

改进非凸估计与非对称时空正则化的红外小目标检测方法

胡亮, 杨德贵*, 赵党军, 张俊超
(中南大学自动化学院, 湖南长沙 410083)

摘要:针对复杂背景下的红外小目标检测,在非对称时空正则化约束的非凸张量低秩估计算法基础上,提出了一种新的核范数估计方法代替原算法中的估计方法。提出基于结构张量与多结构元顶帽(Top-Hat)滤波的自适应权重张量对目标张量进行约束,增强目标张量稀疏性的同时抑制其中残存的强边缘结构。实验结果表明,所提改进算法能够更好地消除图像中强边缘结构对检测结果的影响,在保证检测率的情况下,较原算法具有更低的虚警率。

关键词:红外小目标检测;张量恢复;张量核范数;多结构元 Top-Hat 滤波

中图分类号:TP391 **文献标志码:**A **文章编号:**1001-2486(2024)03-180-15

Infrared small target detection method based on improved non-convex estimation and asymmetric spatial-temporal regularization

HU Liang, YANG Degui*, ZHAO Dangjun, ZHANG Junchao

(School of Automation, Central South University, Changsha 410083, China)

Abstract: Aiming at infrared dim and small targets detection in complex background, a new kernel norm estimation method was proposed based on the non-convex tensor low-rank approximation algorithm with asymmetric spatial-temporal total variation regularization, replacing the original estimation method in the algorithm. An adaptive weight tensor based on structure tensor and multi-structure element Top-Hat filtering was proposed to constrain the target tensor, which had enhanced the sparsity and suppressed the remaining strong edge structures of the target tensor. Experimental results show that the proposed improved algorithm can better eliminate the influence of strong edge structure on the detection results, and has a lower false alarm rate than the original algorithm under the condition of ensuring the detection rate.

Keywords: infrared small target detection; tensor recovery; tensor nuclear norm; multi-structure element Top-Hat filtering

红外技术由于成像距离远、全天候工作等特点,广泛应用于预警、天基红外监控系统等领域,但弹道导弹、无人机等目标成像距离较远,在红外图像上呈现为点目标,且易受空间噪声的干扰,使得这类目标的检测存在较大的难度。

在红外小目标检测上,国内外学者做了大量的工作,取得了斐然的成果。目前红外小目标的检测主要分为两类:基于单帧和基于序列的红外小目标检测。基于单帧的红外小目标检测通过分析目标与背景之间的空域差异性来实现对小目标的检测,目前主要有基于滤波、基于人类视觉、基于低秩与稀疏恢复以及深度学习四类小目标检测方法。基于序列在单帧检测的基础上,结合目标的时域特性实现对目标的检测,代表算法有管道滤波法^[1]、动态规划法^[2]、三维匹配滤波法^[3]以

及时空滤波法^[4],相较于单帧检测算法,多帧检测算法的可信度较高,但是对于缓慢移动的目标和低信噪比图像,检测率仍有待提高,且实时性较单帧检测而言较差。

Top-Hat 滤波法^[5]以及最大中值(max-median)滤波法^[6]是基于单帧的滤波算法,能够较好地增强目标,但对杂波的抑制效果差。文献[7]提出了一种能够通过迭代自适应估计背景的二维最小均方(two dimensional least mean square, TDLMS)滤波器。文献[8]在 TDLMS 的基础上,利用预测值与图像的残差建立权重模板,能有效地检测小目标,但在复杂背景云层背景下,难以权衡检测率和收敛速度。依靠人类视觉机制,文献[9]提出了一种基于局部对比度测量(local contrast measure, LCM)的检测方法,通过分

析当前区域与8邻域灰度值的差异性,增强亮目标和暗目标,但不能有效地应对复杂背景下的小目标检测问题。在此基础上,文献[10]提出了一种基于相对LCM的检测算法,通过分析计算8邻域图像块的相对对比度来达到增强小目标的目的,同时结合多尺度方法,进一步增强算法的鲁棒性。文献[11]引入目标的局部突变熵,提出了加权局部对比度测量(weighted local contrast measure, WLCM)算法,能够消除图像中边缘以及部分角点造成的虚警,提高了小目标检测的鲁棒性。文献[12-13]也对LCM算法进行了改进,虽然这些改进算法在一定程度上提高了对环境的鲁棒性,但对于对比度较低的小目标检测效果依然不如人意。文献[14]首次将稀疏重建与低秩恢复方法引入红外小目标检测,提出了一种红外图像块(infrared patch-image, IPI)算法,该算法可以较好地实现对小目标的检测,但是矩阵的求逆往往需要耗费大量时间,对于高分辨率的图像处理较慢。文献[15]将基于二维的IPI模型拓展到三维空间提出了红外图像张量块(infrared patch-tensor image)模型,该模型能够结合局部信息和全局信息对小目标实现检测,但是对存在非平滑区域的红外图像,该模型依旧无法有效地抑制杂波。文献[16]使用三维全变分原则,利用红外图像序列构建三维红外张量模型,引入结构张量约束目标张量,但对平台的移动敏感。于是文献[17]提出了一种基于非对称时空全变分正则化的非凸张量低秩估计(asymmetric spatial-temporal total variation regularized non-convex tensor low-rank approximation, ASTTV-NTLA)的红外小目标检测算法,利用时空的非对称性,降低算法对平台移动的敏感性,但是应对强边缘处理效果不佳。近年来,使用深度学习进行红外小目标的方法不断涌现,文献[18]提出了一种两阶段的红外小目标检测方法,通过卷积神经网络(convolutional neural network, CNN)提取图像的疑似区域,再使用支持向量机(support vector machine, SVM)筛选疑似区域检测目标。文献[19]设计了一种7层的CNN,能够端到端地自动提取小目标特征并且抑制杂波。文献[20]则通过改进YOLOv3-tiny网络中的特征提取部分,使用更多尺度对小目标进行检测,但是当目标尺寸过小时,以上深度学习方法依旧具有较高虚警率。

针对复杂背景下的红外小目标检测问题,

本文在ASTTV-NTLA算法的基础上,提出了一种基于张量奇异值指数倒数的核范数估计方式代替原算法的估计方式,提出了一种基于结构张量与多结构元Top-Hat滤波的目标自适应权重对目标张量进行约束,增强目标张量的稀疏性,在保证原算法检测率的情况下,有效地降低了虚警率。

1 张量基础知识介绍

1.1 张量基本概念

为了便于读者理解,使用小写字母表示向量,如 \mathbf{a} ;用大写字母表示矩阵,如 \mathbf{A} ;用带下标T的大写字母表示张量,如 \mathbf{A}_T ;用 \mathbb{R} 表示实数域。于是,一个三维张量可以表示为 $\mathbf{A}_T \in \mathbb{R}^{n_1 \times n_2 \times n_3}$,其基于三个维度构建的纤维可以分别表示为 $\mathbf{A}_T(n_1, :, :)$, $\mathbf{A}_T(:, n_2, :)$ 和 $\mathbf{A}_T(:, :, n_3)$,其基于三个维度构建的切面也可以分别表示为 $\mathbf{A}_T(n_1, n_2, :)$, $\mathbf{A}_T(:, n_2, n_3)$ 以及 $\mathbf{A}_T(n_1, :, n_3)$ 。设张量的第 i 个切片可以表示为 $\mathbf{A}^{(i)}$,则张量的展开与折叠操作为:

$$\begin{cases} \text{unfold}(\mathbf{A}_T) = \begin{bmatrix} \mathbf{A}^{(1)} \\ \mathbf{A}^{(2)} \\ \vdots \\ \mathbf{A}^{(n_3)} \end{bmatrix} \\ \text{fold}[\text{unfold}(\mathbf{A}_T)] = \mathbf{A}_T \end{cases} \quad (1)$$

张量 $\mathbf{A}_T \in \mathbb{R}^{n_1 \times n_2 \times n_3}$ 的 l_0 范数表示张量当中非零元素的个数, l_1 范数的定义为:

$$\|\mathbf{A}_T\|_1 = \sum_{ijk} |a_{ijk}| \quad (2)$$

其Frobenius范数的定义为:

$$\|\mathbf{A}_T\|_F = \sqrt{\sum_{ijk} |a_{ijk}|^2} \quad (3)$$

对于张量 $\mathbf{A}_T \in \mathbb{R}^{n_1 \times n_2 \times n_3}$,其傅里叶变换可以根据其第三维度的傅里叶变换得到,即 \mathbf{A}_T 所有管纤维进行傅里叶变换,MATLAB调用命令为:

$$\overline{\mathbf{X}}_T = \text{fft}(\mathbf{X}_T, [], 3) \quad (4)$$

同样地,其傅里叶逆变换为 $\mathbf{X}_T = \text{ifft}(\overline{\mathbf{X}}_T, [], 3)$ 。

张量的bding算子为张量的块对角矩阵算子,对于 $\mathbf{A}_T \in \mathbb{R}^{n_1 \times n_2 \times n_3}$,其块对角矩阵中的第 i 个块对角为张量第 i 个正面切片的傅里叶变换矩阵组成,具体为:

$$\overline{\mathbf{A}} = \text{bding}(\mathbf{A}_T) = \begin{bmatrix} \overline{\mathbf{A}}^{(1)} & & & \\ & \overline{\mathbf{A}}^{(2)} & & \\ & & \ddots & \\ & & & \overline{\mathbf{A}}^{(n_3)} \end{bmatrix} \quad (5)$$

