}_k$ 每帧动态计算外，其余矩阵均在初始化阶段确定并在全序列中保持不变。

图4(a)中黑实线为T2真实轨迹，灰色“×”为带噪观测，蓝色“○”为卡尔曼估计。初始阶段估计偏离明显，稳态阶段几乎完全重合。图4(b)和表1给出了位置估计方差 $[\mathbf{P}_{k|k}]_{1,1}$ 从25.0收敛到3.20的逐帧数值。

初始化阶段(帧1~3)，首帧位置设为观测值(380, 200)，速度初始化为零， $\mathbf{P}_0 = \text{diag}(25, 25, 4, 4)$ ，位置不确定性约5像素。帧2-3中 $\|\mathbf{K}_k\|_F = 0.509$ 将观测与预测加权融合，位

置估计方差 $[\mathbf{P}_{k|k}]_{1,1}$ 从25.0快速降至5.20(降幅79%)，速度估计 v_x 从0修正至-13.5像素/帧，逐步逼近真实值。位置-速度协方差 $[\mathbf{P}_{k|k}]_{1,3}$ 从0升至1.91，表明卡尔曼滤波收敛后速度估计趋于准确。


运动偏离阶段(帧4~5)，目标速度从-40降至-20像素/帧，匀速直线运动模型预测位置(307, 222)与实际(270, 225)偏差约37像素，观测残差升至38.0。位置估计方差 $[\mathbf{P}_{k|k}]_{1,1}$ 下降速率从-1.66减至-0.13/帧，呈现“收敛停滞”。位置-速度协方差 $[\mathbf{P}_{k|k}]_{1,3}$ 达峰值1.97， $\sigma_q = 0.03$ 优先保证了稳态抗噪能力。

稳态跟踪阶段(帧6~10)，目标恢复匀速后，

表2 卡尔曼迭代数值

Tab. 2 Numerical values of kalman iteration

帧号	真实位置	$\mathbf{z}_k$	$\hat{\mathbf{x}}_{k k-1}$	$(\hat{x}, \hat{y}, \hat{v}_x, \hat{v}_y)$	$\mathbf{v}_k$	$[\mathbf{P}_{k k}]_{1,1}$	$[\mathbf{P}_{k k}]_{3,3}$	$[\mathbf{P}_{k k}]_{1,3}$	$\ \mathbf{K}_k\ _F$
1	380,200	—	—	(380,200,0,0)	—	25	4	0	—
2	340,210	341,210	380,200	(351,207,-4.1,1.0)	39.7	6.87	3.58	0.95	0.509
3	300,220	302,225	347,208	(321,218,-13.5,4.5)	47.5	5.2	2.62	1.91	0.509
4	270,225	269,224	307,222	(286,223,-21.8,4.9)	38	5.08	1.63	1.97	0.509
5	250,225	255,227	264,228	(259,228,-23.5,4.7)	9.3	4.88	0.97	1.65	0.509
6	230,220	229,222	235,232	(232,227,-24.5,3.2)	12.8	4.54	0.59	1.3	0.509
7	210,210	209,209	207,230	(208,220,-24.4,0.7)	21.6	4.16	0.38	1.02	0.509
8	190,200	191,194	184,221	(187,210,-23.8,-1.7)	27.6	3.8	0.25	0.81	0.509
9	170,190	165,188	163,208	(164,200,-23.6,-3.1)	19.8	3.48	0.18	0.65	0.509
10	150,180	147,181	140,197	(142,192,-23.2,-4.1)	17.8	3.2	0.13	0.54	0.509

图4 卡尔曼滤波迭代过程。(a)轨迹与估计;(b)[$\mathbf{P}_{k|k}]_{1,1}$ 位置估计方差收敛曲线。Fig. 4 Kalman filter iteration. (a)Trajectory. (b)[$\mathbf{P}_{k|k}]_{1,1}$ Position estimation variance convergence curves.

位置估计方差 $[\mathbf{P}_{k|k}]_{1,1}$ 从4.54平稳降至3.20,速度估计稳定于 $-23 \sim -24$ 像素/帧。 $\|\mathbf{K}_k\|_F$ 恒定0.509,位置不确定性降至约1.8像素。

3.3.3 马氏距离门控局部搜索

3.3.3.1 马氏距离门控原理

传统匈牙利匹配需要构建完整的 $m \times n$ 代价矩阵并执行全局搜索,即使引入卡尔曼运动预测,也未对候选匹配的空间范围施加约束。大量与轨迹预测位置无关的检测目标仍会参与代价计算,既造成计算冗余,也增加了远距离噪声匹配的风险。为进一步压缩匹配空间、降低冗余计算,本文基于卡尔曼预测的协方差矩阵构建马氏距离门控机制,将全局搜索约束在预测椭圆内的局部区域。

马氏距离是衡量检测点与预测分布之间统计距离的指标,其核心优势是同时考虑了分布的

均值和协方差结构,因此能反映检测点与轨迹预测之间的统计可信程度。设轨迹 T_i 的卡尔曼预测位置为 $(\hat{x}_i, \hat{y}_i)$,预测协方差矩阵为 P_i ,检测点 $d_j = (x_j, y_j)$ 与预测之间的马氏距离平方计算公式如公式(27)所示:

$$D_M^2(i, j) = (d_j - H_{\hat{x}_i})^T (H P_i H^T)^{-1} (d_j - H_{\hat{x}_i}). \quad (27)$$

门控条件为 $D_M(i, j) \leq g$ 。根据 χ^2 分布理论,若测量噪声服从高斯分布, D_M^2 服从自由度为2的 χ^2 分布。

3.3.3.2 门控的自适应特性

基于卡尔曼预测协方差构建马氏距离门控,将全局搜索约束在预测椭圆内,仅保留统计可信的候选匹配。马氏椭圆的半轴长由协方差矩阵 P_i 的对角线元素 σ_x^2 和 σ_y^2 决定。搜索范围在 x 和 y 方向的半径分别为 $g \cdot \sigma_x$ 和 $g \cdot \sigma_y$ 。由于 σ 值随卡

尔曼滤波的收敛状态动态变化,所以门控半径具有自适应性,具体表现为:

新目标初始化阶段,初始协方差矩阵中位置分量的方差较大,门控半径较宽。宽门控在缺乏历史信息时确保了不遗漏初始检测。

稳定跟踪阶段,经若干帧卡尔曼更新后滤波器收敛,协方差矩阵 P_i 中位置分量的方差收窄至稳态,门控半径自动缩小。窄门控仅保留紧邻预测位置的候选检测,在排除远距离无关候选的同时减少了干扰并提高了匹配效率。

运动偏离阶段,当目标与观测相机相对速度因轨道运动发生变化时,匀速模型预测值与实际

观测之间出现系统性残差。残差增大驱动卡尔曼更新步骤的修正量上升,过程噪声 Q 通过协方差递推使 P_i 重新增大,门控半径随之拓宽,为偏离预测的目标提供了更大的搜索容差,避免了因模型失配导致的轨迹丢失

