

基于 GLMB 滤波的复杂场景下红外弱小目标自适应跟踪算法

蔡如华¹, 周健斌¹, 吴孙勇^{1,2}, 郑翔飞¹

(1. 桂林电子科技大学 数学与计算科学学院, 广西 桂林 541004;

2. 广西密码学与信息安全重点实验室, 广西 桂林 541004)

摘要: 针对红外弱小目标在复杂场景下受到漏检和杂波影响, 导致跟踪不连续甚至失效的问题, 本文提出一种红外弱小目标自适应跟踪算法。在预处理阶段, 为了减少不必要的计算, 首先定义一种衡量图像复杂度的算法。然后该算法通过计算红外图像多个特征得到场景复杂度来确认场景类型, 再根据场景类型选取对应的检测算法提取目标候选位置、灰度以及局部直方图等特征建立对应的量测模型与似然函数。在目标跟踪阶段, 为了自适应地匹配广义标签多伯努利 (Generalized Labeled Multi-Bernoulli, GLMB) 滤波器的滤波参数, 在 GLMB 的基础上提出一种适应视频图像的新生算法进行航迹起始; 针对红外图像序列目标检测概率未知的情况, 将未知检测概率的基数化概率假设密度 (Cardinality Probability Hypothesis Density, CPHD) 滤波器集成到 GLMB 中实时估计目标检测概率以提升跟踪精度。仿真结果表明, 所提出算法能有效地排除量测漏检和虚警的干扰, 跟踪不同红外复杂场景下的弱小目标。

关键词: 红外弱小目标; 广义标签多伯努利滤波; 自适应跟踪; 复杂场景

中图分类号: TN219 文献标识码: A 文章编号: 1001-8891(2024)07-0743-11

An Adaptive Tracking Algorithm for Infrared Dim Small Targets in Complex Scenes Based on GLMB Filter

CAI Ruhua¹, ZHOU Jianbin¹, WU Sunyong^{1,2}, ZHENG Xiangfei¹

(1. Mathematics and Computer Science College of Guilin University of Electronic Technology, Guilin 541004, China;

2. Guangxi Key Laboratory of Cryptography and Information Security, Guilin 541004, China)

Abstract: In this study, we propose a robust adaptive tracking algorithm for infrared dim objects that addresses the problem of tracking discontinuities and failures caused by missed detections and clutter in complex scenes. In the pre-processing stage, an algorithm that measures the image complexity eliminates unnecessary calculations. This algorithm determines the scene type by calculating multiple features of the infrared image to obtain the scene complexity, and then selects the corresponding detection algorithm to extract the target candidate location, grayscale and local histogram features. Subsequently, a measurement model and likelihood function are established based on the scene type. In the tracking stage, to flexibly match the filtering parameters of the generalized labeled multi-Bernoulli (GLMB) filter, an adaptive algorithm suitable for video image distribution is proposed for track initiation. Aiming at the unknown detection probability of an infrared image sequence, a cardinality probability hypothesis density (CPHD) filter was integrated into the GLMB to estimate the detection probability of the target in real time, thereby improving the accuracy of the tracker. The simulation results show that the proposed algorithm can effectively track small infrared objects in different complex scenarios.

Key words: infrared dim objects, GLMB, adaptive tracking, complex scenario

0 引言

红外弱小目标跟踪的目的是从包含噪声污染、

收稿日期: 2023-02-23; 修订日期: 2023-05-25.

作者简介: 蔡如华 (1971-), 男, 副教授, 硕士, 主要从事目标跟踪方面的研究。E-mail: 934019492@qq.com。

通信作者: 吴孙勇 (1981-), 男, 教授, 博士, 主要从事目标跟踪方面的研究。E-mail: 53505713@qq.com。

基金项目: 桂林电子科技大学研究生教育创新计划资助项目 (2022YCX145); 国家自然科学基金 (地区科学基金项目, 62263007)。

虚警与漏检等不确定性的红外测量数据中估计感兴趣目标的轨迹信息。红外小目标具有隐蔽性强、威胁性大、难以防御等特点^[1]。因此,红外弱小目标跟踪的研究在侦察、制导以及预警等军用领域具有重要意义^[2]。红外弱小目标跟踪(如远空无人机)的难点在于:①红外视频图像信噪比、对比度低,动态范围窄,目标存在场景复杂多变,目标不易发现;②弱小目标本身占用像素量少,缺乏纹理、颜色以及形状等特征信息,并且强度与背景接近时易产生漏检和虚警;③当传感器与目标机动,图像背景由静态转变为动态时,目标背景变化率大,目标轨迹呈非线性。

目标检测方面,基于单帧图像的红外弱小目标检测算法受到了广泛关注。为了有效抑制噪声,基于人类视觉的检测算法如多尺度的局部对比度测量(Local Contrast Measure, LCM)^[3]以及多尺度绝对平均灰度差(Multi-Scale absolute average gray difference, MSAAGD)算法^[4]通过给定多个边界框来检测场景中大小未知的目标,并且能抑制场景中的杂波。文献[5]则基于目标边界框模型,通过局部图像块中值以及极值确定分割弱小目标的最小阈值,与之前的算法相比具有更高的精度和更快的运算速度。然而当目标掩盖于杂波时,在图像中不具有显著性,强度也可能弱于杂波,此时需要通过目标跟踪算法来处理检测算法在检测过程中造成的漏检和虚警。

在目标跟踪方面,根据跟踪与检测的顺序分为检测前跟踪(Track Before Detect, TBD)和跟踪前检测(Detect Before Track, DBT)。对于前者,薛秋条等人基于随机有限集(Random Finite Set, RFS)^[6]使用跳跃马尔可夫系统的概率假设密度(Probability Hypothesis Density, PHD)滤波^[7]来跟踪红外场景中的机动目标, Kim D Y 等人^[8]则在此基础上采用精度更高的GLMB滤波器对红外弱小目标进行跟踪。TBD跟踪模式保留了图像所有的信息,在检测红外弱小目标时能减少目标信息的损失。但当目标强度小于掩盖其的复杂背景并且幅值波动时,其跟踪效率会降低。另一方面,在计算目标点与观测值的似然函数时计算量巨大,不利于实时跟踪。在DBT跟踪模式上,为了适应复杂多变的弱小目标跟踪场景,文献[9]提取感兴趣区域(Region of Interest, ROI)的目标灰度、对比度以及运动信息作为量测,再利用卡尔曼滤波作为目标预测手段,最后融合不同量测对应的权重来进行鲁棒跟踪。文献[10]则是使用支持向量机(Support Vector Machine, SVM)获取感

兴趣的红外弱小目标候选区域,再通过伯努利滤波跟踪红外弱小目标,最后将长度较短的航迹识别为杂波,提取长度最长的轨迹作为目标轨迹。但卡尔曼滤波和伯努利滤波作为单目标跟踪器无法处理数据关联更为复杂的多目标跟踪场景。董小虎等人^[11]通过图像灰度一致性对跟踪场景进行分类,根据跟踪场景选用不同的检测器获取目标量测,最后用带标签的PHD滤波跟踪多个红外弱小目标。然而PHD滤波由于泊松RFS的假设,其均值等于方差,在目标数量增长时,对目标数量的估计效果下降。