则张量的块循环矩阵由bcirc算子计算得到,

其定义为:

$$bcirc(\mathbf{A}_T) = \begin{bmatrix} \bar{\mathbf{A}}^{(1)} & \bar{\mathbf{A}}^{(n_3)} & \dots & \bar{\mathbf{A}}^{(2)} \\ \bar{\mathbf{A}}^{(2)} & \bar{\mathbf{A}}^{(1)} & \dots & \bar{\mathbf{A}}^{(3)} \\ \vdots & \vdots & \ddots & \vdots \\ \bar{\mathbf{A}}^{(n_3)} & \bar{\mathbf{A}}^{(n_3-1)} & \dots & \bar{\mathbf{A}}^{(1)} \end{bmatrix} \quad (6)$$

若张量 $\mathbf{I}_T \in \mathbb{R}^{n_1 \times n_2 \times n_3}$ 的第一个正面切片 $\mathbf{A}^{(1)}$ 是一个单位矩阵,且张量的其他元素为 0,则称该张量为单位张量;对于正交张量,其满足如下条件: $\mathbf{Q}_T^* * \mathbf{Q}_T = \mathbf{Q}_T * \mathbf{Q}_T^* = \mathbf{I}_T$;若张量 $\mathbf{F}_T \in \mathbb{R}^{n_1 \times n_2 \times n_3}$ 的每一个正面切片都为对角矩阵,则称之为 \mathbf{F} 对角张量。

1.2 张量运算法则

对于两个张量 $\mathbf{A}_T \in \mathbb{R}^{n_1 \times n_2 \times n_3}$ 以及 $\mathbf{B}_T \in \mathbb{R}^{n_2 \times l_n \times n_3}$,其乘积可以表示为 $\mathbf{C}_T = \mathbf{A}_T * \mathbf{B}_T$,其中 \mathbf{C}_T 是一个 $n_1 \times l_n \times n_3$ 的张量,并且有:

$$\mathbf{C}_T = \mathbf{A}_T * \mathbf{B}_T = fold[bcirc(\mathbf{A}_T) \cdot unfold(\mathbf{B}_T)] \quad (7)$$

如图 1 所示,对于张量 $\mathbf{A}_T \in \mathbb{R}^{n_1 \times n_2 \times n_3}$ 可以将其奇异值分解(tensor singular value decomposition, T-SVD)定义为:

$$\mathbf{A}_T = \mathbf{U}_T * \mathbf{S}_T * \mathbf{V}_T^* \quad (8)$$

式中, $\mathbf{U}_T \in \mathbb{R}^{n_1 \times n_1 \times n_3}$ 和 $\mathbf{V}_T \in \mathbb{R}^{n_2 \times n_2 \times n_3}$ 是正交张量, $\mathbf{S}_T \in \mathbb{R}^{n_1 \times n_2 \times n_3}$ 是对角张量。

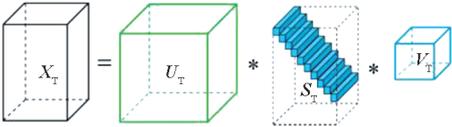


图 1 张量的奇异值分解

Fig. 1 Singular value decomposition of tensors

定义张量的核范数为:

$$\begin{aligned} \|\mathbf{A}_T\|_* &= \langle \mathbf{S}_T, \mathbf{I}_T \rangle = \sum_{i=1}^r \mathbf{S}_T(i, i, 1) \\ &= \frac{1}{n_3} \sum_{i=1}^r \sum_j^{n_3} \mathbf{S}_T(i, i, j) \end{aligned} \quad (9)$$

式中, $\langle \cdot \rangle$ 表示内积操作。

2 方法提出与求解

2.1 ASTTV-NTLA 红外小目标检测方法

对于一幅红外图像 \mathbf{F} ,其可以由背景图像 \mathbf{F}_b 、目标图像 \mathbf{F}_t 以及噪声图像 \mathbf{F}_n 表示,即:

$$\mathbf{F} = \mathbf{F}_b + \mathbf{F}_t + \mathbf{F}_n \quad (10)$$

由于红外传感器通过捕捉物体向空间辐射的能量进行成像,对于同一视场内的背景,向空间辐射的能量差异小,在图像上具有较强的相关性,因此背景

图像往往是低秩的。而对于无人机等目标,通常其向外辐射的能量较背景更多,且成像距离较远,目标图像往往只存在少数非零像素点,具有稀疏性。同样地,对于三维红外图像序列,其分解模型为:

$$\mathbf{F}_T = \mathbf{B}_T + \mathbf{T}_T + \mathbf{N}_T \quad (11)$$

式中: $\mathbf{F}_T, \mathbf{B}_T, \mathbf{T}_T, \mathbf{N}_T \in \mathbb{R}^{n_1 \times n_2 \times n_3}$ 分别代表原始图像张量、背景张量、目标张量以及噪声张量; n_1, n_2, n_3 分别代表张量的三个维度大小,文中分别指图像的宽度、长度以及序列的帧数。同样地,背景张量与目标张量分别满足低秩性与稀疏性,于是小目标的检测可以通过如下优化方法实现:

$$\begin{aligned} \mathbf{B}_T, \mathbf{T}_T, \mathbf{N}_T &= \underset{\mathbf{B}_T, \mathbf{T}_T, \mathbf{N}_T}{\operatorname{argmin}} rank(\mathbf{B}_T) + \lambda_s \|\mathbf{T}_T\|_0 + \lambda_3 \|\mathbf{N}_T\|_F^2 \\ \text{s. t. } &\mathbf{F}_T = \mathbf{B}_T + \mathbf{T}_T + \mathbf{N}_T \end{aligned} \quad (12)$$

但是式(12)是一个非确定多项式(non-deterministic polynomial, N-P)难题,直接求解十分困难,于是上式可以转化为求其松弛问题的解,即

$$\begin{aligned} \mathbf{B}_T, \mathbf{T}_T, \mathbf{N}_T &= \underset{\mathbf{B}_T, \mathbf{T}_T, \mathbf{N}_T}{\operatorname{argmin}} \|\mathbf{B}_T\|_* + \lambda_s \|\mathbf{T}_T\|_0 + \lambda_3 \|\mathbf{N}_T\|_F^2 \\ \text{s. t. } &\mathbf{F}_T = \mathbf{B}_T + \mathbf{T}_T + \mathbf{N}_T \end{aligned} \quad (13)$$

式中,

$$\|\mathbf{B}_T\|_* = \frac{1}{n_3} \sum_{k=1}^{n_3} \|\bar{\mathbf{B}}^{(k)}\| \quad (14)$$

表示背景张量的核范数,基于式(13),非对称时空全变分正则化非凸张量低秩估计通过拉普拉斯函数对核范数进行加权,并引入非对称时空全变分正则项保留背景当中的边缘结构,构建了如式(15)所示优化方法。

$$\begin{aligned} \mathbf{B}_T, \mathbf{T}_T, \mathbf{N}_T &= \underset{\mathbf{B}_T, \mathbf{T}_T, \mathbf{N}_T}{\operatorname{argmin}} \|\mathbf{B}_T\|_{\gamma, *}, * + \lambda_{iv} \|\mathbf{B}_T\|_{ASTTV} + \\ &\lambda_s \|\mathbf{T}_T\|_1 + \lambda_3 \|\mathbf{N}_T\|_F^2 \\ \text{s. t. } &\mathbf{F}_T = \mathbf{B}_T + \mathbf{T}_T + \mathbf{N}_T \end{aligned} \quad (15)$$

式中, λ_{iv} 为惩罚系数, $\|\mathbf{B}_T\|_{ASTTV}$ 表示非对称时空全变分正则项。等式右边第一项代表加权张量核范数,通过使用拉普拉斯函数,对不同的奇异值赋予相应的权重,可以有效解决张量核范数所导致的奇异值“过度收缩”问题,其表达式为:

$$\begin{aligned} \|\mathbf{B}_T\|_{\gamma, *}, * &= \sum_{k=1}^{n_3} \sum_i^{\min(n_1, n_2)} \phi[\sigma_i(\bar{\mathbf{B}}^k)] \\ &= \sum_{k=1}^{n_3} \sum_i^{\min(n_1, n_2)} \phi[1 - e^{-\sigma_i(\bar{\mathbf{B}}^k)/\varepsilon}] \end{aligned} \quad (16)$$

式中, σ_i 表示第 i 大的奇异值。全变分正则化约束主要用于处理图像中的噪声,经改进后,广泛用于图像恢复中的边缘保持问题,三维张量的全变分定义为:

$$\|\mathbf{B}_T\|_{STTV} = \sum_{i,j,k} \{ \|\mathbf{D}_h \mathbf{B}_T\|_1 + \|\mathbf{D}_v \mathbf{B}_T\|_1 + \|\mathbf{D}_z \mathbf{B}_T\|_1 \} \quad (17)$$