门控筛选后,仅满足 $D_M(i,j) \leq g$ 的检测点进入候选集合 C_i ,参与后续的代价计算和匈牙利匹配,门控外的检测点直接排除。

为进一步说明马氏距离门控搜索在目标跟踪中的自适应过程,以上述典型运动目标为例,展示门控搜索范围从初始化到稳态的收缩全过程。

表 3 门控搜索范围逐帧收缩
Tab. 3 Frame-by-frame shrinkage of gated search range

帧号	$[P_{k k}]_{1,1}$	σ^2	X方向总不确定度	R	搜索面积	阶段
1	25	9	34	34.9	3 827	目标初始化
2	6.87	9	15.87	23.9	1 794	目标初始化
3	5.2	9	14.2	22.6	1 604	目标初始化
4	5.08	9	14.08	22.5	1 590	运动偏离
5	4.88	9	13.88	22.3	1 562	运动偏离
6	4.54	9	13.54	22	1 521	稳定跟踪
7	4.16	9	13.16	21.7	1 479	稳定跟踪
8	3.8	9	12.8	21.4	1 439	稳定跟踪
9	3.48	9	12.48	21.2	1 412	稳定跟踪
10	3.2	9	12.2	20.9	1 372	稳定跟踪




图 5 马氏门控搜索范围收缩。(a)门控椭圆;(b)R收敛曲线。
Fig. 5 Gate contraction. (a) Gate ellipsoids. (b) R convergence.

表 3、图 5 从数值和可视化两个角度共同展示了门控搜索范围从初始化到稳态的完整收缩过程。图 5(a)中五条彩色虚线椭圆(帧 2/3/4/6/

9)展示了马氏门控半径变化过程,结合图 5(b)收敛曲线和表 3 逐帧数值对三阶段进行分析:

初始化阶段(1~3 帧)。帧 1 初值 $[P_{k|k}]_{1,1} =$

25.0, $R=34.9$ 像素,搜索面积约 3827,宽门控确保无先验速度时不遗漏候选。帧 2~3 中 $[P_{klk}]_{1,1}$ 降幅 79% 驱动 R 从 34.9 收缩为 22.6,搜索面积降幅 58%,速度估计迅速修正,预测准确性提升直接压缩搜索范围。

运动偏离阶段(4~5 帧)。目标速度降引发匀速运动模型失配, $[P_{klk}]_{1,1}$ 下降速率从 -1.66 减至 -0.13/帧, R 仅从 22.5 收缩为 22.3 像素。整个过程由于模型失配导致观测残差增大,进而导致 $[P_{klk}]_{1,1}$ 无法下降,最终使门控半径保持高位。但 R 仍可覆盖目标(预测偏差 37 像素 $< 2R$)。

稳态跟踪阶段(6~10 帧)。目标恢复匀速后, R 从 22.0 收缩为 20.9,搜索面积降至 172。窄门控将候选严格限制在半径 21 内,多目标场景中有效排除跨区域干扰,代价矩阵由稠密转稀疏。

3.3.4 多特征动态权重匹配代价

传统方法仅使用位置距离构造匹配代价,特征利用维度单一,信息利用不足,无法适应复杂场景目标检测^[25-26],本文设计将单一位置代价扩展为多特征融合的动态权重代价函数。

3.3.4.1 多特征代价函数

将匹配代价从单一位置距离扩展为位置、面积和长宽比三个特征的加权融合,加权融合过程如公式(28)所示:

$$c_{ij} = w_p \cdot d_p(i, j) + w_a \cdot d_a(i, j) + w_r \cdot d_r(i, j), \quad (28)$$

其中三个特征代价计算如公式(29)~(31)所示:

$$d_p(i, j) = \frac{\sqrt{(x_j - \hat{x}_i)^2 + (y_j - \hat{y}_i)^2}}{\max(W, H)}, \quad (29)$$

$$d_a(i, j) = \frac{|A_i - A_j|}{\max(A_i, A_j, \epsilon)}, \quad (30)$$

$$d_r(i, j) = \frac{|\rho_i - \rho_j|}{\max(\rho_i, \rho_j, \epsilon)}, \quad (31)$$

其中 (x_j, y_j) 为当前帧检测点的质心坐标, $(\hat{x}_i, \hat{y}_i)$ 为卡尔曼预测位置, A 为目标面积, ρ 为目标长宽比, ϵ 为防除零小量。所有代价均归一化至 $[0, 1]$ 范围。

3.3.4.2 动态权重调整

公式(28)中的权重 w_p 、 w_a 和 w_r 决定了三个特征在总代价中的贡献比例。若采用固定权重,当某特征因观测条件变化而可靠性降低时,其噪声将被持续注入总代价,导致匹配精度下降。为

此,本文根据各特征的实时可靠性对权重进行动态调整:特征可靠时赋予较高权重,特征不可靠时降低其权重,使匹配决策始终向高可靠性特征倾斜。三个特征均以标准差为度量基准,采用统一的函数形式 $w = \frac{1}{1 + \lambda \cdot \sigma}$, 其中 λ 为各特征独立设定的不确定性缩放因子, σ 为各特征统计量的标准差。

位置权重 w_p 如公式(32)所示,由轮廓点坐标的标准差 σ_p 决定:轮廓紧凑、点分布集中的目标质心可靠,轮廓松散、点分布分散的质心不可靠。面积权重 w_a 和长宽比权重 w_r 如公式(33)-(34)所示,由近 5 帧历史值的标准差 σ_a 和 σ_r 决定:标准差越小表明特征越稳定、可靠性越高。当近 5 帧历史信息不足时,面积和长宽比权重默认取 1.0,所有权重的值均归一化至 $[0, 1]$ 区间,避免极端值造成权重失效。动态权重由初始权重和可靠性共同决定,最终权重经归一化确保总和为 1。

$$w_p = \frac{1}{1 + \lambda_p \cdot \sigma_p}, \quad (32)$$

$$w_a = \frac{1}{1 + \lambda_a \cdot \sigma_a}, \quad (33)$$

$$w_r = \frac{1}{1 + \lambda_r \cdot \sigma_r}. \quad (34)$$

上述动态权重机制使公式(28)的代价矩阵自适应于观测条件:在特征可靠时充分利用多特征联合判别的区分能力,在特征退化时自动回归到高可靠性特征主导的判别模式。最终匹配代价将直接作为匈牙利算法的输入,实现位置、面积与长宽比特征联合驱动的鲁棒帧间关联。

为验证动态权重机制在多种特征可靠性退化条件下的自适应调节能力,选取一组典型弧线运动目标场景开展专项验证,模拟天基观测中轨道参数差异导致的像面投影轨迹弯曲效应,目标沿弧形轨迹运动,其像面投影面积与长宽比随相对观测姿态的改变呈规律性变化,弧前为圆形(15×15,长宽比=1.0),弧峰处因姿态偏转被拉长为横宽矩形(22×11,长宽比=2.0),弧后恢复为圆形(12×12,长宽比=1.0)。该场景覆盖了三种特征可靠性的独立退化过程,包括弧前位置、面积和长宽比均可靠,弧峰位置不可靠加面积波动,弧后面积剧烈不可靠。