为了自适应地联合跟踪估计复杂场景下的红外弱小目标的位置与数量,本文工作如下:①根据图像的信息熵、图像灰度离散系数以及峰值信噪比等多个统计量确认跟踪场景,自适应地选择检测器。首先利用图像的信息熵、离散系数等特征对图片进行加权分类,再根据图像的复杂程度分别采用方向梯度直方图(Histogram of Oriented Gradient, HOG)特征^[12]显著算法以及小边界框滤波算法检测弱小目标位置;②选取目标位置、灰度以及局部模板直方图作为量测,并根据这3类特征分别建立似然函数,增加跟踪的稳定性;③将未知检测概率的CPHD滤波器与GLMB结合,实时估计检测概率,并结合一种适用于图像的自适应新生算法完成航迹起始以达到稳定跟踪的目的。

1 红外弱小目标的数学模型

1.1 红外弱小目标定义及表示

根据国际光学工程学会(SPIE)的定义:红外弱小目标尺寸占据画面小于15%,大小约为2×2~9×9个像素^[13]。包含弱小目标的红外图像中任意像素灰度值 $F(x,y)$ 定义为:

$$F(x,y)=F_T(x,y)+F_B(x,y)+n(x,y) \quad (1)$$

式中: $F_T(x,y) \geq 0$, $F_B(x,y) \geq 0$ 分别代表目标和背景的灰度值; $n(x,y)$ 是服从高斯分布的零均值高斯白噪声。红外弱小目标像素灰度分布自然地建模为高斯分布:

$$F_T \approx a \exp \left\{ -\frac{1}{2} \left[\frac{(x-x_0)}{\delta_x^2} + \frac{(y-y_0)}{\delta_y^2} \right] \right\} \quad (2)$$

式中: a 表示目标像素峰值; (x_0, y_0) 表示目标中心点的坐标; δ_x 、 δ_y 则分别表示该像素点在水平、垂直方向上的标准差。

1.2 标签随机有限集多目标转移与似然函数

给定一个拓扑空间 $X \subseteq \mathbb{R}^d$, $d \geq 1$, RFS X 是在其所有有限子集 $\mathcal{F}(X)$ 上取值的随机变量^[6], 其状态 $x \in X$

是随机且无序的。考虑一个离散可数空间 $L = \{\alpha_i : i \in N\}$, 其中 N 是正整数集, 集合中的元素 α_i 是互异的。标签随机有限集 (Labeled Random Finite Set, LRFS) 就是定义在状态空间和离散标签空间的笛卡尔积 $\mathbb{X} \times \mathbb{L}$ 上的有限值集, 即在 $\mathbb{X} \times \mathbb{L}$ 取值的随机变量。

在本文常用数学函数上, 内积记为 $\langle f, g \rangle \triangleq \int f(x)g(x)dx$, 多目标指数表示为 $h^X = \prod_{x \in X} h(x)$ 。其中, h 是一个实值函数并规定 $h^\emptyset = 1$ 。广义克罗内克德尔塔函数定义为:

$$\delta_Y(X) = \begin{cases} 1, & \text{if } X = Y \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

并且包含函数定义为:

$$1_Y(X) = \begin{cases} 1, & \text{if } X \subseteq Y \\ 0, & \text{otherwise} \end{cases} \quad (4)$$

令 $\mathcal{L} : \mathbb{X} \times \mathbb{L} \rightarrow \mathbb{L}$ 为映射 $\mathcal{L}((x, l)) = l$, 集合 X 的标签集表示为 $\mathcal{L}(X) = \{\mathcal{L}(x) : x \in X\}$ 。那么空间 $\mathbb{X} \times \mathbb{L}$ 上的有限子集 X 有各异的标签当且仅当 $\delta_{|X|_c}(|\mathcal{L}(X)|_c) = 1$ 。这里算子 $|\cdot|_c$ 表示集合的基数。

根据以上定义, 标签单目标状态可描述为 $x = (x, l) \in \mathbb{X} \times \mathbb{L}$ 。通俗来讲, k 时刻出现的每个标签是一个有序对 $l = (t_b, i)$ 。其中, $t_b \leq k$ 表示状态新生的时间, i 是用于区分同一时间出现不同状态互异的标签。在当前时刻 k 令 B 表示新生标签空间, 那么在 $k+1$ 新生标签属于空间 $B_+ = \{(k+1, i) : i \in N\}$, 并因此有 $L \cap B_+ = \emptyset$ 。在 $k+1$ 时刻所有状态属于空间记为 $L_+ = L \cup B_+$ 。为紧凑表示, 采用下标“+”来替代下一时间索引。

在标签多目标贝叶斯密度中, 给定多目标转移密度 f_+ 和多目标似然 g_+ , 标签多目标状态的概率密度函数 π 的贝叶斯预测更新迭代过程为:

$$\pi(X_+) = \int f_+(X_+ | X) \pi(X) \delta X \quad (5)$$

$$\pi_+(X_+ | Z_+) = \frac{g_+(Z_+ | X_+) \pi(X_+)}{\int g_+(Z_+ | X_+) \pi(X_+) \delta X_+} \quad (6)$$

式中: 公式(5)和(6)为文献[6]定义的集合积分, $f(X_+ | X)$ 和 $g_+(Z_+ | X_+)$ 分别为多目标转移密度和多目标似然。

在预测阶段, 针对从上一时刻存活到当前时刻的 LRFS X_{S+} 和同时新生的 LRFS X_{B+} , 给定单目标转移密度 $f(x_+ | x, l) \delta(l)$ 和生存概率 $p_s(x, l)$, 多目标转移密度由以下式子给出:

$$f_+(X_+ | X) = f_{S+}(X_{S+} | X) f_{B+}(X_{B+}) \quad (7)$$

$$f_{S+}(X_{S+} | X) = \Delta(X_{S+}) \Delta(X) \mathbf{1}_{\mathcal{L}(X)}(\mathcal{L}(X_{S+})) \times \\ [\Phi_{S+}(X_{S+} | \cdot)]^X + [1 - \mathbf{1}_{\mathcal{L}(X_{S+})}(l)](1 - p_s(x, l)) \quad (8)$$

$$\Phi_{S+}(X_{S+} | x, l) = \sum_{(x_+, l_+) \in X_{S+}} \delta_l(l_+) p_s(x, l) f_{S+}(x_+ | x, l) \\ + [1 - \mathbf{1}_{\mathcal{L}(X_{S+})}(l)](1 - p_s(x, l)) \quad (9)$$

$$f_{B+}(X_{B+}) = \Delta(X_{B+}) \omega_B(\mathcal{L}(X_{B+})) [p_{B+}]^{X_{B+}} \quad (10)$$

$$\omega_B(l) = [1 - r_{B+}]^{\mathbb{B}_+ - l} \mathbf{1}_{\mathbb{B}_+}(l) [r_{B+}]^l \quad (11)$$

式中: p_{B+} 、 ω_B 以及 r_{B+} 为给定的滤波参数。

在更新阶段, 针对多目标量测 Z , 给定检测概率为 $p_D(x, l)$ 似然和 $g(z | x, l)$ 的量测 $z \in \mathbb{Z}$, 对应标签多目标集合 X 的多目标似然为:

$$g(Z | X) \propto \sum_{\theta \in \Theta(\mathcal{L}(X)) (x, l) \in X} \prod \psi_z^{(\theta(l))}(x, l) \quad (12)$$

$$\psi_z^{(\theta(l))}(x, l) = \delta_0(\theta(l)) q_D(x, l) \\ + (1 - \delta_0(\theta(l))) \frac{p_D(x, l) g(z_{\theta(l)} | x, l)}{\kappa(z_{\theta(l)})} \quad (13)$$

式中: $\kappa(\cdot)$ 是泊松强度函数; Θ 是单射 $\theta : L \rightarrow \{0 : |Z|\}$ 中所有正数的集合。泊松强度分别由平均杂波强度 λ_c 以及范围为图像尺度的均匀分布 $\mathcal{U}(\mathbb{Z})$ 表示, 即: $\kappa = \lambda_c \mathcal{U}(\mathbb{Z})$ 。