其中

$$\begin{cases} D_h \mathbf{B}_T = \mathbf{B}_T(i, j, k) - \mathbf{B}_T(i + 1, j, k) \\ D_v \mathbf{B}_T = \mathbf{B}_T(i, j, k) - \mathbf{B}_T(i, j + 1, k) \\ D_z \mathbf{B}_T = \mathbf{B}_T(i, j, k) - \mathbf{B}_T(i, j, k + 1) \end{cases} \quad (18)$$

分别表示图像沿张量正面切片水平、垂直以及时间轴方向上的全变分算子。ASTTV-NTLA 算法认为时空域具有不对称性,对于三个变分算子,应给予不同的权重,设空域 x, y 轴方向上算子权重为 1,于是提出了非对称的全变分算子:

$$\|\mathbf{B}_T\|_{ASTTV} = \sum_{i,j,k} \{ \|\mathbf{D}_h \mathbf{B}_T\|_1 + \|\mathbf{D}_v \mathbf{B}_T\|_1 + \delta \|\mathbf{D}_z \mathbf{B}_T\|_1 \} \quad (19)$$

2.2 改进的 ASTTV-NTLA 红外小目标检测方法

针对核范数存在的“过度收敛”问题,本文提出了一种新的核范数加权估计方式,同时在 ASTTV-NTLA 方法的基础上,根据图像的先验知识,提出了一种基于结构张量与多结构元 Top-Hat 的目标自适应权重约束目标张量,在保证原算法检测率的情况下降低了虚警率。

2.2.1 基于指数倒数加权的核范数估计

由于张量的大奇异值往往代表图像中的细节部分,如小目标、边缘等结构,因此在背景张量中应尽可能地对其进行惩罚。本小节提出了一种新的核范数加权方式指数倒数加权,该加权方式能够惩罚背景张量中较大的奇异值,其表达式为:

$$\|\mathbf{B}_T\|_{*,Exp} = \sum_{k=1}^{n_3} \sum_r^{\min(n_1, n_2)} \phi(e^{-\frac{\sigma}{|\sigma_i(B^k)|}}) \quad (20)$$

图 2 所示为所提加权核范数估计与 $\ln(\cdot)$ 运算加权核范数估计、基于张量奇异值 l_1 范数加权的对比示意图。由图 2 可知,所提的核范数估计方式可以很好地惩罚张量的大奇异值,逼近张量奇异值的 l_0 范数从而达到估计张量秩的目的。

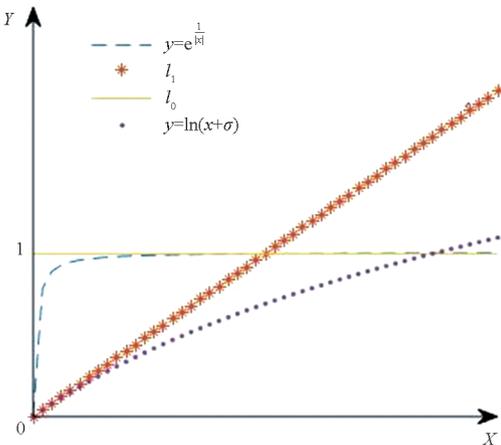


图 2 矩阵奇异值的 l_0 范数、 l_1 范数以及 \ln 运算和指数倒数加权的核范数

Fig. 2 l_0 norm, l_1 norm and \ln operation and reciprocal weighted kernel norm of matrix singular value

2.2.2 基于结构张量与多结构元 Top-Hat 的目标自适应权重

结构张量(structure tensor, ST)又称为图像的第二矩阵,是通过计算每个像素点四个二阶导数所构建的一个 2×2 的矩阵,其定义为:

$$\mathbf{S} = G_\sigma \left(\begin{bmatrix} g_x \\ g_y \end{bmatrix} \begin{bmatrix} g_x \\ g_y \end{bmatrix}^T \right) = \begin{bmatrix} T_{11} & T_{12} \\ T_{21} & T_{22} \end{bmatrix} \quad (21)$$

式中: g_x, g_y 分别为当前像素点在 x 和 y 方向上的梯度; G_σ 表示高斯模糊函数, σ 为高斯核的标准差。则结构张量矩阵的两个特征值分别为:

$$\begin{cases} \lambda_1 = \frac{1}{2} [T_{22} + T_{11} + \sqrt{(T_{22} - T_{11})^2 + 4T_{12}^2}] \\ \lambda_2 = \frac{1}{2} [T_{22} + T_{11} - \sqrt{(T_{22} - T_{11})^2 + 4T_{12}^2}] \end{cases} \quad (22)$$

根据 λ_1, λ_2 的相对大小关系可以确定像素所处区域的结构信息。在平坦区域,满足 $\lambda_1 \approx \lambda_2 \approx 0$; 在边缘区域, $\lambda_1 \gg \lambda_2 \approx 0$; 在角点区域, $\lambda_1 \gg \lambda_2 \gg 0$ 。根据这一特性,文献[21]采用

$$\mathbf{W}_{st} = \max(\lambda_1, \lambda_2) \frac{\lambda_1 \lambda_2}{\lambda_1 + \lambda_2} \quad (23)$$

构建目标权重矩阵,该权重在大多数场景下可以较好地抑制图像中的边缘结构。但是对于地面等复杂背景,该加权方式显得有些力不从心,于是本节提出了一种基于结构张量与多结构元 Top-Hat 滤波的目标自适应权重。首先根据式(23)得到目标的局部结构张量权重,然后使用多结构元 Top-Hat 滤波得到图像的综合响应 \mathbf{W}_{1-h} 。

$$\mathbf{W}_{1-h} = \max\{\mathbf{W}_{1-h_1}, \mathbf{W}_{1-h_2}, \dots, \mathbf{W}_{1-h_n}\} \quad (24)$$

式中, $\mathbf{W}_{1-h_i} = \mathbf{F} - [(\mathbf{F} \Theta se_i) \oplus se_i]$, \mathbf{F} 表示红外图像, se_i 表示第 i 个结构元素, Θ 和 \oplus 分别代表腐蚀和膨胀操作。

使用如图 3 所示的四种结构元素。计算式(23)和式(24)的 Hadamard 乘积。

$$\mathbf{W}_t = \mathbf{W}_{st} \odot \mathbf{W}_{1-h} \quad (25)$$

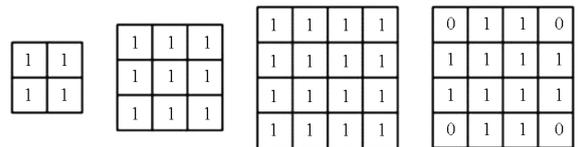


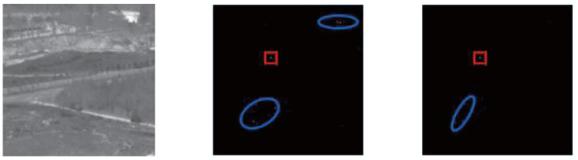
图 3 本文所使用的四种结构元素

Fig. 3 Four structural elements used in this paper

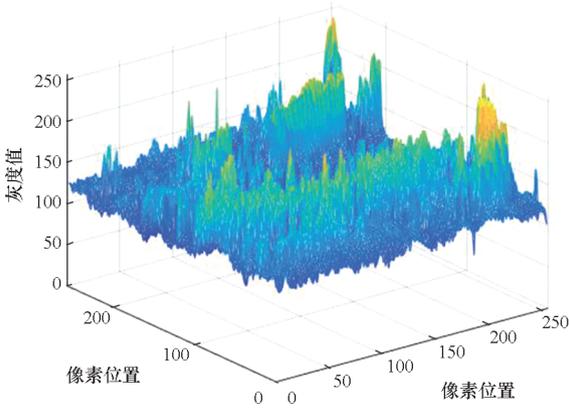
对式(25)进行归一化处理得到目标的权重矩阵

$$\mathbf{W}_t = \frac{\mathbf{W}_t - \mathbf{W}_{tmin}}{\mathbf{W}_{tmax} - \mathbf{W}_{tmin}} \quad (26)$$

式中, $\mathbf{W}_{tmin}, \mathbf{W}_{tmax}$ 分别代表矩阵 \mathbf{W}_t 的最小值和最大值。图 4 为实验序列中典型帧分别采用式(23)和式(26)所构建的目标权重对比图。由

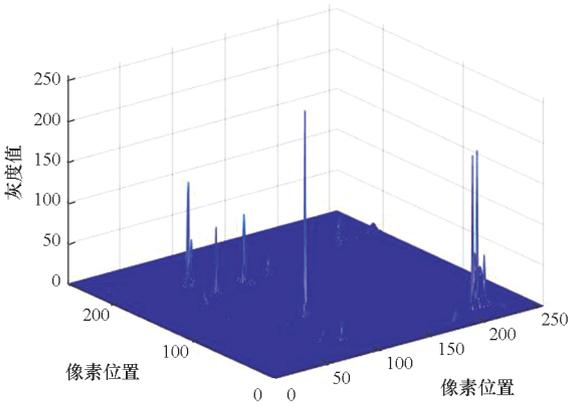


(a) 原图 (b) 式(23)计算结果 (c) 式(26)计算结果
 (a) Raw image (b) Result of equation (23) (c) Result of equation (26)