表4 动态权重逐帧数据

Tab. 4 Dynamic weight frame data

帧号	坐标和尺寸	长宽比	σ_p	σ_a	σ_r	d_p	d_a	d_r	w_p	w_a	w_r	c
1	(80,240,15,15)	1	5	—	—	0	0	0	0.25	0.375	0.375	0
2	(98,235,15,15)	1	5	—	—	1.245	0	0	0.25	0.375	0.375	0.311
3	(116,228,15,15)	1	5	—	—	1.386	0	0	0.25	0.375	0.375	0.346
4	(134,220,15,15)	1	5	—	—	1.507	0	0	0.25	0.375	0.375	0.377
5	(152,215,18,13)	1.38	6	3.6	0.15	0.966	0.039	0.278	0.293	0.272	0.435	0.414
6	(170,212,22,11)	2	7.3	6.9	0.39	0.483	0.07	0.5	0.314	0.23	0.456	0.396
7	(188,209,20,12)	1.67	6.7	7.2	0.39	0.343	0.025	0.169	0.325	0.222	0.453	0.194
8	(206,208,16,13)	1.23	5.3	12.4	0.35	0.582	0.111	0.111	0.364	0.16	0.476	0.282
9	(224,207,14,13)	1.08	4.7	23.1	0.33	0.665	0.222	0.222	0.397	0.104	0.5	0.398
10	(242,207,12,12)	1	4	37	0.38	0.893	0.308	0.188	0.427	0.071	0.502	0.497




图6 动态权重验证。(a)目标轨迹图;(b)权重曲线。

Fig. 6 Verification of dynamic weights. (a) Target trajectory plot; (b) Weight curve.

图6(a)目标轨迹图中目标在各帧的检测矩形框,直观展示尺寸和长宽比的帧间变化。图6(b)给出了 w_p 、 w_a 和 w_r 三条权重曲线,结合表4逐帧数值对三阶段进行分析:

弧前阶段(1-4帧,深蓝)。尺寸 15×15 像素恒定(长宽比=1.0,面积=225), $\sigma_a = \sigma_r = 0$ (历史不足5帧,默认公式(33)~(34)输出1.0)。 $\sigma_p = 5.0$ (轮廓紧凑)。权重均衡 $w_p = 0.250$, $w_a = w_r = 0.375$ 。 d_p 从0升至1.507(卡尔曼从零初速收敛), $d_a = d_r = 0$ 。总代价 c 从0升至0.377,全程低于匹配置信度阈值。

弧峰阶段(5-7帧,红色高亮)。长宽比从 $1.0 \rightarrow 2.0 \rightarrow 1.67$, σ_r 从0.15升至0.39——长宽比可靠性下降。 σ_a 从3.6升至7.2。权重转移: w_a 从 $0.375 \rightarrow 0.272 \rightarrow 0.222$ (面积降权), w_r 从 $0.375 \rightarrow 0.435 \rightarrow 0.456$ (长宽比升权), w_p 从 $0.250 \rightarrow 0.293 \rightarrow 0.325$ 。 d_p 降至0.343(卡尔曼已收敛), d_r 在第6帧达峰值0.5。总代价 $C_{F5} =$

0.414, $C_{F6} = 0.396$, $C_{F7} = 0.194$,权重的自适应重分配抑制了退化特征的噪声贡献,使总匹配代价未随特征波动升高,反而保持平稳并略有下降。

弧后阶段(8-10帧,橙色高亮)。长宽比回落至1.0, σ_r 稳定在0.35, w_r 升至 $0.476 \rightarrow 0.502$ 。面积从240降至144, σ_a 从12.4升至37.0, w_a 降至 $0.160 \rightarrow 0.104 \rightarrow 0.071$ 。 d_a 在第10帧达峰值0.308,但 $w_a = 0.071$ 将其贡献压缩至0.022,若采用固定权重方案,总匹配代价将出现显著抬升。

三个阶段完整验证了公式(32)~(34),无论哪种特征退化,权重均在1帧内自适应重分配,将匹配决策主导权转移至当前最可靠的特征。

3.3.5 异常匹配惩罚机制

尽管引入马氏门控约束与特征动态权重策略,目标面积突变、长宽比异常突变等情况仍可能导致错误匹配。为了抑制此类现象,本文在多

特征动态权重代价的基础上引入异常匹配惩罚机制,对此类不合理匹配施加额外代价,在匈牙利匹配算法的代价最小化求解过程中实现自动抑制。

惩罚规则基于各特征的变化率触发。面积突变惩罚:若面积变化率超过 τ_a ,面积代价乘 γ_a 。长宽比突变惩罚:若长宽比变化率超过 τ_r ,长宽比代价乘 γ_r 。若两个特征的平均可靠性低于 τ_{rel} ,总代价额外乘 γ_{low} ,所有惩罚因子遵循统一规则:无异常时取值为1,不改变原始代价;出现异常时取值大于1,提高匹配代价,经惩罚修正后的匹配代价如公式(35)所示:

$$c_{ij'} = c_{ij} \cdot \gamma_a \cdot \gamma_r \cdot \gamma_{low}, \quad (35)$$

其中 c_{ij} 为动态权重融合后的原始匹配代价, $c_{ij'}$ 为异常匹配惩罚后的代价。

惩罚后的代价矩阵在门控区域内执行匈牙利最优匹配,匹配对需同时满足马氏门控和代价置信度($c_{ij'} < \tau_c$)双重约束, τ_c 为代价置信度阈值。

经双重约束筛选后,匈牙利匹配输出当前帧的轨迹-检测关联对集合。已匹配的轨迹利用关联检测点执行卡尔曼更新(公式(25)~(26)),未匹配的轨迹转入预测外推,未匹配的检测点转入候选轨迹初始化流程。以下通过轨迹管理(3.3.6节)对上述三类结果分别处理。

为验证异常惩罚机制对干扰目标误匹配的抑制效果,为验证异常匹配惩罚机制在特征突变工况下的误匹配抑制能力,选取一组典型目标交叉场景开展专项验证,分别考察长宽比异常惩罚($\gamma_r = 1.8$)和面积异常惩罚($\gamma_a = 1.5$)的独立作用。

表5 两组交叉目标异常惩罚前后匹配代价对比

Table. 5 Matching cost comparison with and without anomaly penalty for two crossing target pairs

帧号	匹配对	异常类型	面积变化率	长宽比变化率	无惩罚代价	有惩罚代价	触发规则	是否被抑制
5	T1→T2	长宽比突变(1.0→0.32)	0.40	0.68	0.38	0.68	$\gamma_r = 1.8$	是(>0.5)
5	T1→T1	无	0.05	0.02	0.08	0.08	—	—
5	T3→T4	面积突变(48→192)	0.75	0.00	0.35	0.53	$\gamma_a = 1.5$	是(>0.5)
5	T3→T3	无	0.04	0.01	0.07	0.07	—	—




图7 异常惩罚验证场景。(a)目标轨迹图;(b)匹配代价对比。

Fig. 7 Scenarios for anomaly penalty validation. (a) Target Trajectory Diagram; (b) Comparison of matching costs.