2 复杂环境红外弱小目标鲁棒跟踪算法

本文红外弱小目标跟踪总体框架以及细节如图 1 所示, 整个跟踪流程分为预处理、目标检测以及目标跟踪 3 个模块。

2.1 红外图像序列预处理与检测

在预处理模块, 首先除去与弱小目标特征相似的坏点, 再根据红外图像的特征信息判断其复杂性。文献[14]通过计算红外图像的信息熵, 并以此为依据对红外图像进行分类。但若场景存在背景抖动以及目标机动的现象时, 单纯地使用信息熵不能客观地判断场景复杂性。因此, 本文计算红外图像信息熵 E 、离散系数 (Coefficient of Variation, CoV) [15] 来描述红外图像灰度分布特征, 其对应的类型判别阈值分别设为 T_e 、 T_{CoV} ; 计算两帧图像间的峰值信噪比 (Peak Signal to Noise Ratio, PSNR) 以及结构相似性 (Structural Similarity, SSIM) [16] 用于衡量背景变化率, 并且对应的分类阈值设为 T_{PSNR} 、 T_{SSIM} 。最终给定全局阈值 T_G 对当前图像进行分类。由于缺乏对两帧图像间的 PSNR 进行量化分析的标准, 因此考虑前后两个时刻 PSNR 的差分作为图像背景运动的依

据。其中, diff 表示差分算子, 详细的操作细节由算法 1 给出。

在目标检测阶段, 若图像场景判定为简单场景, 此时场景中背景类型单一, 弱小目标受杂波干扰较小, 直接提取目标 HOG 特征; 若图像场景判定

为复杂场景, 则采用的快速小目标边界框滤波器^[5]提取弱小目标位置以及对应的图像遮罩。经过滤波后的图像仍然可能存在一些杂波, 需要对图像进行阈值化处理与连通域分析得到红外图像最终的位置与图像遮罩, 整体流程如图 1 所示。

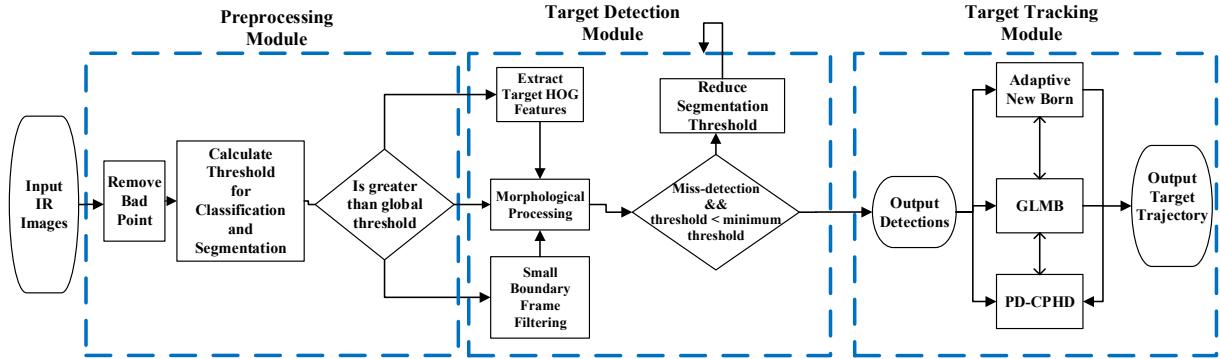


图 1 红外弱小目标跟踪算法流程图

Fig.1 Diagram of infrared small target tracking algorithm

Algorithm 1: Classification algorithm for infrared image

输入: 图像序列 I_k , 分类判别阈值 T_e , T_{Cov} , T_{PSNR} , T_{SSIM} , T_{global} , 类型累计索引 idx1 , idx0

1. 计算图像 $F_k(x,y)$ 的信息熵 $E(b)$ 、Cov、PSNR 以及 SSIM
2. $\text{Tmp1} = E(b) > T_e$;
3. $\text{Tmp2} = \text{Cov} > T_{\text{Cov}}$;
4. $\text{Tmp3} = \text{abs}(\text{diff}(\text{PSNR})) > T_{\text{PSNR}}$;
5. $\text{Tmp4} = \text{abs}(\text{diff}(\text{SSIM})) > T_{\text{SSIM}}$;
6. $\text{Tmp} = \omega_1 \text{Tmp1} + \omega_2 \text{Tmp2} + \omega_3 \text{Tmp3} + \omega_4 \text{Tmp4}$;
7. IF $\text{Tmp} > T_{\text{global}}$

判定图像为复杂图像;

$\text{idx1} = \text{idx1} + 1$;

更新判定阈值: $T_{\text{global}} = \max(0, T_{\text{global}} \cdot (1 - \frac{\text{idx1}}{\text{idx1} + \text{idx0}}) \cdot \alpha)$;

else

判定图像为简单图像;

$\text{idx0} = \text{idx0} + 1$;

更新判定阈值: $T_{\text{global}} = \min(1, T_{\text{global}} \cdot (1 + \frac{\text{idx0}}{\text{idx1} + \text{idx0}}) \cdot \alpha)$;

End

输出: 红外图像 $F_k(x,y)$ 的类型 $\text{Class}_{\text{img}}$

2.2 红外弱小目标模型与量测模型

1.2 节给出了弱小目标在贝叶斯框架下状态预测更新的一般范式, 而对于未标签的单目标状态可表示为 $\mathbf{x} = [p, I_x]^T$, $\mathbf{p} = [p_x, p_{xx}, p_y, p_{yy}]$ 为该目标的运动学特征, 下标 x , y 以及 xx , yy 分别表示目标在 x 与 y 方向上的位置与速度, 符号 “ T ” 表示转置。 I_x 表示目标所在点灰度值。那么量测可建模为 $\mathbf{z} = [p_z, I_z]^T$, \mathbf{p}_z

$=[p_{xz}, p_{yz}]$ 表示量测点所在的位置, I_z 表示量测点对应的灰度值。为了尽可能利用图像中的目标信息, 对 k 时刻的红外图像 $F_k(x, y)$, 以像素坐标 (i_0, j_0) 为圆心, 尺寸为 $M \times N$ 的局部直方图定义为^[17]:

$$H(b) = \sum_{i=-\frac{M}{2}}^{\frac{M}{2}} \sum_{j=-\frac{N}{2}}^{\frac{N}{2}} F(i_0 + i, j_0 + j) \\ F(i_0 + i, j_0 + j) \in \left[b \frac{K}{B}, (b+1) \frac{K}{B} \right] \quad (14)$$

$$b = 0, \dots, B-1$$

式中: $F(i_0 + i, j_0 + j)$ 为模板内像素的灰度值; B 是灰度级区间数; K 是区间内像素点值的动态范围。

弱小目标灰度由目标本身能量和场景噪声如大气光强度, 含雾量决定, 目标直方图由模板内前景与背景灰度同时决定。因此假设位置、灰度以及局部直方图 3 类特征在统计上相互独立, 将单目标似然函数拆分成 3 类特征对应似然函数的乘积:

$$g(\mathbf{x}|z, l) = g(\mathbf{x}|z) = p(\mathbf{x}_p|z_p) \times \\ p(\mathbf{x}_I|z_I) e^{(-(1-B(x|z)))} \quad (15)$$

$$p(\mathbf{x}_p|z_p) = (2\pi\sigma_p)^{-\frac{1}{2}} e^{-\frac{1}{2\sigma_p^2}(z_p - x_p)^2} \quad (16)$$

$$p(\mathbf{x}_I|z_I) = (2\pi\sigma_I)^{-\frac{1}{2}} e^{-\frac{1}{2\sigma_I^2}(z_I - x_I)^2} \quad (17)$$

$$B(\mathbf{x}|z) = \sum_{b=0}^{B-1} \sqrt{H_x(b) H_z(b)} \quad (18)$$

式(15)中: 下标 p , I 分别表示状态向量以及量测向量对应的位置分量以及灰度值分量; $0 \leq B(x|z) \leq 1$ 为 Bhattacharyya 系数^[18], 用于衡量公式(18)求解出目标