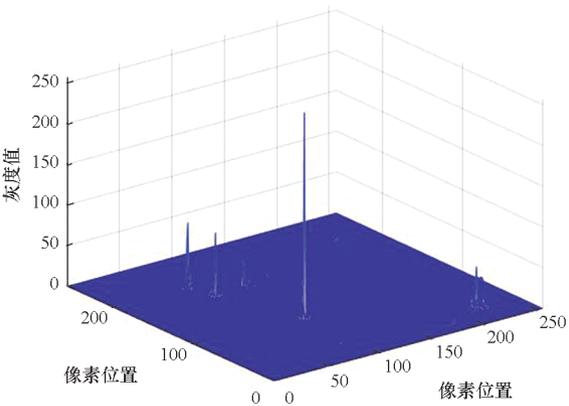
(d) 图(a)的三维图

(d) Three-dimensional view of fig. (a)



(e) 图(b)的三维图

(e) Three-dimensional view of fig. (b)



(f) 图(c)的三维图

(f) Three-dimensional view of fig. (c)

图 4 目标权重对比图

Fig. 4 Comparison chart of target weights

图 4 可知,采用式(26)所构建的目标权重矩阵能更好地抑制图像中的强边缘结构。

2.2.3 所提方法流程

本文提出了一种改进的 ASTTV-NTLA 方法,其优化方法定义为:

$$\begin{aligned} \mathbf{B}_T, \mathbf{T}_T, \mathbf{N}_T = \min_{\mathbf{B}_T, \mathbf{T}_T, \mathbf{N}_T} & \|\mathbf{B}_T\|_{*, \text{Exp}} + \lambda_T \|\mathbf{W}_T \odot \mathbf{T}_T\|_1 + \\ & \lambda_N \|\mathbf{N}_T\|_F + \lambda_D \|\mathbf{D}_h(\mathbf{B}_T) + \mathbf{D}_v(\mathbf{B}_T) + \delta \mathbf{D}_z(\mathbf{B}_T)\|_1 \\ \text{s. t.} & \mathbf{F}_T = \mathbf{B}_T + \mathbf{T}_T + \mathbf{N}_T \end{aligned} \quad (27)$$

式中, $\lambda_T, \lambda_D, \lambda_N$ 分别为背景核范数、目标 l_1 范数以及噪声 Frobenius 范数的惩罚系数,具体数值设置将在 3.2 节中提及。

整个红外小目标的检测算法流程如图 5 所示,模型首先根据连续的图像帧序列构建原始张量,然后根据 2.2.2 节设计的算法,再通过交替方向乘法 (alternating direction method of multipliers, ADMM) 求解模型,得到背景张量、目标张量以及噪声张量,最后通过对目标张量进行自适应阈值分割得到目标信息。

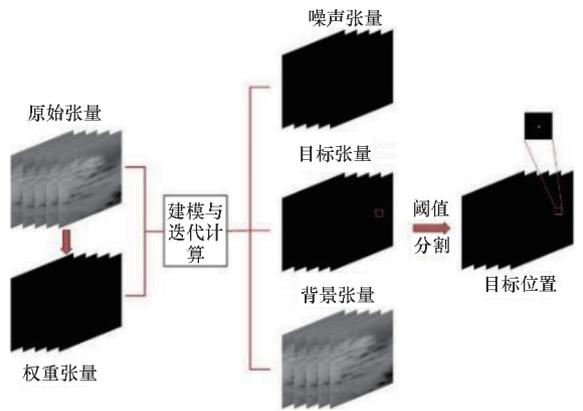


图 5 本文算法流程示意图

Fig. 5 Schematic diagram of algorithm flow in this paper

2.3 方法求解

对于式(27),采用 ADMM 求解,为了便于背景求解以及变分求解,引入辅助变量 $\mathbf{Z}_T = \mathbf{B}_T$, $\mathbf{D}_{1T} = \mathbf{D}_h \mathbf{B}_T$, $\mathbf{D}_{2T} = \mathbf{D}_v \mathbf{B}_T$ 以及 $\mathbf{D}_{3T} = \mathbf{D}_z \mathbf{B}_T$, 则式(27)可表示为:

$$\begin{aligned} \mathbf{B}_T, \mathbf{T}_T, \mathbf{N}_T = \min_{\mathbf{B}_T, \mathbf{T}_T, \mathbf{N}_T} & \|\mathbf{B}_T\|_{*, \text{Exp}} + \lambda_T \|\mathbf{W}_T \odot \mathbf{T}_T\|_1 + \lambda_N \|\mathbf{N}_T\|_F + \\ & \lambda_D \|\mathbf{D}_h(\mathbf{B}_T) + \mathbf{D}_v(\mathbf{B}_T) + \delta \mathbf{D}_z(\mathbf{B}_T)\|_1 \\ \text{s. t.} & \begin{cases} \mathbf{Z}_T = \mathbf{B}_T \\ \mathbf{D}_{1T} = \mathbf{D}_h \mathbf{B}_T \\ \mathbf{D}_{2T} = \mathbf{D}_v \mathbf{B}_T \\ \mathbf{D}_{3T} = \mathbf{D}_z \mathbf{B}_T \\ \mathbf{F}_T = \mathbf{B}_T + \mathbf{T}_T + \mathbf{N}_T \end{cases} \end{aligned} \quad (28)$$

则构造相应的增广拉格朗日方程:

$$\begin{aligned}
& L_{\Lambda}(\mathbf{B}_T, \mathbf{T}_T, \mathbf{N}_T, \mathbf{Z}_T, \mathbf{D}_{1T}, \mathbf{D}_{2T}, \mathbf{D}_{3T}) \\
= & \|\mathbf{Z}_T\|_{*, \text{Exp}} + \lambda_T \|\mathbf{W}_T \odot \mathbf{T}_T\|_1 + \lambda_D \|\mathbf{D}_{1T} + \mathbf{D}_{2T} + \delta \mathbf{D}_{3T}\|_1 + \\
& \lambda_N \|\mathbf{N}_T\|_F^2 + \langle \mathbf{Y}_{1T}, \mathbf{Z}_T - \mathbf{B}_T \rangle + \langle \mathbf{Y}_{2T}, \mathbf{D}_{1T} - \mathbf{D}_h \mathbf{B}_T \rangle + \\
& \langle \mathbf{Y}_{3T}, \mathbf{D}_{2T} - \mathbf{D}_v \mathbf{B}_T \rangle + \langle \mathbf{Y}_{4T}, \mathbf{D}_{3T} - \mathbf{D}_z \mathbf{B}_T \rangle + \\
& \langle \mathbf{Y}_{5T}, \mathbf{F}_T - \mathbf{B}_T - \mathbf{T}_T - \mathbf{N}_T \rangle + \frac{\mu}{2} (\|\mathbf{Z}_T - \mathbf{B}_T\|_F^2 + \\
& \|\mathbf{D}_{1T} - \mathbf{D}_h \mathbf{B}_T\|_F^2 + \|\mathbf{D}_{2T} - \mathbf{D}_v \mathbf{B}_T\|_F^2 + \\
& \|\mathbf{D}_{3T} - \mathbf{D}_z \mathbf{B}_T\|_F^2 + \|\mathbf{F}_T - \mathbf{B}_T - \mathbf{T}_T - \mathbf{N}_T\|_F^2) \quad (29)
\end{aligned}$$

1) 根据 ADMM, 首先求解变量 \mathbf{Z}_T , 固定式(29)中的其他变量为常量, 提取含有变量 \mathbf{Z}_T 的项可得到:

$$\begin{aligned}
\mathbf{Z}_T^{k+1} = & \underset{\mathbf{Z}_T}{\text{argmin}} \|\mathbf{Z}_T\|_{*, \text{Exp}} + \langle \mathbf{Y}_{1T}^k, \mathbf{Z}_T - \mathbf{B}_T^k \rangle + \\
& \frac{\mu}{2} \|\mathbf{Z}_T - \mathbf{B}_T^k\|_F^2 \\
= & \|\mathbf{Z}_T\|_{*, \text{Exp}} + \frac{\mu}{2} \left[\mathbf{Z}_T - \left(\mathbf{B}_T^k - \frac{\mathbf{Y}_{1T}^k}{\mu} \right) \right] \quad (30)
\end{aligned}$$

式(30)可以转化为张量的核范数极小化优化问题, 设 $\mathbf{X}_T = \mathbf{B}_T^k - \frac{\mathbf{Y}_{1T}^k}{\mu}$, 其优化过程如算法1所示。

算法1 加权核范数

Alg.1 Weight nuclear norm

输入: $\mathbf{X}_T \in \mathbb{R}^{n_1 \times n_2 \times n_3}$, ε

输出: \mathbf{Z}_T^{k+1}

1. 计算 $\bar{\mathbf{X}}_T = \text{fft}(\mathbf{X}_T, [\cdot], 3)$
 2. 采用 SVD 方法对张量 \mathbf{X}_T 的所有正面切片进行分解, 过程如下:

for $n = 1, \dots, \lceil \frac{n_3 + 1}{2} \rceil$ do

$$(1) [\bar{\mathbf{U}}^{(n)}, \bar{\mathbf{S}}^{(n)}, \bar{\mathbf{V}}^{(n)}] = \text{SVD}(\bar{\mathbf{X}}_T^{(n)})$$