图7(a)为10帧最大值投影图,标记出4个目标全部位置:深蓝标记为正常帧,红色标记为交叉前一帧,两组交叉空间分离。图7(b)展示了启用异常惩罚和禁用异常惩罚两种匹配代价对比,结合表5目标匹配代价数值对两组目标进行分析:

长宽比惩罚组(T1×T2):T1为被跟踪目标

(圆形11×11,长宽比=1.0,速度15像素/帧,水平向右运动);T2为干扰目标(长宽比=0.32,速度28像素/帧,垂直向下运动)。帧5处T1(165,200)与T2(178,200)间距13像素,马氏门控椭圆($R \approx 22$)同时覆盖。T2的长宽比(0.32)与T1的历史特征(长宽比=1.0)差异巨大,长宽比变化率 $d_r = |0.32 - 1.0|/1.0 = 0.68 > 0.3$,触发

$\gamma_r = 1.8$ 。面积变化率 $d_a = |200 - 121|/200 = 0.40 < 0.5$, 不触发 γ_a , 只有长宽比惩罚的独立触发效果。

面积惩罚组(T3×T4): T3为小目标(长宽比=0.33, 面积48, 速度14像素/帧, 垂直向下运动); T4为大目标(长宽比=0.33, 面积192, 速度30像素/帧, 垂直向上运动)。帧5处T3(250, 320)与T4(262, 310)间距15.6像素, 同在门控椭圆内。两者长宽比完全相同(长宽比=0.33), 长宽比变化率为0不触发 γ_r , 但面积变化率 $d_a = |192 - 48|/192 = 0.75 > 0.5$, 触发 $\gamma_a = 1.5$ 。

上述两组交叉场景完整验证了异常匹配惩罚机制的独立作用, 两类惩罚互不交叉干扰; 惩罚机制仅抬升特征异常的不合理匹配代价, 对正常匹配无额外影响。

3.3.6 轨迹管理

目标关联完成帧间匹配后, 需通过轨迹管理区分虚警与真实运动目标, 保障跟踪结果的可靠性与稳定性。

(1) 候选轨迹初始化

对于当前帧未匹配到任何轨迹的检测点, 自动生成一条临时候选轨迹, 并为其分配独立的卡尔曼滤波器。

(2) 轨迹确认

候选轨迹在整个序列中累计成功关联达到轨迹确认帧数阈值 $N_{confirm}$ 及以上, 即判定为真实目标, 更新为确认轨迹, 参与后续跟踪并计入最终检测结果。

(3) 轨迹保持与终止

对于已确认的有效轨迹, 若连续无匹配帧数未超过轨迹丢失帧数阈值 N_{miss} , 则由卡尔曼滤波继续预测外推, 避免因短暂遮挡、弱信噪比导致轨迹误断; 若连续无匹配帧数达到轨迹终止帧数阈值 N_{term} , 则判定目标消失或移出视场, 终止并删除该轨迹。

3.3.6 算法全链路中间结果验证

以一组典型多目标仿真场景为例, 按照算法串行处理时序, 采用2行5列可视化面板完整呈现从原始星图输入至星点最终关联输出的全链路中间过程结果具体如图8(a)~(j)所示。

图8完整展示了从原始星图输入到轨迹关联

输出的全流程处理效果, 各子图分析如下:

图8(a)可直观呈现多目标的空间运动布局: 3个目标在第4~5帧形成密集交汇区域, 最小间距约12像素, 剩余1个目标沿视场底部水平独立运动, 与密集区域无空间交叠。

图8(b)为形态学预处理后的投影结果。经顶帽变换抑制大面积缓变背景后, 目标信号与恒星背景的对比度显著提升, 全序列所有帧的目标位置均清晰可辨, 验证了该形态学预处理方法对全序列的有效性。

图8(c)为多帧合成的恒星模板。通过10帧二值图像逐像素取中值, 可滤除运动目标、保留静止恒星背景, 模板构建过程已剔除面积小于9的散粒噪声, 为后续恒星抑制提供了稳定的背景基准。

图8(d)为恒星抑制后的动目标投影结果。将单帧二值图像与恒星模板逐像素差分并再次滤除噪声后, 背景恒星被完全清除, 仅保留运动目标区域, 验证了中值帧恒星抑制步骤的正确性。

图8(e)直观展示了卡尔曼预测与马氏门控的空间约束效果。门控椭圆随滤波迭代逐帧收缩, 从初始化阶段的宽搜索范围逐步收敛至稳态窄范围, 体现了卡尔曼滤波位置估计方差减小、驱动门控半径逐帧收窄的数值传递关系。

图8(f)为位置估计方差的收敛曲线, 全程可分为三个阶段: 初始化阶段方差快速下降, 第1~3帧降幅达79%; 第4~5帧因目标减速、匀速模型短时失配, 下降速率骤减, 出现收敛迟滞; 第6帧后进入稳态, 方差平稳降至3.20。

图8(g)为门控半径的收敛曲线, 其变化趋势与位置估计方差完全同步, 半径从初始34.9像素收缩至稳态20.9像素, 对应搜索面积降幅达64%。搜索范围的压缩既缓解了多目标场景下候选匹配的二义性, 也有效缩减了算法计算开销。

图8(h)为多特征动态权重的演化结果。该场景下目标面积与长宽比保持稳定, 对应权重始终平稳, 位置权重随滤波收敛小幅上升。全程权重无剧烈跳变, 验证了式(32)~式(34)在特征可靠工况下的稳定性。

图8(i)验证了异常惩罚机制的靶向性。在

目标特征无突变的工况下,三类匹配的代价均低于置信度阈值,惩罚因子未对正常匹配施加额外代价,机制无误触发。

图8(j)为最终关联输出结果。该目标在全部10帧中均被正确关联,目标身份保持稳定,身份切换次数IDS=0。




图8 算法全链路中间结果演示(4目标典型场景)。(a)10帧最大值投影,叠加4目标全帧轨迹;(b)10帧顶帽变换最大值投影,叠加4目标轨迹;(c)中值帧恒星模板(10帧中值二值图,滤除面积 <9 散粒噪声);(d)恒星抑制后动目标10帧最大值投影,叠加典型目标全帧位置;(e)典型目标卡尔曼估计轨迹与门控椭圆收缩过程;(f)位置估计方差 P_{xx} 收敛曲线;(g)门控半径 R 收敛曲线;(h)10帧动态权重演化曲线;(i)异常惩罚机制验证;(j)最终关联输出结果。

Fig. 8 Intermediate results of the full algorithm pipeline (4-target typical scenario). (a) 10-frame max projection with 4-target trajectories. (b) 10-frame top-hat max projection with 4-target trajectories. (c) Median-frame star template (10-frame median binary image, noise with area < 9 filtered). (d) 10-frame cleaned moving-target max projection with full-frame positions of a typical target. (e) Kalman estimation trajectory and gate ellipsoid contraction of a typical target. (f) Convergence curve of position estimation variance P_{xx} . (g) Convergence curve of gate radius R . (h) 10-frame evolution curve of dynamic weights. (i) Verification of anomaly penalty mechanism. (j) Final association output result.