与量测对应的局部直方图的相似性。

2.3 自适应的广义标签多伯努利滤波

在目标跟踪阶段, 采用自适应的 GLMB 滤波实现弱小目标跟踪。在 1.2 节中规定的检测概率 $p_D(x, l)$ 通常取值为常数, 与传感器抖动, 画面模糊而造成检测概率时变这一实际情况不匹配。对此, 采用未知检测概率的 CPHD^[19]估计检测器的平均检测概率, 再将其输入到 GLMB 滤波器中。而对目标新生的先验信息估计, 则采用基于量测驱动^[20]的自适应新生算法, 使滤波器快速收敛。由于 CPHD 滤波器的低复杂度, 检测概率可以有效快速地在滤波迭代中估计。而 GLMB 滤波作为跟踪器则可以输出目标轨迹。

2.3.1 自适应新生的广义标签多伯努利滤波

假设当前时刻多目标密度为 GLMB 密度为:

$$\pi(X) = \Delta(X) \sum_{(I, \xi) \in \mathcal{F}(L) \times \Xi} \omega^{(I, \xi)} \delta_I(\mathcal{L}(X)) [p^\xi]^X \quad (19)$$

式中: $I \in \mathcal{F}(L)$ 表示标签集中的标签; $\xi \in \Xi$ 为历史关联, 每个 $p^\xi(\cdot, l)$ 表示目标在状态空间 \mathbb{X} 上的状态分布, 并且 $\int p^\xi(x, l) dx = 1$, 每个非负权重 $\omega^{I, \xi}$ 满足:

$$\sum_{I \in \mathcal{F}(L)} \sum_{\xi \in \Xi} \omega^{(I, \xi)} (L) = 1 \quad (20)$$

在得到当前时刻的量测数据后, 对目标的后验状态进行联合估计, 更新的 GLMB 密度表示为^[21]:

$$\pi_+(X_+ | Z_+) \propto \Delta(X_+) \cdot \sum_{I, \xi, I_+, \theta_+} \omega^{(I, \xi)} \omega_{Z_+}^{(I, \xi, I_+, \theta_+)} \delta_{I_+} [\mathcal{L}(X_+)] \left[p_{Z_+}^{(\xi, \theta_+)} \right]^{X_+} \quad (21)$$

式中: 在得到下一时刻量测集 Z_+ 后, $I_+ \in \mathcal{F}(L_+)$, $\xi_+ \in \Xi_+$ 为下一时刻标签集中的标签和历史关联映射中的历史关联。并且式(21)中的各个因子表示为:

$$\omega_{Z_+}^{(I, \xi, I_+, \theta_+)} = 1_{\Theta_+(I_+)}(\theta_+) \left[1 - \bar{P}_S^\xi \right]^{I - I_+} \times \left[\bar{P}_S^\xi \right]^{I - I_+} \left[1 - r_{B,+} \right]^{\mathbb{B}_+ - I_+} r_{B,+}^{\mathbb{B}_+ \cap I_+} \left[\bar{\psi}_{Z_+}^{(\xi, \theta_+)} \right]^{I_+} \quad (22)$$

$$\bar{P}_S^\xi(l) = \langle p^\xi(\cdot, l), p_S(\cdot, l) \rangle \quad (23)$$

$$\bar{\psi}_{Z_+}^{(\xi, \theta_+)}(l_+) = \langle \bar{p}_+^\xi(\cdot, l_+), \psi_{Z_+}^{\theta_+(l_+)}(\cdot, l_+) \rangle \quad (24)$$

$$\begin{aligned} \bar{p}_+^\xi(x_+, l_+) = & 1_{\mathbb{B}_+}(l_+) p_{B,+}(x_+, l_+) + \\ & 1_{\mathbb{L}_+}(l_+) \frac{\langle p_S(\cdot, l_+) f_+(x_+ | l_+), p^{(\xi)(\cdot, l_+)} \rangle}{\bar{P}_S^\xi(l_+)} \end{aligned} \quad (25)$$

$$p_{Z_+}^{(\xi, \theta_+)}(x_+, l_+) = \frac{\bar{p}_+^\xi(x_+, l_+)}{\psi_{Z_+}^{\theta_+(l_+)}(l_+)} \quad (26)$$

给定 GLMB 滤波密度, 可以提取估计的多目标状态和轨迹^[21]。采用吉布斯采样联合预测更新的方法, 选取 GLMB 滤波密度的重要分量 (高权重分量)。在标准的 GLMB 滤波迭代中, 新生集合 \mathbf{X}_{B+} 以及检测概率 p_D 是假设已知的。然而, 在现实应用中这些先验信息通常是未知的。在提出的自适应 GLMB 滤波器中, 检测概况是从一个独立运行的鲁棒 CPHD 滤波器中估计的。此外, 文献[20]认为量测 $z \in Z$ 与当前时刻上存在的对象关联的概率越低, 下一个时刻上由新生对象生成的概率就越高。但在图像量测中, 跟踪场景大小是固定的, 除了目标存在场景中的第几个时刻, 新生的目标更有可能从图像边缘中新生, 对此本文提出一种适应于图像量测的自适应新生算法。

在给定公式(26)的 GLMB 密度后, 量测 z 的关联概率可以表示为:

$$r_U(z) = \sum_{I \in \mathcal{F}(L)} \sum_{\theta \in \Xi_{I,k}} 1_\theta(z) \omega^{(I, \theta)} \quad (27)$$

式中: $\Xi_{I,k}$ 当前时刻标签集 I 的关联映射集。包含函数 $1_\theta(z)$ 确保了权重总和仅考虑将测量 z 分配给其轨道之一的那些假设。那么基于当前时刻量测 z 的下一时刻新生强度为:

$$r_{B+}(z) = \min \left(r_{B,\max}, \frac{1 - r_U(z)}{\sum_{\xi \in Z} 1 - r_U(\xi)} \cdot \lambda_{B+} \right) \quad (28)$$

式中: λ_{B+} 是下一时刻新生目标的期望值; $r_{B,\max} \in [0, 1]$ 是最大新生强度。由于在图像中目标更有可能从图像边缘中新生, 因此公式(28)改写为:

$$r_{B+}(z) = \min \left(r_{B,\max}, \frac{1 - r_U(z)}{\sum_{\xi \in Z} 1 - r_U(\xi)} \cdot \lambda_{B+} \cdot r_{\text{edge}}(z) \right) \quad (29)$$

$$r_{\text{edge}}(z) = \left(\min \sqrt{(p_z - x_{\text{center}})^2} \right) / \max(M, N) \quad (30)$$

式中: x_{center} 为图像的中心点; p_z 为量测位置分量; M 和 N 表示图像尺寸; r_{edge} 为新生强度的控制遮罩, 形状如图 2 新生强度控制遮罩所示。