(2) compute $\bar{\mathbf{D}}_{\text{V}\sigma_p, k}^{(n)}$

$$\bar{\mathbf{D}}_{\text{V}\sigma_p, k}^{(n)} = (\bar{\mathbf{S}}^{(n)}(i, j, k) - \nabla \sigma_i^{n, k})_+$$

$$(3) (\bar{\mathbf{Z}}^{k+1})^{(n)} = \bar{\mathbf{U}}^{(n)} * \bar{\mathbf{D}}_{\text{V}\sigma_p, k}^{(n)} * \bar{\mathbf{V}}^{(n)}$$

end for

for $n = \lceil \frac{n_3 + 1}{2} \rceil + 1, \dots, n_3$ do

$$(\bar{\mathbf{Z}}^{k+1})^{(n)} = \text{conj}((\bar{\mathbf{Z}}^{k+1})^{(n_3 - n + 2)})$$

end for

3. 计算 $\mathbf{Z}_T^{k+1} = \text{ifft}(\bar{\mathbf{Z}}^{k+1}, [\cdot], 3)$

2) 更新变量 \mathbf{B}_T , 提取式(29)中含有 \mathbf{B}_T 的项, 可以构建如下线性问题:

$$\begin{aligned}
(2\mathbf{I} + \mathbf{D}_h^T \mathbf{D}_h + \mathbf{D}_v^T \mathbf{D}_v + \mathbf{D}_z^T \mathbf{D}_z) \mathbf{B}_T = \\
\left(\mathbf{Z}_T^{k+1} + \frac{\mathbf{Y}_{1T}^k}{\mu} + \mathbf{F}_T - \mathbf{T}_T^k - \mathbf{N}_T^k + \frac{\mathbf{Y}_{5T}^k}{\mu} \right) +
\end{aligned}$$

$$\begin{aligned}
\mathbf{D}_h^T \left(\mathbf{D}_{1T}^k + \frac{\mathbf{Y}_{2T}^k}{\mu} \right) + \mathbf{D}_v^T \left(\mathbf{D}_{2T}^k + \frac{\mathbf{Y}_{3T}^k}{\mu} \right) + \mathbf{D}_z^T \left(\mathbf{D}_{3T}^k + \frac{\mathbf{Y}_{4T}^k}{\mu} \right) \quad (31)
\end{aligned}$$

式中, \mathbf{D}_h^T , \mathbf{D}_v^T , \mathbf{D}_z^T 分别为 \mathbf{D}_h , \mathbf{D}_v , \mathbf{D}_z 的转置。式(31)可以通过三维傅里叶变换求解, 即

$$\begin{cases}
\mathbf{H}_T = \left(\mathbf{Z}_T^{k+1} + \frac{\mathbf{Y}_1^k}{\mu} + \mathbf{F}_T - \mathbf{T}_T^k - \mathbf{N}_T^k + \frac{\mathbf{Y}_{5T}^k}{\mu} \right) + \\
\mathbf{D}_h^T \left(\mathbf{D}_{1T}^k + \frac{\mathbf{Y}_{2T}^k}{\mu} \right) + \mathbf{D}_v^T \left(\mathbf{D}_{2T}^k + \frac{\mathbf{Y}_{3T}^k}{\mu} \right) + \\
\mathbf{D}_z^T \left(\mathbf{D}_{3T}^k + \frac{\mathbf{Y}_{4T}^k}{\mu} \right) \\
\mathbf{K}_T = |\text{fftn}(\mathbf{D}_h)|^2 + |\text{fftn}(\mathbf{D}_v)|^2 + |\text{fftn}(\mathbf{D}_z)|^2 \\
\mathbf{B}_T^{k+1} = \text{ifftn} \left[\frac{\text{fftn}(\mathbf{H}_T)}{2\mathbf{I}_T + \mathbf{K}_T} \right]
\end{cases} \quad (32)$$

其中, fftn 和 ifftn 分别表示三维傅里叶变换及其逆变换。

3) 更新目标张量 \mathbf{T}_T , 提取式(29)中含有 \mathbf{T}_T 的项, 有:

$$\begin{aligned}
\mathbf{T}_T^{k+1} = & \underset{\mathbf{T}_T}{\text{argmin}} \lambda_i \|\mathbf{W} \odot \mathbf{T}_T\|_1 + \\
& \frac{\mu}{2} \left\| \mathbf{T}_T^k - \left(\mathbf{F}_T - \mathbf{B}_T^{k+1} - \mathbf{N}_T^k + \frac{\mathbf{Y}_{5T}^k}{\mu} \right) \right\|_F^2 \quad (33)
\end{aligned}$$

根据软阈值算法有:

$$\mathbf{T}_T^{k+1} = \text{Th}_{\lambda_i, \mathbf{W}_T(\mu^k)}^{-1} \left(\mathbf{F}_T - \mathbf{B}_T^{k+1} - \mathbf{N}_T^k + \frac{\mathbf{Y}_{5T}^k}{\mu} \right) \quad (34)$$

4) 更新辅助变量 $\mathbf{D}_{1T}, \mathbf{D}_{2T}, \mathbf{D}_{3T}$, 有:

$$\begin{cases}
\mathbf{D}_{1T}^{k+1} = \text{Th}_{\lambda_d(\mu^k)}^{-1} \left(\mathbf{D}_h \mathbf{B}_T^{k+1} - \frac{\mathbf{Y}_{2T}^k}{\mu} \right) \\
\mathbf{D}_{2T}^{k+1} = \text{Th}_{\lambda_d(\mu^k)}^{-1} \left(\mathbf{D}_h \mathbf{B}_T^{k+1} - \frac{\mathbf{Y}_{3T}^k}{\mu} \right) \\
\mathbf{D}_{3T}^{k+1} = \text{Th}_{\delta \lambda_d(\mu^k)}^{-1} \left(\mathbf{D}_h \mathbf{B}_T^{k+1} - \frac{\mathbf{Y}_{4T}^k}{\mu} \right)
\end{cases} \quad (35)$$

5) 更新噪声张量 \mathbf{N}_T , 提取式(29)中含有 \mathbf{N}_T 的项, 有:

$$\begin{aligned}
\mathbf{N}_T^{k+1} = & \underset{\mathbf{N}_T}{\text{argmin}} \left(\lambda_n + \frac{\mu}{2} \right) \times \\
& \left\| \mathbf{N}_T - \frac{\mu \left(\mathbf{F}_T - \mathbf{B}_T^{k+1} - \mathbf{T}_T^{k+1} + \frac{\mathbf{Y}_{5T}^k}{\mu} \right)}{2\lambda_n + \mu} \right\|_F^2 \quad (36)
\end{aligned}$$

显而易见, 当

$$\mathbf{N}_T^{k+1} = \frac{\mu \left(\mathbf{F}_T - \mathbf{B}_T^{k+1} - \mathbf{T}_T^{k+1} + \frac{\mathbf{Y}_{5T}^k}{\mu} \right)}{2\lambda_n + \mu} \quad (37)$$

时, 式(36)有最小值0。

6)更新拉格朗日乘子组,有:

7)更新 μ ,有:

$$\begin{cases} Y_{1T}^{k+1} = Y_{1T}^k + \mu^k (Z_T^{k+1} - B_T^{k+1}) \\ Y_{2T}^{k+1} = Y_{2T}^k + \mu^k (D_T^{k+1} - D_h B_T^{k+1}) \\ Y_{3T}^{k+1} = Y_{3T}^k + \mu^k (D_T^{k+1} - D_v B_T^{k+1}) \\ Y_{4T}^{k+1} = Y_{4T}^k + \mu^k (D_T^{k+1} - D_z B_T^{k+1}) \\ Y_{5T}^{k+1} = Y_{5T}^k + \mu^k (F_T - B_T^{k+1} - T_T^{k+1} - N_T^{k+1}) \end{cases} \quad (38)$$

$$\mu^{k+1} = \min(\rho\mu^k, \mu_{\max}) \quad (39)$$

3 实验结果与分析

3.1 数据集介绍与评价指标

3.1.1 数据集介绍

选取 5 组实验数据对算法进行测试,表 1 为 5 组序列的详细介绍。

表 1 红外数据集介绍

Tab. 1 Information of infrared data sets

序列	图像大小	帧数	目标大小	目标描述	背景描述	局部信噪比范围
1	512 × 640	180	3 × 3 ~ 6 × 6	变速小目标	厚云层,边缘明显	0.87 ~ 1.35
2	256 × 256	99	2 × 3 ~ 3 × 3	低速小目标	森林、道路、建筑物	0.82 ~ 1.31
3	256 × 256	150	3 × 3 ~ 4 × 6	快速小目标	森林、强辐射地面	1.20 ~ 2.10
4	256 × 256	198	2 × 3 ~ 3 × 3	低速小目标	建筑物、村庄、道路	1.00 ~ 2.11
5	256 × 256	150	2 × 2 ~ 3 × 3	低速小目标	森林、强辐射地面	0.86 ~ 1.50

3.1.2 评价指标

为了定量评价本文算法性能,本节介绍了几种常见的评价指标。图 6 为目标区域与背景邻域示意图,图中 $a \times b$ 为目标区域,则其背景邻域大小为 $(a + 2d) \times (b + 2d)$,一般情况下取 $d = 20$ 。