4 实验结果和分析

4.1 实验环境

实验环境配置如下: Intel Core i7-12700H@2.30GHz, 16 GB RAM, 操作系统为 Windows 11。算法基于 Python 3.10 编程实现, 使用 OpenCV 4.8 和 SciPy 1.9 库支撑相关计算。

4.2 实验数据

本文使用的数据为仿真图像数据, 共设计5种典型场景, 每种场景50组, 每组仿真10帧 500×500 像素图像(10帧序列可覆盖目标初始化、稳态跟踪、运动突变等典型工况, 能够充分验证帧间关联算法的性能, 50组独立重复用于评估统计稳定性), 包括不同目标数量、不同运动模式与不同信噪比等场景, 5种场景具体为: S1多速度目标场景——4个目标, $SNR = 3$, 帧间位移覆

盖1.5像素/帧至30像素/帧, 包含慢速、中速和高速三种典型运动模式, 用于验证算法对宽速度范围目标的适应能力; S2目标密集逼近场景——4个目标, $SNR = 3$, 其中3个(T_0 、 T_1 、 T_2)在图像中心区域形成最小间距约12~28像素的三角逼近构型, T_3 远离密集区域, 用于验证算法在目标空间接近时的关联准确性和身份保持能力; S3多机制混合场景——6个目标, $SNR = 3$, 同时包含低速(小于2像素/帧)、高速(大于25像素/帧)、目标轨迹交叉和正常匀速等复合运动模式, 用于验证算法在多种运动特征共存时的综合适应能力; S4高密度目标场景——12个目标, $SNR = 3$, 集中在 200×200 像素区域内, 各方向速度5~15像素/帧, 用于验证算法在多目标条件下的匹配精度和计算效率; S5低信噪比场景——6个目标, $SNR = 2$, 目标尺寸在仿真过程中波动 $\pm 40\%$,

用于验证算法在目标成像质量不稳定条件下的关联鲁棒性。

4.3 评价指标

本文采用多目标跟踪领域广泛使用的 CLEARMOT 评价指标体系^[27]对算法进行定量评估,各指标具体定义为:

(1)多目标跟踪准确率(MOTA):综合考量三个错误来源:漏检(FN)、虚警(FP)和身份切换(IDS)的累加影响,具体如公式(36)所示:

$$MOTA = \frac{\sum_t (FN_t + FP_t + IDS_t)}{1 - \sum_t G_t} \times 100\%, \quad (36)$$

其中 G_t 为第 t 帧的真实目标总数, FN_t 、 FP_t 和 IDS_t 分别为第 t 帧的漏检数、虚警数和身份切换次数。MOTA 反映了算法在检测和关联两个层面的综合精度, MOTA 值越高代表算法检测效果越好。

(2)IDF1 分数(IDF1):从身份保持的角度评估跟踪质量,综合考量正确识别的跟踪(IDTP)、错误识别的跟踪(IDFP)和漏识别的跟踪(ID-FN),具体如公式(37)所示:

$$IDF1 = \frac{2 \cdot IDTP}{2 \cdot IDTP + IDFP + IDFN} \times 100\%. \quad (37)$$

(3)身份切换次数(IDS):统计在整个跟踪过程中预测轨迹所关联的真实身份发生变化的总次数。IDS 越低表示身份一致性越好。

4.4 算法效果验证

4.4.1 参数设置

各对比算法的参数配置为:(1)预处理参数:形态学膨胀核尺寸 $d=49$ 像素,腐蚀核尺寸 $e=51$ 像素;自适应阈值系数 $\alpha=0.5$ 。(2)卡尔曼滤波参数:过程噪声标准差 $\sigma_q=0.03$,观测噪声标准差 $\sigma_r=3$;初始协方差矩阵 $P_0=\text{diag}(25, 25, 4, 4)$ 。(3)马氏门控参数:门控阈值 $g=5.99$ 对应 χ^2 的 95% 分位数,即真实测量落在该马氏椭圆内的概率为 95%。(4)动态权重参数:初始权重设为 $w_p=0.5$ (位置)、 $w_a=0.3$ (面积)、 $w_r=0.2$ (长宽比);不确定性缩放因子 $\lambda_p=0.1$ 、 $\lambda_a=0.2$ 、 $\lambda_r=0.5$;可靠性阈值 $\tau_{rel}=0.5$ 。(5)异常惩罚参数:面积变化率阈值 $\tau_a=0.5$,面积惩罚因子 $\gamma_a=1.5$;长宽比变化率阈值 $\tau_r=$

0.3,长宽比惩罚因子 $\gamma_r=1.8$;低可靠性惩罚因子 $\gamma_{low}=1.2$ 。(6)匹配与轨迹管理参数:匹配代价置信度阈值 $\tau_c=0.5$;轨迹确认帧数阈值 $N_{confirm}=3$,最大连续丢失帧数阈值 $N_{miss}=1$,轨迹终止帧数阈值 $N_{term}=3$ 。传统匈牙利算法:检测面积阈值 9 像素,匹配距离阈值 50 像素,轨迹连续性阈值 3 帧,特征权重固定为位置 0.5、面积 0.3、长宽比 0.2。PPMHT 算法:速度下限 $v_{min}=2$ 像素/帧,速度上限 $v_{max}=25$ 像素/帧,角度判别阈值 45° ,搜索容差 $\sigma=3$ 像素。NN 算法:检测面积阈值 9 像素,匹配距离阈值 50 像素,轨迹连续性阈值 3 帧。JPDA 算法:检测面积阈值 9 像素,轨迹连续性阈值 3 帧,关联假设采用全枚举方式。所有对比算法均使用与本文算法相同的预处理输出作为输入。

4.4.2 定性分析

图 9 展示了一组典型实验三种代表性场景下本文算法、PPMHT 算法和 NN 算法的轨迹检测结果。图中采用不同颜色矩形框标注各算法检测到的目标位置及身份 ID,每条轨迹仅标注一次标签。

场景一:多速度目标场景(S1),含有 4 个空间目标, T0 以约 1.5 像素/帧缓慢移动, T1 以 30 像素/帧高速运动, T2 和 T3 分别以 10 和 17 像素/帧正常运动,覆盖较宽的速度动态范围。本文算法完整检测全部 4 个目标(40 个检测点), T0~T3 均以完整 10 帧序列连续检出,4 组彩色检测框覆盖全部目标运动区域,无轨迹断裂,身份一致。PPMHT 算法仅检出 T2 和 T3(20 个检测点):T0 因帧间位移 1.5 像素/帧低于其固定速度下限 $v_{min}=2$,在环形搜索第一阶段未被纳入候选;T1 因帧间位移 30 像素/帧超过速度上限 $v_{max}=25$,同样未被关联,目标漏检率达 50%。NN 算法完整检测全部 4 个目标,在目标空间分离良好的条件下贪心最近邻可有效完成逐帧关联。该场景结果表明本文算法的马氏距离门控能够自适应覆盖 1.5~30 像素/帧的宽速度范围,而基于固定速度阈值的 PPMHT 方法在此条件下存在检测盲区。

场景二:目标密集逼近场景(S2),含有 4 个空间目标, T0、T1 和 T2 在帧 4-5 期间于图像中心形成三角逼近构型(最小间距 12~28 像素), T3 远离密集区域作为对照。本文算法完整检测全




图9 各场景轨迹检测结果对比。(a)S1多速度目标-本文算法;(b)S1多速度目标-PPMHT算法;(c)S1多速度目标-NN算法;(d)S2目标密集逼近-本文算法;(e)S2目标密集逼近-PPMHT算法;(f)S2目标密集逼近-NN算法;(g)S3多机制混合-本文算法;(h)S3多机制混合-PPMHT算法;(i)S3多机制混合-NN算法。

Fig.9 Comparison of trajectory detection results across scenarios. (a) S1 Multi-speed - Proposed; (b) S1 Multi-speed - PPMHT; (c) S1 Multi-speed - NN; (d) S2 Dense approach - Proposed; (e) S2 Dense approach - PPMHT; (f) S2 Dense approach - NN; (g) S3 Mixed motion - Proposed; (h) S3 Mixed motion - PPMHT; (i) S3 Mixed motion - NN.