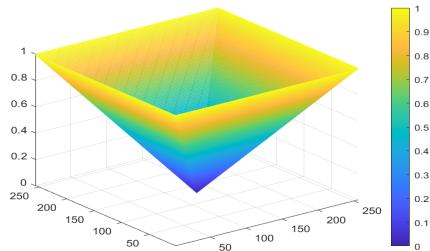


图2 新生强度控制遮罩

Fig.2 New born intensity controlling mask

由文献[21]可知, GLMB 自适应新生模型为标签多伯努利 (Labeled Multi-Bernoulli, LMB) 的形式:

$$\pi_{B,+} = \{r_B^l, p_B^l\}_{l=1}^{|Z|} \quad (31)$$

即当前时刻的新生量由上一时刻的量测决定。然而, 当场景从第 1 到第 $t(t \geq 2)$ 时刻目标不出现或都发生漏检时, 自适应新生模块将无法传递新生信息导致航迹起始失败。为了处理这一情况, 本文在目标未出现或漏检时采用固定点新生算法, 在存在量测时采用基于量测驱动的自适应新生, 见算法 2。

Algorithm 2: Adaptive new born algorithm

输入: 上一时刻的 GLMB 密度, 当前时刻量测集 Z_+ , 时间索引 k

1. If $|Z_+| == 0 \ \&\& k == 1$

按照固定参数进行新生;

else

根据公式(27)~(30)计算量测关联密度 $r_U(z)$ 、新生强度 $r_{B,+}(z)$ 以及强度控制参数 $r_{\text{edge}}(z)$;

End

输出: 输出新生模型 $\pi_{B,+}$

2.3.2 基于 CPHD 滤波估计检测概率

由于 CPHD 滤波器在单目标空间上估计目标状态, 避免了目标与量测数据关联时产生的巨大计算, 本文采用未知检测概率的 CPHD^[19]估计图像序列目标检测概率。

令 $(\Delta) = [0, 1]$ 表示未知检测概率的空间, 定义增广状态空间为:

$$\underline{\mathbb{X}} = \mathbb{X} \times \mathbb{X}^{(\Delta)} \quad (32)$$

下划线符号始终用于表示在增广状态空间上定义的函数或变量, 即: $\underline{x} = [x, a] \in \underline{\mathbb{X}}$ 为增广状态。其中, $x \in \mathbb{X}$ 为标签的单目标状态, $a \in \mathbb{X}^{(\Delta)} = [0, 1]$ 为增广的检测概率。函数积分 $\underline{f}: \underline{\mathbb{X}} \rightarrow \mathbb{R}$ 可表示成:

$$\int_{\underline{\mathbb{X}}} \underline{f}(\underline{x}) d\underline{x} = \int_{\mathbb{X}^{(\Delta)}} \int_{\mathbb{X}} f(x, a) dx da \quad (33)$$

增广的单目标生存概率和转移密度定义为:

$$\underline{p}_{S,+}(\underline{x}) = \underline{p}_{S,+}(x, a) = p_S(x) \quad (34)$$

$$f_+(\underline{x}_+ | \underline{x}) = f(x_+ | x) f(a_+ | a) \quad (35)$$

新生目标由增广状态的强度 $\underline{\gamma}_+(\underline{x}_+) = \underline{\gamma}(x_+, a_+)$

和基数分布 $\rho_{X_{B,+}}(n)$ 给出。增广状态的单目标似然和检测概率分别表示为:

$$\underline{p}_{D,+}(\underline{x}) = \underline{p}_{D,+}(x, a) = a \quad (36)$$

$$\underline{g}_+(z | \underline{x}) = g_+(z | x, a) = g_+(z | x) \quad (37)$$

给定当前时刻的 PHD \underline{v} 和基数分布 ρ , CPHD 滤波的预测步为^[19]:

$$\begin{aligned} \underline{v}_+(x_+, a_+) &= \underline{\gamma}(x_+, a_+) + \\ &\int \int_0^1 p_{S,+}(x_+) f(x_+ | x) f(a_+ | a) \underline{v}(x, a) da dx \end{aligned} \quad (38)$$

$$\rho_+(n) = \sum_{j=0}^n \rho_{X_{B,+}}(n) (n-j) \sum_{l=j}^{\infty} C_j^l \rho(l) (1-\phi)^{l-j} \phi^j \quad (39)$$

在得到下一时刻的量测集 Z_+ , PHD 和基数分布的更新公式为^[19]:

$$\rho_+(n) = \frac{\underline{\Upsilon}_+^0[\underline{v}_+; Z_+](n) \cdot \rho_+(n)}{\langle \underline{\Upsilon}_+^0[\underline{v}_+; Z_+], \rho_+(n) \rangle} \quad (40)$$

$$\begin{aligned} \underline{v}_+(x_+, a_+) &= [(1-a) \frac{\underline{\Upsilon}_+^1[\underline{v}_+; Z_+], \rho_+(n)}{\langle \underline{\Upsilon}_+^0[\underline{v}_+; Z_+], \rho_+(n) \rangle} + \\ &\sum_{z \in Z_+} \underline{\psi}_{z,+}(x, a) \frac{\underline{\Upsilon}_+^1[\underline{v}_+; Z_+ - \{z\}], \rho_+(n)}{\langle \underline{\Upsilon}_+^0[\underline{v}_+; Z_+], \rho_+(n) \rangle} \underline{v}(x, a)] \end{aligned} \quad (41)$$

最终, 平均检测概率 $\bar{p}_{D,+}$ 由每个目标估计的检测概率加权平均得到。

3 仿真实现

为验证本文算法的有效性, 采用国防科技大学和中国航天科工二院共同制作的《红外序列图像中小飞机目标检测跟踪数据集》^[22]。根据跟踪场景的类型, 按照文献的描述, 选取第 4、6、8、9、13、15、17、18、20 以及 22 号数据的前 250 帧为代表进行跟踪测试。所测试数据集部分图像如图 3 所示, 对应的场景描述以及算法 1 给出的分类结果如表 1 所示。

在表 1 中数据采集的主要环境背景及数据的信杂比 (signal-to-cluster ratio, SCR) 定义为^[22]:

$$SCR = \frac{|\mu_{tg} - \mu_{img}|}{\delta_{img}} \quad (42)$$

式中: μ_{tg} 表示目标所在区域均值; μ_{img} 为图像平均均值; δ_{img} 表示图像均值标准差。

表 1 红外弱小目标数据集信息表

Table 1 Infrared small target data set information sheet

Dataset	Average SCR	SCR Variance	Description	Type
4	3.75	3.646	Close range, two targets, sky background, intersecting flight	Simple
6	5.11	1.571	Moving near and far, single target, ground background	Simple
8	6.07	0.159	Moving far and near, single target, ground background	Complex
9	6.29	17.086	Moving near and far, single target, ground background	Complex
13	1.98	0.886	Target moving near and far, single target, weak target, ground background	Complex
15	3.42	0.965	Single target, target maneuvering, ground background	Complex
17	1.09	0.353	Target moving near and far, single target, weak target, ground background	Complex
18	3.32	0.165	Target moving far and near, single target, ground background	Complex
20	3.01	1.485	Single target, target maneuvering, sky background	Complex
22	2.20	0.150	Target moving far and near, single target, ground background	Complex