式中, $LSNR_{in}$ 和 $LSNR_{out}$ 分别为代表图像在经过算法处理前后的局部信噪比,局部信噪比 $LSNR$ 的定义为:

$$LSNR = \frac{P_T}{P_B} \quad (41)$$

式中, P_T 和 P_B 分别代表目标区域以及目标的背景邻域中最大的灰度值。

BSF 定义为:

$$BSF = \frac{\sigma_{in}}{\sigma_{out}} \quad (42)$$

式中, σ_{in} 和 σ_{out} 分别表示目标的背景邻域在算法处理前后的标准差。

SCRG 的定义为:

$$SCRG = \frac{SCR_{out}}{SCR_{in}} \quad (43)$$

式中,信杂比 SCR 的定义为:

$$SCR = \frac{|\mu_T - \mu_B|}{\sigma_B} \quad (44)$$

式中, μ_T 代表红外小目标区域的灰度均值, μ_B 和 σ_B 分别代表目标的背景邻域的灰度均值以及灰度标准差。

CG 的定义为:

$$CG = \frac{CON_{out}}{CON_{in}} \quad (45)$$

式中, CON_{in} 和 CON_{out} 分别表示算法处理前后目标与背景邻域的灰度对比度,即

$$CON = |\mu_T - \mu_B| \quad (46)$$

为了更直观地对算法进行评价,引入虚警概

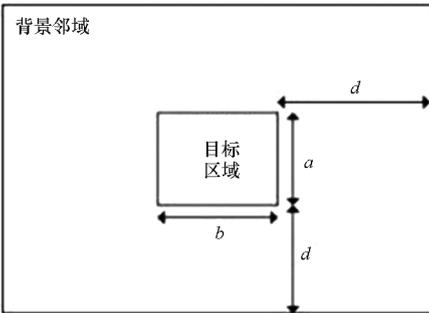


图 6 红外小目标区域及其背景邻域

Fig. 6 Infrared small target region and its background neighborhood

常用红外小目标评价的指标有局部信噪比增益(local signal-to-noise ratio gain, LSNRG)、背景抑制因子(background suppression factor, BSF)以及信杂比增益(signal-to-clutter gain, SCRG)。当算法完全抑制背景图像时,上述三个指标都为无穷大,因此,还介绍了对比度增益(contrast gain, CG)作为评价指标。

LSNRG 定义为:

$$LSNRG = \frac{LSNR_{out}}{LSNR_{in}} \quad (40)$$

率 F_a 和检测概率 P_d 两个概念,其定义为:

$$P_d = \frac{TD}{AT} \quad (47)$$

$$F_a = \frac{FD}{NP} \quad (48)$$

其中, TD 和 FD 分别表示正确检测到的目标数量和算法的虚警目标个数, AT 和 NP 分别表示当前帧真实目标的个数以及图像的像素总数。基于 F_a 和 P_d 两个指标,可以得到测试者操作特征(receiver operation characteristic, ROC)曲线,ROC曲线可以揭示算法在不同虚警概率下的性能。

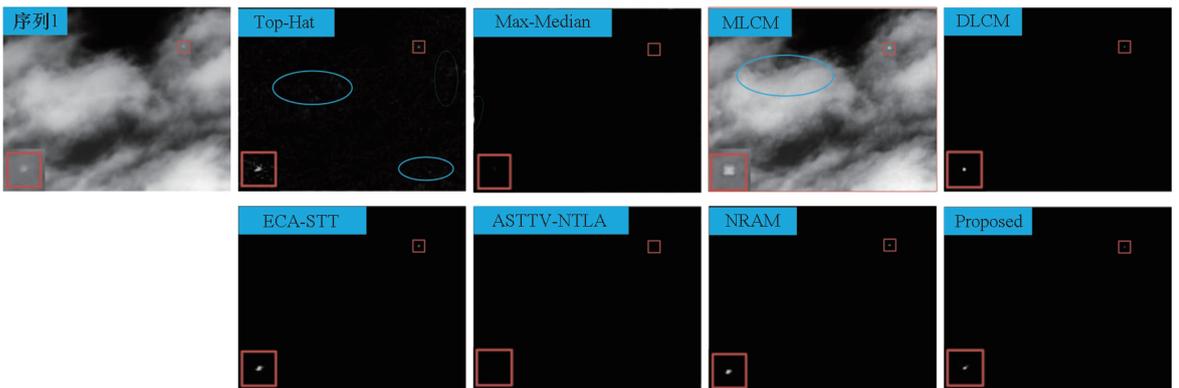
3.2 对比实验分析

为了验证本文算法的有效性,选取了7种常见的红外小目标检测算法,通过分析各算法在3.1.1节所介绍的数据集上的表现,证明算法的有效性。试验测试平台为: Intel(R) Core(TM) i7-9700, 3.00 GHz, 16 GB 内存, Windows10 系统台式机,采用 MATLAB2018b 软件对算法进行验证。7种红外小目标检测算法分别是 Top-Hat^[5]、Max-Median^[6]、LCM^[9]、双层局部对比度测量(double-layer local contrast measure, DLCM)、基于时空张量的边缘与角点感知模型^[23](edge and corner awareness-based spatial-temporal tensor model, ECA-STT)、非凸秩最小化估计^[24](non-convex rank approximation minimization, NRAM)以及 ASTTV-NTLA^[17]。其中, Top-Hat、Max-Median、多尺度 LCM(multiscale LCM, MLCM)、DLCM 和 NRAM 为基于单帧的红外小目标检测算法, ECA-STT 和 ASTTV-NTLA 为基于序列的红外小目标检

测算法, NRAM、ECA-STT 以及 ASTTV-NTLA 为基于核范数估计的目标检测算法。表2为各算法的参数设置表,图7~11分别为本文算法与7种同类型对比算法在实验序列上的典型帧的检测图与三维图的效果对比。

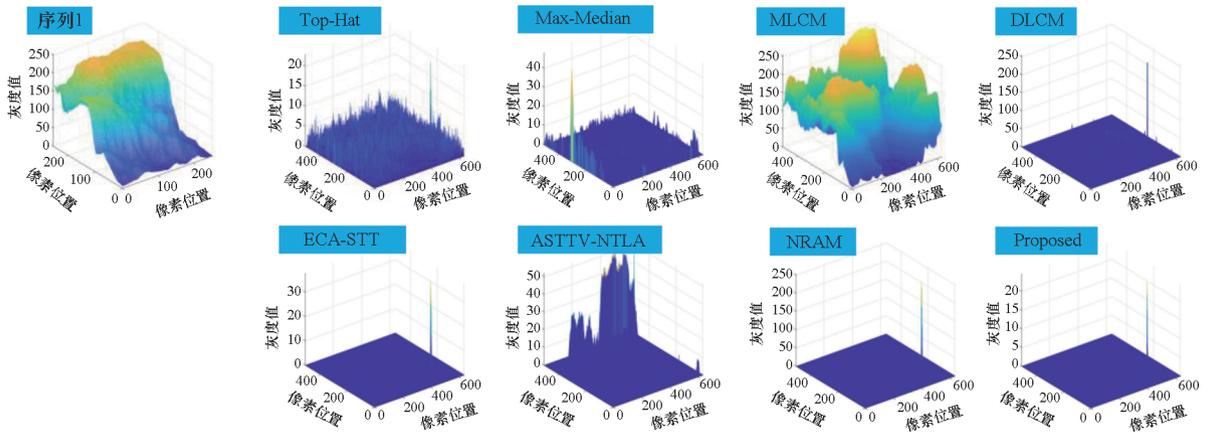
表2 各算法参数设置表

算法	参数设置
Top-Hat	结构形态: 圆形 结构大小: 5×5
Max-Median	滤波器大小: 5×5
MLCM	尺度: 4 局部尺寸: $3 \times 3, 5 \times 5, 7 \times 7, 9 \times 9$
DLCM	局部尺寸: 3×3
ECA-STT	$\beta = 0.1, t = 3, \lambda_1 = 0.009, \lambda_2 = 5.0 / \sqrt{\min(m, n)} \cdot t, \lambda_3 = 100, \varepsilon = 10^{-7}$ 图像块大小: 50×50 滑窗步长: 10
NRAM	$\lambda = 1 / \sqrt{\max(M, N)}, \gamma = 0.002,$ $\mu^0 = 3 \sqrt{\min(M, N)}, C = \sqrt{\min(M, N)} / 2.5,$ $\varepsilon = 10^{-7}$
ASTTV-NTLA	$L = 3, H = 6, \lambda_w = 0.005,$ $\lambda_s = H / \sqrt{\max(M, N)} \cdot L, \lambda_3 = 100$
Proposed	$L = 3, H = 3, \lambda_T = H / \sqrt{\max(M, N)} \cdot L,$ $\lambda_D = 0.005, \lambda_N = 100, \delta = 0.5, \varepsilon = 10^{-7}$