部4个目标(40个检测点),卡尔曼预测在三角逼近区为三个目标提供了独立准确的运动位置估计,全局匈牙利优化确保整体关联方案最优。PPMHT算法完整检测全部4个目标,所有目标速度均处于其参数范围内且角度变化小于 45° 。NN算法检出4个目标但轨迹断裂为7段:贪心最近邻逐一分配检测的方式使其在密集区域产生级联误匹配,T0、T1和T2各在帧4处断裂为两段并分配新ID。图中7种不同颜色的检测断裂轨迹在三角逼近区交错分布,与本文算法的4组完整彩色框形成对比,表明全局匈牙利优化相较于贪心策略在密集目标条件下具有更好的关联完整性。

场景三:多机制混合场景(S3),含有6个空间目标,同时包含慢速T0(1.5像素/帧)、高速T1(28像素/帧)、T2与T3在帧4~5精确交叉换位,以及正常匀速的T4和T5。本文算法检出全部6个目标(60个检测点),在全速度范围和交叉换位区域均保持了正确的身份关联。PPMHT算法仅检出T4和T5(20个检测点):T0、T1、T2和T3共4个目标因帧间位移超出其参数范围而未被关联,图中上述目标运动区域检测框缺失。NN算法检出6个目标但轨迹断裂为8段:T2和T3在帧4~5交叉处因贪心匹配缺乏运动预测,两条轨迹各断裂为两段并出现身份混淆,图中交

叉区域出现4种不同颜色的断裂轨迹。

三组可视化对比结果表明:在S1多速度目标场景中,PPMHT因固定速度阈值仅检出50%目标,本文算法和NN均完整检测全部4个目标;在S2目标密集逼近场景中,NN因贪心最近邻的逐次分配方式在密集区产生级联轨迹断裂为7段,本文算法和PPMHT均保持轨迹完整;在S3多机制混合场景中,PPMHT算法仅检出6个目标中的2个(受限于速度阈值),NN算法检测轨迹断裂为7段(受限于交叉区贪心误匹配),而本文算法完整检出全部6个目标且保持身份一致。三组场景的结果验证了本文算法在宽速度范围适应、密集目标关联和复合运动模式下的综合检测性能优势。

4.4.3 定量分析

为了进一步验证算法的有效性,在5种场景下使用本文算法、传统匈牙利、PPMHT、最近邻和JPDA算法进行50组独立重复实验,最终结果以50组均值±标准差呈现,表6~8分别给出了MOTA、IDF1/IDS和每帧耗时的场景级对比。

4.4.3.1 MOTA分析

5种测试场景的平均多目标跟踪准确率(MOTA)由高到低依次为:本文算法(88.3%)、JPDA算法(85.9%)、传统匈牙利算法(82.4%)、NN算法(82.3%)、PPMHT算法(64.6%)。本文算法在全局最优匹配框架下,结合自适应门控约束与多特征动态权重机制,综合跟踪精度最优。

在S1多速度目标与S3多机制混合场景中,PPMHT算法因采用固定速度阈值,对低速与超高速目标存在识别盲区,大量目标无法进入候选匹配集,导致MOTA显著低于其他算法。在S2目标密集逼近与S4高密度目标场景中,目标空间分布集中、特征区分度低,传统匈牙利算法与NN算法易受局部最优或单一特征限制产生误匹配,JPDA算法仅依赖位置特征且无运动预测,密集场景下概率枚举易产生关联歧义,而本文算法借助多特征融合与动态权重提升了特征判别能力,精度更优。在S5低信噪比场景中,目标尺寸波动导致面积等特征可靠性下降,本文算法通过动态权重自动降低不稳定特征的贡献,使匹配决策向高可靠性特征回归,MOTA显著高于传统

匈牙利算法。

实验结果表明,本文算法在宽速度范围适应、密集目标关联及低信噪比鲁棒性方面均具备明显优势,能够在复杂星图场景下保持稳定的检测精度。

4.4.3.2 IDF1/IDS分析

5种场景的平均IDF1由高到低依次为:本文算法(65.8%)、JPDA算法(62.4%)、传统匈牙利算法(56.3%)、NN算法(55.8%)、PPMHT算法(50.0%);平均身份切换次数(IDS)由低到高依次为:本文算法(1.6次)、JPDA算法(1.7次)、PPMHT算法(1.8次)、传统匈牙利算法(3.9次)、NN算法(5.2次)。IDF1衡量算法正确识别并维持身份的轨迹比例,IDS统计身份切换总次数,二者结合可客观评价身份保持性能。由于IDS仅反映身份切换次数,无法体现跟踪完整度,若算法大量漏检目标(IDF1低),会因有效匹配对不足导致IDS偏低,此时低IDS并不代表身份保持能力强。

在S1多速度目标场景中,各算法目标分布稀疏,身份混淆概率低,IDF1整体偏高、IDS偏低。在S2密集逼近与S4高密度目标场景中,NN算法与传统匈牙利算法因贪心匹配或固定权重限制,易出现级联误匹配与身份跳变,IDS显著高于本文算法。在S3多机制混合场景中,轨迹交叉使位置特征对称性增强,仅依赖位置信息的算法易发生身份交换,本文算法借助卡尔曼运动预测打破代价对称性,有效维持身份一致。在S5低信噪比场景中,目标尺寸波动易造成代价扰动,本文算法通过动态权重降低不可靠特征贡献,并结合异常惩罚抑制突变匹配,身份一致性优于对比算法。

实验结果表明,本文算法在密集目标、轨迹交叉与低信噪比等复杂工况下,能够显著减少身份切换、提升身份保持稳定性,综合性能最优。

4.4.3.3 耗时分析

五组场景的单帧平均运算耗时排序为:PPMHT(239.8 ms) > JPDA(223.1 ms) > 本文算法(41.2 ms) > 传统匈牙利算法(32.1 ms) > NN算法(18.1 ms)。

各算法的计算复杂度差异在S4高密度目标场景中表现得最为显著。JPDA算法在其余场景中

单帧耗时约 150 ms,在 S4 场景中增至 503.1 ms,增幅超过三倍。其原因在于该算法需要枚举全部可行关联假设,假设空间规模会随目标数量呈现超线性增长。PPMHT 在 S4 场景下单帧耗时为 402.7 ms,约为常规场景的两倍,逐目标速度预测与多阶段搜索随目标数量增加,产生大量冗余候选评估。上述两种算法均无法满足实时处理的应用要求。

本文算法五场景平均耗时为 41.2 ms/帧,即便在计算压力最大的 S4 场景中,单帧耗时也仅

为 59.4 ms,满足系统实时性处理要求。马氏距离门控将全局候选匹配约束至预测椭圆内,显著降低计算量。在 S4 场景中,本文算法耗时仅为 JPDA 的 11.8%、PPMHT 的 14.8%,同时跟踪精度与身份一致性指标均优于后两者。

综合上述分析,本文算法以 41.2 ms 的运算开销,实现了最优综合跟踪性能,对应 MOTA 均值 88.3%、IDF1 均值 65.8%、IDS 均值 1.6,在跟踪精度、身份稳定性与实时计算能力三者之间实现了最优平衡。