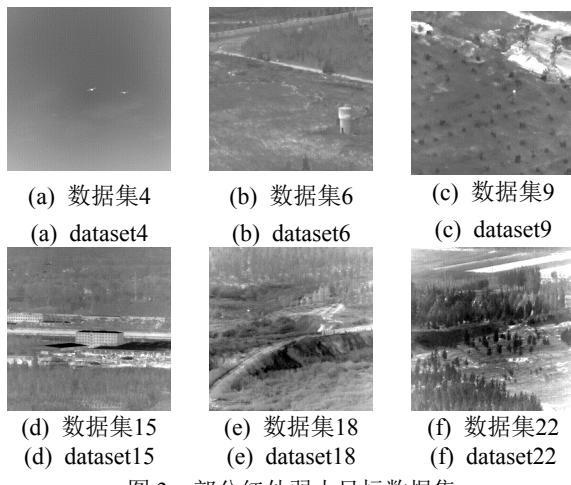


图 3 部分红外弱小目标数据集

Fig.3 Partial infrared small target dataset

3.1 图像预处理与检测结果分析

表 1 最后一列为算法 2 计算后得到的分类结果, 可以发现尽管数据集 13、17 以及 22 的平均 SCR 很低, 算法却仍旧判定其为复杂类型, 判断依据如图 4、图 5 所示。图 4 的 4 张子图分别为数据集 17 每张图像的信息熵、离散系数的倒数、PSNR 以及 SSIM 的差分。这里给定图像类型判定阈值 $T_e=6$, $T_{Cov}=4.5$, $T_{PSNR}=5$, $T_{SSIM}=0.3$ 。不难看出数据 17 的信息熵和离散系数都大于判定阈值, 尽管该场景 SCR 不大, 但图像包含信息量过大, 背景复杂。此外, PSNR 和 SSIM 的差分序列波动较大, 说明场景背景变化率大。在图像判定上, 给定 4 个参数的权重 $\{\alpha_i\}_{i=1}^4 = \{0.2, 0.2, 0.3, 0.3\}$; 判定阈值 $T_G=0.5$, 算法 2 中的

α 为缩放因子, 取值为 0.01。每帧图像的复杂度分布如图 5 所示, 红色的虚线为图像类型判定全局阈值, 蓝色的直线为算法 2 得到的图像分类决定值。图像数据表明当图像序列复杂类型数量占优时, 全局判定阈值也会因此更新而逐渐下降, 倾向于把整个跟踪场景判定为复杂场景。

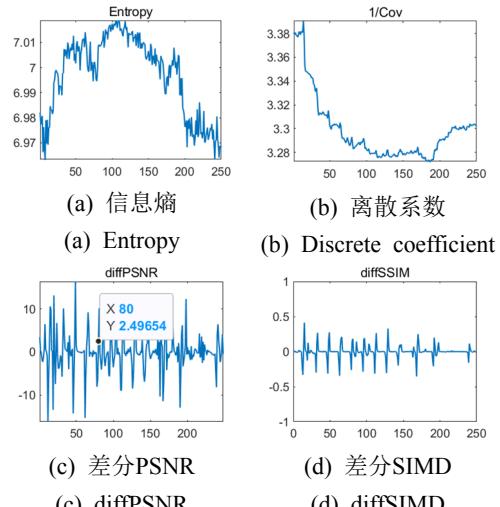


图 4 数据集 17 图像序列特征

Fig.4 Image sequence characteristics of dataset 17

在目标检测的设置上, 图 6 中的检测模块见算法 2, 其中, $T_{seg} = \mu_{img} + 5\delta_{img}$, $T_{min_seg} = \mu_{img} - 2\delta_{img}$ 。图像在经过阈值分割后得到二值化图像后进行连通域分析, 去除不符合弱小目标面积 ($2 \times 2 \sim 9 \times 9$) 的连通域。如图 6 所示, 本文算法能有效对弱小目标前景进行分割。

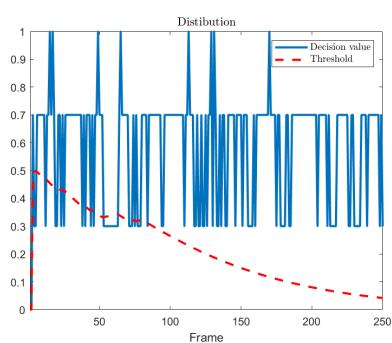


图5 数据集17图像复杂度分布

Fig.5 Image complexity distribution of dataset 17

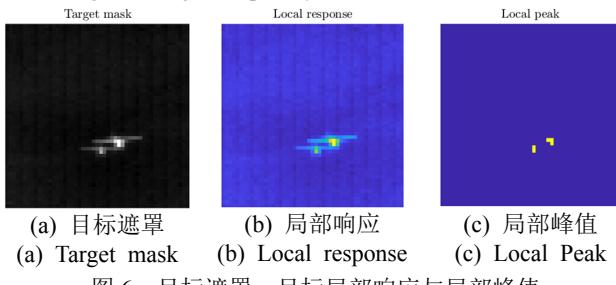


图6 目标遮罩、目标局部响应与局部峰值

Fig.6 Target mask, local response and peak

3.2 弱小目标跟踪算法结果分析

在 GLMB 滤波中, 目标转移模型和量测模型均为线性高斯模型, 定义为:

$$f_+(x_+|x) = N(x_+; F(x, w), Q) \quad (43)$$

$$g(z|x) = N(z; Hx, R) \quad (44)$$

式中: $N(\cdot; m, P)$ 是均值为 m 协方差为 P 的高斯密度; $Q = \text{diag}([0.1, 0.01, 0.1, 0.01, 10])^2$ 为过程噪声协方差; $R = \text{diag}([1, 1, 10])^2$ 为量测协方差; F 为状态转移矩阵; H 为量测提取矩阵。给定采样时间 $T=1$ s, 有:

$$F = \begin{pmatrix} A_4 & 0 \\ 0 & 1 \end{pmatrix}$$

$$A_4 = \begin{pmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

$$H = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix}$$

在滤波参数的布置上, 每个目标的生存概率 p_s

$=0.99$, 最大假设数为 1000, 在服从泊松分布的杂波强度 $\kappa = \lambda_c U(Z)$ 中, $\lambda_c=10$ 为单位面积内的杂波数, $U(Z)=1/MN$ 为均匀分布的概率密度。新生密度为贝塔高斯混合的形式:

$$\underline{\gamma}(x, a) = \sum_{j=1}^J \omega^j \beta(a; s^j, t^j) N(x; m^j, P^j)$$

式中: J , a^j , s^j , t^j , m^j , P^j , $j=1, \dots, J$ 为给定的模型参数。每个目标的检测概率 a 建模为贝塔分布, 记为 $\beta(a; s, t)$ 。本文将贝塔初始的参数设定为 $s=0.8$, $t=0.2$, 即其初始均值为 0.8。 $P=\text{diag}([10, 2, 10, 2, 10])^2$ 为新生目标的协方差, m 为新生目标的均值, J 为新生目标的个数由新生强度决定。

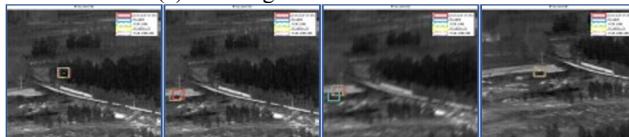
对于检测器的检测效果设置漏检平均占比 (Average Miss Detection Rate, AMDR) 以及虚警平均占比 (Average False Alarm Rate, AFAR)。AMDR 为漏检帧数占总跟踪帧数的比率。单帧的虚警占比为由非目标产生的量测数占场景当前量测数的比率, AFAR 则为所有帧数虚警占比的算数平均。为了衡量跟踪性能, 对于单目标, 采用均方根误差^[23] (Root Mean Squared Error, RMSE) 衡量目标定位精度; 将 RMSE 的标准差记为 R_{std} 衡量跟踪的稳定性; 引入文献[14]中的规定求解跟踪的成功率 (Accuracy Rate, AR) 以及准确率 (Precision Rate, PR)。其中, 成功跟踪定义为估计的目标位置位于以标签集为中心, 大小为 9×9 像素的标注框中, AR 则定义为成功检测的帧数占该数据集总帧数的比率。准确跟踪则是将标注框大小缩减至 3×3 。对于多目标跟踪, 采用最优子模式分配 (Optimal Sub-pattern Assignment, OSPA)^[24] 来同时衡量目标定位精度与目标数量精度。OSPA 衡量的是估计状态随机集与真实目标随机集之间的误差, 分别对目标位置和速度的估计进行评估。其中, OSPA 度量的阶数设置为 1, 截断距离为 30。