(a) 8种算法对序列1典型帧处理结果

(a) The processing results of 8 algorithms for typical frames in sequence 1

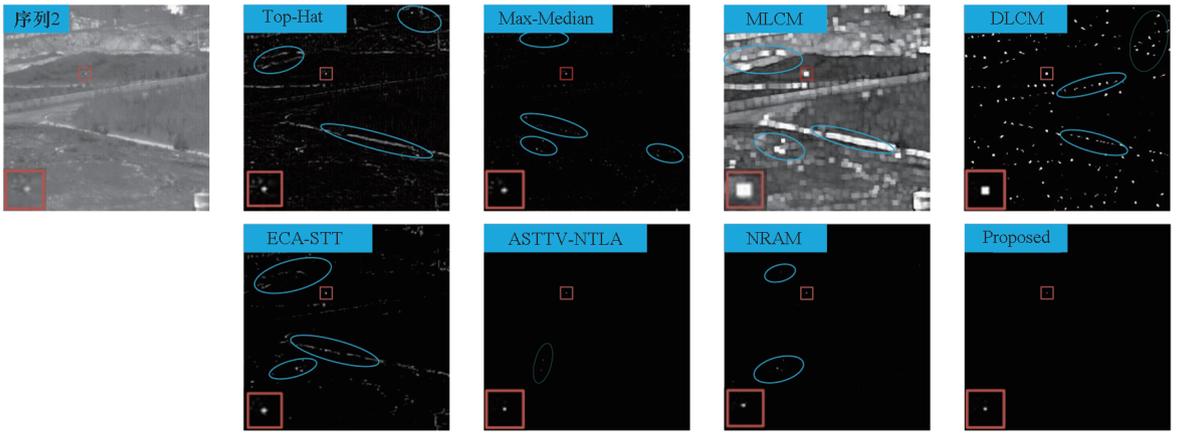


(b) 8 种算法对序列 1 典型帧处理结果三维图

(b) The three-dimensional view of processing results of 8 algorithms for typical frames in sequence 1

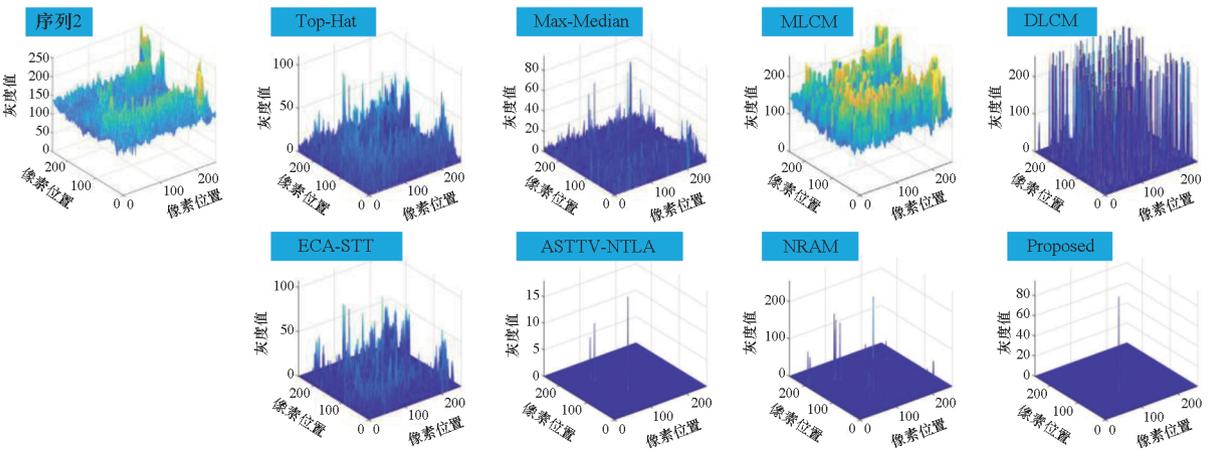
图 7 序列 1 典型帧 8 种算法效果对比图

Fig. 7 Comparison diagram of 8 algorithms for typical frames in sequence 1



(a) 8 种算法对序列 2 典型帧处理结果

(a) The processing results of 8 algorithms for typical frames in sequence 2

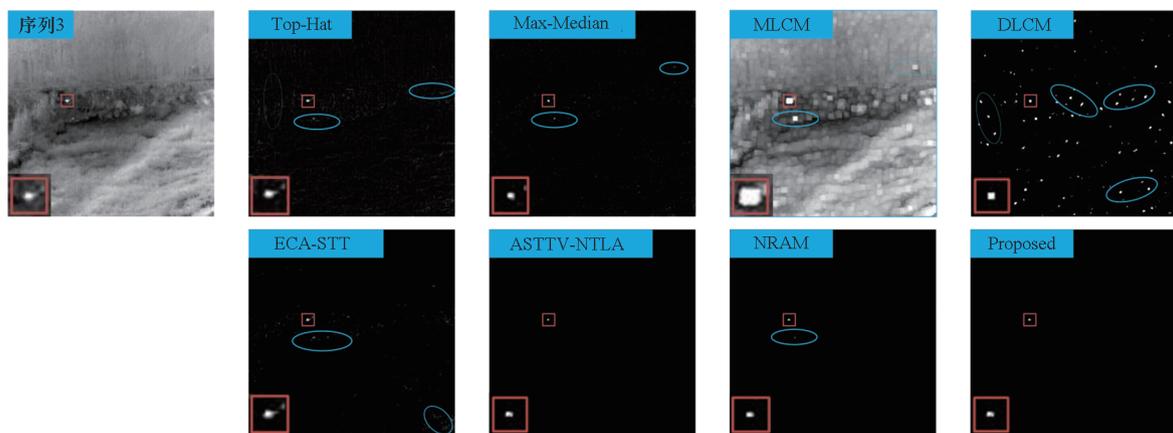


(b) 8 种算法对序列 2 典型帧处理结果三维图

(b) The three-dimensional view of processing results of 8 algorithms for typical frames in sequence 2

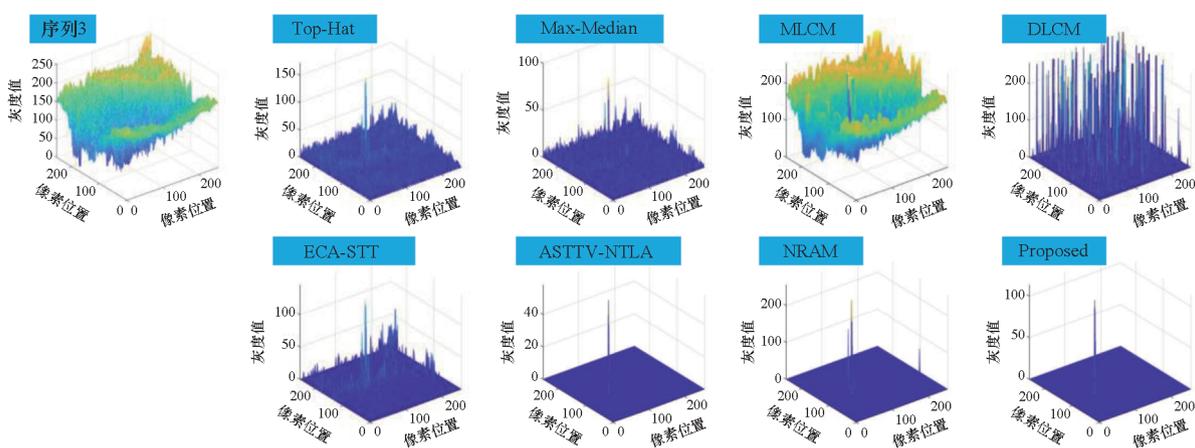
图 8 序列 2 典型帧 8 种算法效果对比图

Fig. 8 Comparison diagram of 8 algorithms for typical frames in sequence 2



(a) 8 种算法对序列 3 典型帧处理结果

(a) The processing results of 8 algorithms for typical frames in sequence 3

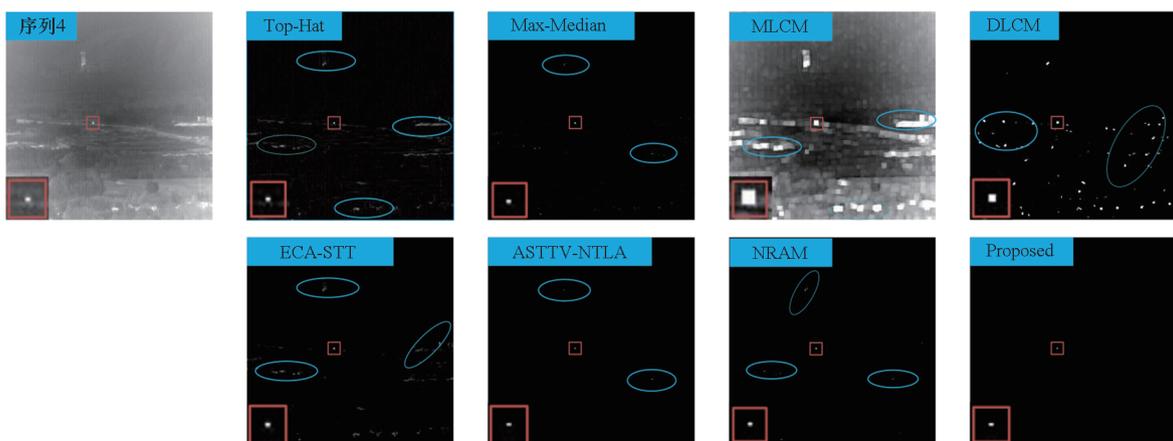


(b) 8 种算法对序列 3 典型帧处理结果三维图

(b) The three-dimensional view of processing results of 8 algorithms for typical frames in sequence 3