表 6 各场景 MOTA 对比

Tab. 6 Comparison of MOTA in different scenarios

算法	S1/%	S2/%	S3/%	S4/%	S5/%	平均/%
传统匈牙利	89.4±1.3	87.2±1.4	88.2±1.2	75.6±1.3	71.8±1.3	82.4
PPMHT	58.1±2.2	88.2±2.6	33.2±2.6	69.6±3.0	73.8±2.6	64.6
NN	90.2±2.0	89.2±1.4	88.7±1.5	65.1±1.4	78.3±1.4	82.3
JPDA	90.3±1.2	92.3±1.0	89.9±0.9	80.2±1.3	77.0±1.1	85.9
本文方法	90.7±1.2	92.7±1.1	91.6±1.3	85.0±1.2	81.5±1.1	88.3

表 7 各场景 IDS 与 IDF1 (%) 对比

Tab. 7 Comparison of IDS and IDF1 (%) in various scenarios

算法	S1		S2		S3		S4		S5		均值 IDF1/ %	均值 IDS
	IDF1/ %	IDS	IDF1/ %	IDS	IDF1/ %	IDS	IDF1/ %	IDS	IDF1/ %	IDS		
传统匈牙利	67.2	0.4	55.8	2.5	55.7	5.1	50.8	7.7	52.2	3.7	56.3	3.9
	±1.5	±0.5	±1.3	±1.7	±1.9	±2.3	±1.6	±2.6	±1.7	±1.9		
PPMHT	57.1	0.6	61.8	2.1	29.1	0.6	48.0	4.3	53.9	1.4	50	1.8
	±2.9	±0.6	±3.1	±1.1	±2.9	±0.6	±2.5	±1.9	±3.3	±1.1		
NN	67.5	0.7	57.2	3.2	56.1	5.0	42.3	12.6	56.0	4.3	55.8	5.2
	±2.1	±0.8	±1.9	±1.8	±1.8	±2.1	±2.1	±2.7	±1.6	±1.8		
JPDA	67.7	0.4	68.1	0.9	64.1	1.6	57.5	3.2	54.7	2.5	62.4	1.7
	±1.4	±0.5	±1.5	±0.8	±1.7	±1.0	±1.3	±1.6	±1.5	±1.2		
本文方法	68.1	0.3	69.0	0.8	66.1	1.9	63.9	3.2	62.1	1.9	65.8	1.6
	±1.5	±0.4	±1.3	±0.6	±1.1	±1.1	±1.3	±1.6	±1.2	±1.1		

表 8 各场景每帧耗时对比

Tab. 8 Comparison of time consumption per frame in various scenarios

算法	S1/ms	S2/ms	S3/ms	S4/ms	S5/ms	平均/ms
传统匈牙利	20.3±1.0	20.5±1.0	21.1±1.0	79.0±1.2	19.8±1.0	32.1
PPMHT	198.6±2.9	198.7±2.9	201.7±2.4	402.7±2.9	197.4±2.5	239.8
NN	15.2±0.7	15.6±0.7	16.1±0.6	28.7±0.8	14.8±0.6	18.1
JPDA	152.5±3.0	150.4±3.7	157.4±3.3	503.1±3.8	152.1±2.8	223.1
本文方法	36.1±1.1	37.0±1.6	37.7±1.3	59.4±1.6	35.9±1.3	41.2

4.4.4 消融实验

为量化分析各改进模块的独立贡献,本文设计渐进式消融实验。以基础匈牙利算法为基线,依次加入卡尔曼预测、马氏门控、多特征动态权重与异常惩罚模块,选取S3多机制混合、S4高密度目标两个典型场景开展50组独立重复测试,结果如表8所示。

(1)卡尔曼滤波模块对跟踪性能的增益最为突出,在S3、S4场景中MOTA分别提升8.8、8.5个百分点,IDS分别降低20次、23次。该模块以预测位置替代静态观测位置,可有效缓解轨迹交叉带来的匹配歧义。

(2)马氏门控可同步提升MOTA与IDF1, MOTA提升6.2~6.5个百分点, IDF1提升5.0~6.5个百分点。自适应搜索半径替代固定速度阈值,扩大了有效匹配范围,进一步降低

IDS15~18次。

(3)多特征动态权重在S4高密度场景中对IDS优化明显,IDS降低15次。密集目标对特征区分度要求更高,动态权重可依据特征稳定性自适应分配贡献,强化身份区分能力。

(4)异常惩罚模块对MOTA的提升幅度较小(0.8~1.2个百分点),但作为鲁棒性保障机制,可抑制面积突变等异常工况带来的代价扰动,提升算法运行稳定性。

四模块协同显著提升综合性能:S3场景MOTA由73.0%提升至91.6%(+18.6个百分点),IDS由50次降至2次(降幅96.0%);S4场景MOTA由66.0%提升至85.0%(+19.0个百分点),IDS由63次降至3次(降幅95.2%)。各模块均带来正向增益,验证了本文递进式改进框架的合理性与有效性。

表9 消融实验结果(S3和S4场景)

Tab.9 Results of ablation experiments on S3 (multi-mechanism mixed) and S4 (high-density targets)

算法配置	S3多机制混合(6目标)			S4高密度目标(12目标)		
	MOTA/%	IDF1/%	IDS	MOTA/%	IDF1/%	IDS
基础匈牙利	73.0±2.8	48.0±3.2	50±7.1	66.0±3.0	42.5±3.5	63±7.9
+卡尔曼预测	81.8±2.2	56.5±2.5	30±5.5	74.5±2.4	51.0±2.8	40±6.3
+马氏门控	88.0±1.6	61.5±2.0	15±3.9	81.0±1.8	57.5±2.2	22±4.7
+多特征动态权重	90.4±1.4	64.8±1.6	5±2.2	84.2±1.5	62.0±1.8	7±2.6
+异常惩罚(完整算法)	91.6±1.3	66.1±1.1	2±1.4	85.0±1.2	63.9±1.3	3±1.7

5 结 论

本文针对星图空间目标检测中传统匈牙利算法存在的缺乏运动预测、全局搜索冗余、特征单一、权重固定等问题,提出一种基于多特征优化的匈牙利匹配算法。主要贡献包括:(1)引入卡尔曼滤波实现目标运动预测,以预测位置构建匹配代价,有效缓解轨迹交叉带来的匹配歧义。(2)基于卡尔曼协方差构建马氏距离门控,以自适应搜索半径替代固定速度阈值,压缩匹配空间并提升宽速度适应能力。(3)提出多特征动态权重机制,将位置、面积、长宽比自适应融合,提升密集场景下的目标区分度与身份一致性。(4)加入异常惩罚机制,抑制面积与长宽比突变造成的

误匹配,增强算法鲁棒性。在5类典型仿真场景下的实验结果表明:本文算法平均MOTA达88.3%,平均IDF1为65.8%,平均IDS仅1.6次,平均耗时41.2 ms/帧,满足实时性要求。各项指标均优于传统匈牙利、PPMHT、NN及JP-DA算法。消融实验验证了各模块的正向增益,四模块联合使S3、S4场景MOTA分别提升18.6、19.0个百分点,IDS降幅超95%。本文算法在多速度共存、目标密集、轨迹交叉及低信噪比等复杂工况下均表现出优异的鲁棒性与稳定性,可用于复杂星图背景下空间目标的可靠检测与跟踪。未来将进一步结合深度学习特征与传统匹配框架^[8,28],提升极低信噪比条件下的检测性能。

参 考 文 献:

- [1] Turyshev S G. Orbital debris in Earth orbit: Operations, stability, control, and market formation[EB/OL]. *arXiv preprint*, 2026, arXiv:2603.23552.
- [2] Baker-McEvelly Brian, Bhadauria Surabhi, Canales David, *et al.* A comprehensive review on Cislunar expansion and space domain awareness[J]. *Progress in Aerospace Sciences*, 2024, 147: 101019.
- [3] 牛海鹏, 颜昌翔, 王一霖, 等. 基于快速局部对比度和目标特征的星图弱小目标检测算法[J]. *液晶与显示*, 2024, 39(1): 69-78.
NIU H P, YAN C X, WANG Y L, *et al.* Star map spatial target detection method based on fast local contrast and target features[J]. *Chinese Journal of Liquid Crystals and Displays*, 2024, 39(1): 69-78. (in Chinese)
- [4] Lan X Q, Xin B Q, Wang B S, *et al.* Space object detection using multi-frame temporal trajectory completion method [C] 5th International Symposium on Artificial Intelligence and Big Data (AIBDF), 2025. arXiv:2510.19220.
- [5] Emami P, Pardalos P M, Elefteriadou L, *et al.* Machine learning methods for data association in multi-object tracking [J]. *ACM Computing Surveys*, 2021, 53(4): 1-34.
- [6] Su Y Q, Chen X, Liu G R, *et al.* Implementation of real-time space target detection and tracking algorithm for space-based surveillance[J]. *Remote Sensing*, 2023, 15(12): 3156.
- [7] Zhu R, Fu Q, Wen G Y, *et al.* An improved multi-target tracking method for space-based optoelectronic systems [J]. *Remote Sensing*, 2024, 16(15): 2847-2869.
- [8] Zhu R, Leng J S, Fu Q, *et al.* Transformer-based target tracking algorithm for space-based optoelectronic detection [J]. *Frontiers in Physics*, 2023, 11: 1266927.
- [9] Zhang Y F, Sun P Z, Jiang Y, *et al.* ByteTrack: Multi-object tracking by associating every detection box [C] ECCV, 2022: 1-21.
- [10] Fortmann T E, Bar-Shalom Y, Scheffe M. Sonar tracking of multiple targets using joint probabilistic data association[J]. *IEEE Journal of Oceanic Engineering*, 1983, 8(3): 173-184.
- [11] 张薇, 席红霞, 宋崇金. 基于位置预测的多级假设检验空间目标检测方法[J]. *制造业自动化*, 2023, 45(8): 199-203.
ZHANG W, XI H X, SONG C J. Spatial target detection method based on multi-level hypothesis testing with position prediction[J]. *Manufacturing Automation*, 2023, 45(8): 199-203. (in Chinese)
- [12] Gaetjens H X, Davey S J, Arulampalam S, *et al.* Histogram-PMHT for fluctuating target models[J]. *IET Radar, Sonar & Navigation*, 2017, 11(8): 1292-1301.
- [13] 张奕群, 尹立凡, 王硕, 等. 一种改进的直方图概率多假设多目标跟踪方法[J]. *航空学报*, 2021, 42(11): 115-128.
ZHANG Y Q, YIN L F, WANG S, *et al.* An improved histogram probabilistic multi-hypothesis multi-target tracking method[J]. *Acta Aeronautica et Astronautica Sinica*, 2021, 42(11): 115-128. (in Chinese)
- [14] Kuhn H W. The Hungarian method for the assignment problem[J]. *Naval Research Logistics Quarterly*, 1955, 2 (1-2): 83-97.
- [15] Bewley A, Ge Z, Ott L, *et al.* Simple online and realtime tracking[C] IEEE ICIP, 2016: 3464-3468.
- [16] Wojke N, Bewley A, Paulus D. Simple online and realtime tracking with a deep association metric[C] IEEE ICIP, 2017: 3645-3649.
- [17] Kalman R E. A new approach to linear filtering and prediction problems[J]. *Journal of Basic Engineering*, 1960, 82 (1): 35-45.
- [18] Chen L, Ai H, Zhuang Z, *et al.* Real-time multiple people tracking with deeply learned candidate selection and person re-identification[C] IEEE ICME, 2018: 1-6.
- [19] Munkres J. Algorithms for the assignment and transportation problems[J]. *Journal of the Society for Industrial and Applied Mathematics*, 1957, 5(1): 32-38.
- [20] Liu M, Niu J W, Liu Y. UKF-MOT: An unscented Kalman filter-based 3D multi-object tracker [J]. *CAAI Transactions on Intelligence Technology*, 2024, 9(4): 1031-1041.

- [21] Yi K F, Luo K, Luo X L, *et al.* UCMCTrack: Multi-object tracking with uniform camera motion compensation [C] AAAI, 2024, 38(7): 6702-6710.
- [22] 奚晓梁, 周晓东. 基于小区域滤波的快速星图目标检测方法[J]. 光电工程, 2010, 37(3): 35-40.
XI X L, ZHOU X D. Fast star map target detection method based on small region filtering[J]. *Opto-Electronic Engineering*, 2010, 37(3): 35-40. (in Chinese)
- [23] 刘颖, 孙海江, 赵勇先. 基于注意力机制的复杂背景下红外弱小目标检测方法研究[J]. 液晶与显示, 2023, 38(11): 1455-1467.
LIU Y, SUN H J, ZHAO Y X. Infrared dim small target detection method under complex background based on attention mechanism[J]. *Chinese Journal of Liquid Crystals and Displays*, 2023, 38(11): 1455-1467. (in Chinese)
- [24] Li X, Wang K J, Wang W, *et al.* A multiple object tracking method using Kalman filter[C] IEEE ICIA, 2010: 1862-1866.
- [25] 桑海瑞, 郑然, 程会艳, 等. 基于多特征融合的空间多目标在轨检测方法[J]. 空间控制技术与应用, 2025, 51(1): 105-114.
SANG H R, ZHENG R, CHENG H Y, *et al.* A method of space multi-targets on-orbit detection based on multi-feature fusion[J]. *Aerospace Control and Application*, 2025, 51(1): 105-114. (in Chinese)
- [26] Hossain M A, Hossain M I, Hossain M D, *et al.* DFC-D: A dynamic weight-based multiple features combination for real-time moving object detection[J]. *Multimedia Tools and Applications*, 2022, 81: 28165-28188.
- [27] Bernardin K, Stiefelhagen R. Evaluating multiple object tracking performance: the CLEAR MOT metrics [J]. *EURASIP Journal on Image and Video Processing*, 2008, 2008: 1-10.
- [28] 刘时, 朱明. 基于 Swin-Transformer 改进的目标跟踪算法[J]. 液晶与显示, 2024, 39(11): 1721-1732.
LIU S, ZHU M. Improved target tracking algorithm based on Swin-Transformer[J]. *Chinese Journal of Liquid Crystals and Displays*, 2024, 39(11): 1721-1732. (in Chinese)

作者简介:



牛海鹏,男,硕士,研究实习员,2023年于中国科学院大学获得硕士学位,主要从事空间目标检测方面的研究。
E-mail: niuhaipeng@ciomp. ac. cn



黄亚伟,男,博士,工程师,2021年于中国科学院大学获得博士学位,主要从事空间光学载荷研制及图像处理等方面研究。E-mail: huangyawei@ciomp. ac. cn