LRFS 根据近似方法不同分为对应的联合估计算法分别为 (Joint Generalized Labelled multi-Bernoulli, JGLMB) 以及 (Joint Labelled multi-Bernoulli, JLMB)^[20], 假设本文算法改进算法分别记为 JGLMBAD 和 JLMBAD。其中, 对比算法采用未改进的自适应新生算法, 本文算法采用改进的自适应新生算法。图 7 展示了本文算法和对比算法在不同红外场景下的跟踪效果。其中, 真实目标被其质心张成的 9×9 大小的红色矩形框标注, 作为对照的 JLMB 和 JGLMB 算法分别使用蓝色实线矩形框和绿色虚线矩形框标注, 而本文所提算法 JLMBAD 和

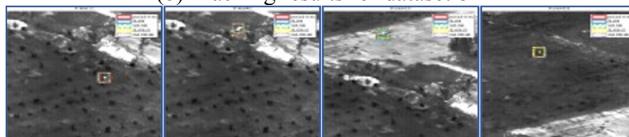
JGLMBAD 分别用黄色和紫色矩形框标注。图 8 对比的是多目标跟踪场景中本文算法与对比算法的 OSPA 误差。其中, 从上到下分别是整体误差、位置误差以及基数误差。图 9 是基数分布对比图, 黑色实线为真实目标基数分布, 蓝色虚线为本文算法估计分布, 红色虚线则为对照算法基数分布。JGLMBAD 滤波每个场景 100 次蒙特卡罗的实验平均跟踪性能如表 2 所示。



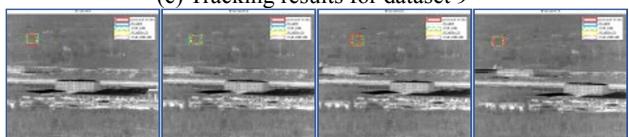
(a) 数据集 4 跟踪结果
(a) Tracking results for dataset 4



(b) 数据集 8 跟踪结果
(b) Tracking results for dataset 8



(c) 数据集 9 跟踪结果
(c) Tracking results for dataset 9



(d) 数据集 15 跟踪结果
(d) Tracking results for dataset 15



(e) 数据集 18 跟踪结果
(e) Tracking results for dataset 18



(f) 数据集 22 跟踪结果
(f) Tracking results for dataset 22

图 7 不同场景下的跟踪效果

Fig.7 Results about different scenes

图 7 展示的分别是数据集 4、8、9、15、18 以及 22 的跟踪场景, 数据集 4 为多目标跟踪场景, 其余场景皆为单目标跟踪场景。在多目标对比场景中所有算法均能稳定目标, 但在目标分离后由于传感器

机动, JGLMB 和 JLMB 出现了不同程度的目标偏离, 本文所提出的算法则稳定跟踪目标。在单目标对比场景中, 数据集 8 为传感器高机动场景, 数据集 15 以及 18 为目标机动场景。在数据集 8 第 58~66 帧出现画面模糊与目标位置突变。通过对比可以发现, 本文所提出算法在传感器机动时偏离目标位置较小。在数据集 15 第 35 帧中, JLMB 出现漏估, JGLMB 出现偏移。数据集 18 由于目标机动, 所有滤波器均出现偏移, 通过数据集 18 可以发现, JGLMB 和 JLMB 偏移量更大。

综合对比表 2, 本文所提出的算法在所有单目标场景都具有 95% 以上的成功跟踪率, 尤其是在场景 22 虚警率及漏检率都较高的情况下均能顺利实现跟踪。在跟踪准确度上场景 15、17 由于目标机动且背景变化较快, 因此跟踪精度有所下降。

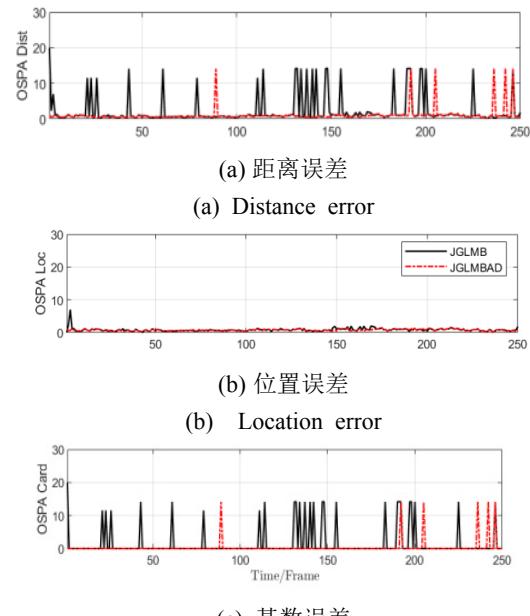


图 8 OSPA 误差对比

Fig.8 OSPA error comparison

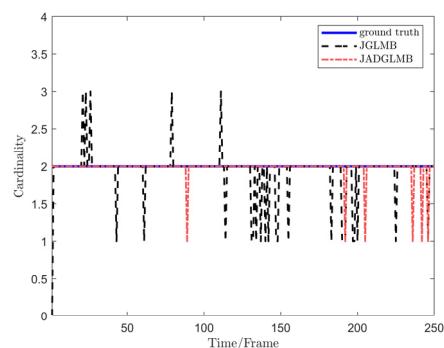


图 9 基数估计分布对比

Fig.9 Comparison of cardinality distribution estimation

表2 本文算法在不同数据集下的跟踪结果

Table 2 Tracking results of the proposed algorithm on different datasets

Dataset	AMD	AFA	AR	PR	$R_{std,x}$	$R_{std,y}$
6	8%	2%	95.2%	93.6%	0.43761	0.86444
8	8%	9.5%	97.2%	89.2%	5.3831	2.6797
9	10%	11%	98.8%	92.4%	0.8031	0.8671
13	2%	0%	100%	98.8%	0.5980	0.6135
15	2%	8%	97.2%	86.4%	1.1927	0.6202
17	10.8	6%	100%	67.6%	1.2950	0.9641
18	1.2%	0%	99.6%	99.6%	0.6654	0.5817
20	0%	0%	100%	100%	0.2274	0.2453
22	21.6%	28.4%	96.8%	84.8%	1.2324	0.71792

为了对比本文提出算法与对比算法在时间上效能。本文在 CPU 型号为 AMD Ryzen 7 5800H, 内存为 16GB 的笔记本上运行了不同的滤波算法, 使用了包含两个目标的数据集 4 和单个目标的数据集 8。从表 3 可以发现, 当目标仅为一个时, 本文所提出算法均优于对比算法。LMB 关于量测的时间复杂度为 $O(|Z|^3)$ ^[25], 本文引入 CPHD 估计检测概率, 其由于初等对称函数的性质复杂度同为 $O(|Z|^3)$ 。但对比算法由于对场景检测概率的错误估计会导致其关联更多的虚警。因此, 量测 Z 基数增长引起的时间增长大于 LMB 与 GLMB 叠加引起的时间耗损。而当目标不唯一时, 由于产生的量测量增加, CPHD 滤波部分带来的运算时间会使得本文算法运算量增加。因此, 在数据集 4 中, 本文提出的 JGLMBAD 算法要略慢于原始算法。而与 GLMB 滤波不同, 其中的 LMB 滤波不传播多目标假设, 因此在目标数量较多时, 具有更快的运算时间。因此, JLMBAD 算法与 JLMB 算法运算速度均快于 JGLMB 类算法。

表3 每个滤波器的平均耗时

Table 3 Average time cost of every filter

Dataset	Filter				s
	JLMB	JLMBAD	JGLMB	JGLMBAD	
4	3.8125	3.2813	7.625	8.8175	
8	2.2031	1.951	2.625	1.6563	

最后对比图 8~图 9, 从位置误差上分析, 标准 JGLMB 在对目标进行估计时需要一段时间收敛, 而 JGLMBAD 得益于改进的自适应新生算法, 能在一开就收敛到真实目标的位置上。其次, 在 140~180 帧目标间距离接近的这个区间, 本文算法位置精度更高。除此之外, 本文算法过估计与漏检发生的频次更低。

4 结论

为了解决红外弱小目标跟踪场景中出现的漏检、虚警和随机噪声等不确定性导致目标跟踪困难的问题, 本文将图像预处理、目标检测与目标跟踪整合在一起, 通过计算图像信息熵、灰度离散程度等特征自适应地选择检测算法。并且, 在原有的自适应 GLMB 滤波跟踪基础上, 本文对自适应新生算法进行了改进, 使其更适用于视频跟踪环境。本文所提出的跟踪算法在多个红外视频序列上进行了实验验证, 结果表明该算法能够有效地检测和跟踪红外弱小目标, 并且具有较高的精度和鲁棒性。然而, 本文所提出的跟踪算法也存在计算量较大, 对于实时性要求较高的场景不太适合等不足。

参考文献:

- [1] 张雪, 梁晓庚. 红外探测器发展需求[J]. 电光与控制, 2013, 20(2): 41-45.
ZHANG Xue, LIANG Xiaogeng. Development of and demands for infrared detectors[J]. *Electronics Optics & Control*, 2013, 20(2): 41-45.
- [2] 赵琰, 刘荻, 赵凌君, 等. 基于 YOLOv3 的复杂环境红外弱小目标检测[J]. 航空兵器, 2019, 26(6): 29-34.
ZHAO Yan, LIU Di, ZHAO Lingjun, et al. Infrared dim and small target detection based on YOLOv3 in complex environment[J]. *Aero Weapony*, 2019, 26(6): 29-34.
- [3] CHEN C L, LI H, WEI Y, et al. A local contrast method for small infrared target detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 52(1): 574-581.
- [4] Aghaziyarati S, Moradi S, Talebi H. Small infrared target detection using absolute average difference weighted by cumulative directional derivatives[J]. *Infrared Physics & Technology*, 2019, 101: 78-87.
- [5] FU J, ZHANG H, WEI H, et al. Small bounding-box filter for small target detection[J]. *Optical Engineering*, 2021, 60(3): 1-14.
- [6] 薛秋条, 宁巧娇, 吴孙勇, 等. 基于 JMS-SMC-PHD 滤波的检测前跟踪算法[J]. 红外技术, 2020, 42(8): 783-788.
XUE Qiutiao, NING Qiaojiao, WU Sunyong, et al. A track-before-detect algorithm based on a JMS-SMC-PHD filter[J]. *Infrared Technoilogy*, 2020, 42(8): 783-788.
- [7] Bocquel M. Random finite sets in multi-target tracking-efficient sequential MCMC implementation[D]. Enschede: Centre for Telematics and Information Technology, 2013: 21-22.
- [8] Kim D Y, Vo B N, Vo B T. A labeled random finite set online multi-object tracker for video data[J]. *Pattern Recognition*, 2019, 90: 377-389.
- [9] XIAO S, MA Y, FAN F, et al. Tracking small targets in infrared image sequences under complex environmental conditions[J]. *Infrared Physics &*

- Technology, 2020, **104**: 103102.
- [10] TAO H, SHEN X, DENG Q. Infrared target tracking algorithm based on Bernoulli filter and support vector machine[C]//International Conference on Information Science and Education (ICISE-IE). IEEE, 2020: 277-281.
- [11] 董小虎, 傅瑞罡, 高颖慧, 等. 复杂背景下红外小目标自适应检测跟踪[J]. 航空兵器, 2019, **26**(6): 22-28.
- DONG Xiaohu, FU Ruigang, GAO Yinghui, et al. Detection and tracking of small infrared targets adaptively in complex background[J]. *Aero Weaponry*, 2019, **26**(6): 22-28.
- [12] SHU C, DING X, FANG C. Histogram of the oriented gradient for face recognition[J]. *Tsinghua Science and Technology*, 2011, **16**(2): 216-224.
- [13] Eysa R, Hamdulla A. Issues on infrared dim small target detection and tracking[C]//International Conference on Smart Grid and Electrical Automation (ICSGEA). IEEE, 2019: 452-456.
- [14] 施天俊, 鲍广震, 王福海, 等. 一种适用于多场景的红外弱小目标检测跟踪算法[J]. 航空兵器, 2020, **26**(6): 35-42.
- SHI Tianjun, BAO Guangzhen, WANG Fuhai, et al. An infrared small target detection and tracking algorithm applying for multiple scenarios[J]. *Aero Weaponry*, 2020, **26**(6): 35-42.
- [15] Brown C E. *Coefficient of Variation*[M]. Berlin: Springer, 1998: 155-157.
- [16] Horé A, Ziou D. Image quality metrics: PSNR vs. SSIM[C]//20th International Conference on Pattern Recognition, 2010: 2366-2369.
- [17] Dubuisson Séverine. *Tracking with Particle Filter for High-dimensional Observation and State Spaces*[M]. New York: John Wiley & Sons, Inc., 2015.
- [18] Derpanis K G. The bhattacharyya measure[J]. *Mendeley Computer*, 2008, **1**(4): 1990-1992.
- [19] Mahler R P S, Vo B T, Vo B N. CPHD filtering with unknown clutter rate and detection profile[J]. *IEEE Transactions on Signal Processing*, 2011, **59**(8): 3497-3513.
- [20] Reuter S, Vo B T, Vo B N, et al. The labeled multi-Bernoulli filter[J]. *IEEE Transactions on Signal Processing*, 2014, **62**(12): 3246-3260.
- [21] Do C T, Nguyen T T D, et al. Multi-object tracking with an adaptive generalized labeled multi-Bernoulli filter[J]. *Signal Processing*, 2022, **196**: 1-20.
- [22] HUI B W, SONG Z Y, FAN H Q, et al. A dataset for dim small target detection and tracking of aircraft in infrared image sequences [DB/OL]. Science Data Bank, 2022 [2022-09-01]. <https://www.scidb.cn/en/>.
- [23] 刘洁, 李小昱, 李培武, 等. 基于近红外光谱的板栗水分检测方法[J]. 农业工程学报, 2010, **26**(2): 338-341.
- LIU Jie, LI Xiaoyu, LI Peiwu, et al. Determination of moisture in chestnuts using near infrared spectroscopy[J]. *Transaction of the Chinese Society of Agricultural Engineering*, 2010, **26**(2): 338-341.
- [24] Schuhmacher D, Vo B T, Vo B N. A consistent metric for performance evaluation of multi-object filters[J]. *IEEE Transactions on Signal Processing*, 2007, **56**(8): 3447-3457.
- [25] HAO Q, GAO H, JUN G. Variational Bayesian labeled multi-Bernoulli filter with unknown sensor noise statistics[J]. *Chinese Journal of Aeronautics*, 2016, **29**(5): 1378-1384.