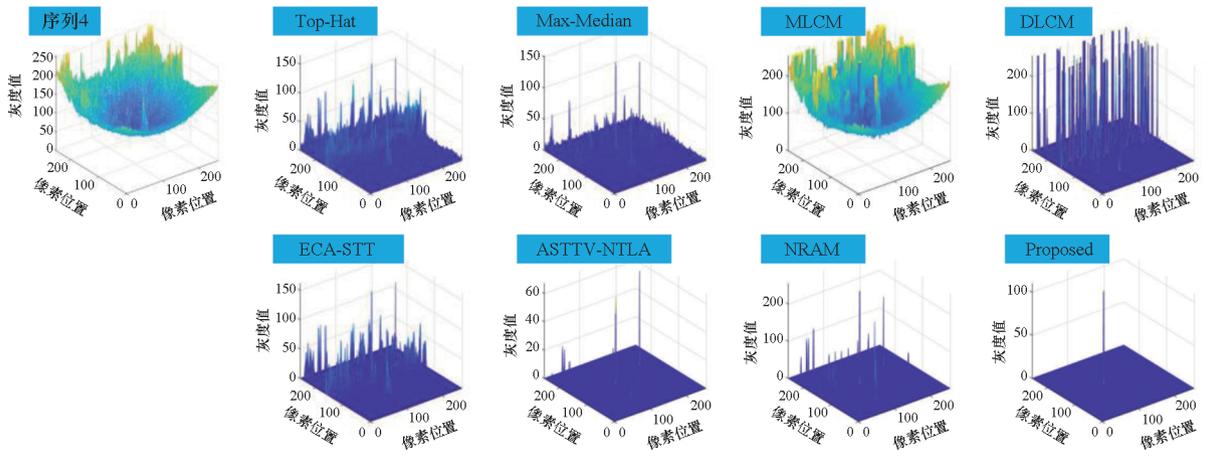
图 9 序列 3 典型帧 8 种算法效果对比图

Fig. 9 Comparison diagram of 8 algorithms for typical frames in sequence 3



(a) 8 种算法对序列 4 典型帧处理结果

(a) The processing results of 8 algorithms for typical frames in sequence 4

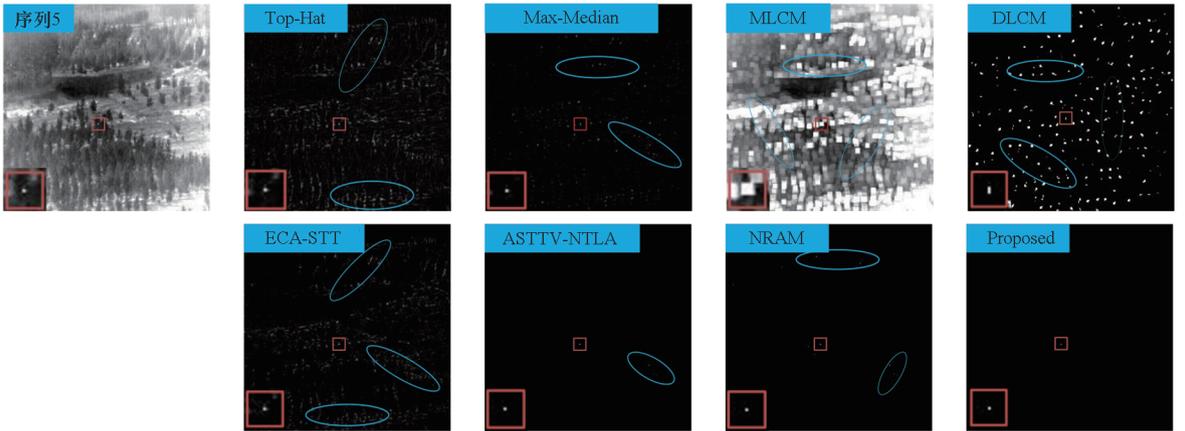


(b) 8 种算法对序列 4 典型帧处理结果三维图

(b) The three-dimensional view of processing results of 8 algorithms for typical frames in sequence 4

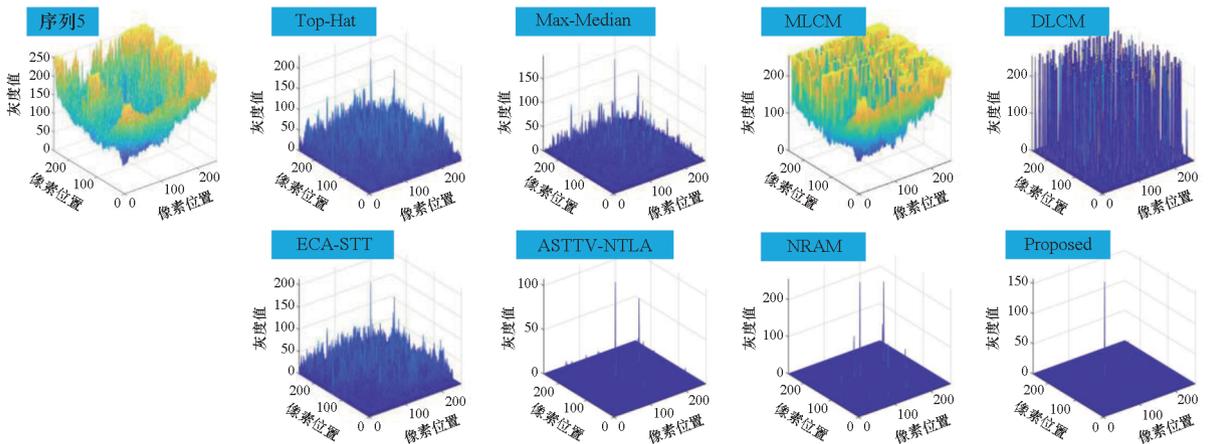
图 10 序列 4 典型帧 8 种算法效果对比图

Fig. 10 Comparison diagram of 8 algorithms for typical frames in sequence 4



(a) 8 种算法对序列 5 典型帧处理结果

(a) The processing results of 8 algorithms for typical frames in sequence 5



(b) 8 种算法对序列 5 典型帧处理结果三维图

(b) The three-dimensional view of processing results of 8 algorithms for typical frames in sequence 5

图 11 序列 5 典型帧 8 种算法效果对比图

Fig. 11 Comparison diagram of 8 algorithms for typical frames in sequence 5

图7为8种算法在序列1典型帧上的处理结果示意图,序列1背景主要为云层,不存在大量的角点结构,因此大部分算法都取得了较好的检测效果。从Top-Hat以及Max-Median处理结果的三维效果图可知,虽然可以检测出来目标,但是得到的目标图像中仍然存在大量噪声,主要为云层的边缘结构。而MLCM算法在增强目标的同时,没有有效地去除图像中的高亮干扰。ASTTV-NTLA算法在该序列当中对某些帧未能正确检测到目标,原因是目标约束项的惩罚因子稍大导致抑制太强,但是考虑到其他序列的情况,对此不做调整。而DLCM算法、ECA-STT算法、NRAM算法以及本文算法在该序列上的表现都很优秀,能够很好地检测出目标位置。

图8~11分别为8种算法在序列2、3、4、5上典型帧的处理效果对比图,上述4个序列都为地面背景,背景中存在大量容易被误检的干扰物,如建筑物的边缘、高亮度的道路边缘以及森林中的强辐射地面,这些都给检测算法带来了巨大的挑战。从图8~11的处理效果来看,Top-Hat可以较好地检测出目标,但是应对强边缘结构的干扰物,其抑制效果并不明显,如序列2典型帧中,其处理效果图中包含了大量的道路边缘以及建筑物边缘结构。Max-Median算法也可较好地检测到图像中的目标位置,但同样对强边缘结构的抑制能力有待加强,从其在4个序列的三维效果图中可以看出,使用该滤波器得到的处理图存在较多杂波,且部分误检点跟目标的响应幅度相近。MLCM算法跟DLCM算法在4个序列当中都能对目标区域进行不同程度的增强,但是在增强目标区域的同时,对图像中细小的干扰物或者高亮背景区域的边缘识别能力差,从处理的效果图可知,2种算法存在大量的虚警点,由于DLCM算法使用双层结构而不是简单地使用多个尺度不同的局部窗口,其对高亮背景的抑制能力稍强于MLCM算法,但是效果依旧不尽如人意。ECA-STT算法、ASTTV-NTLA算法、NRAM算法以及本文算法相较于传统算法以及基于人类视觉对比度方法来说,处理效果都有较大的提升。在这4种算法当中,处理效果相对较差的为ECA-STT算法,尤其是当图像中存在较多的小面积干扰物以及强边缘时,该算法的虚警目标较多,从其在序列2以及序列4中的典型帧处理效果来看,背景当中的建筑物角点、道路边缘等对其影响都比较大。ASTTV-NTLA算法和NRAM算法的处理效果相较于其他5种对比算法来说,有明显提升,得到的目标图像能够很好地增强目标,虚警点也较少,但是

2种算法还是存在对图像中某些建筑物的角点以及边缘结构的误检,且从4个序列典型帧的三维效果图的表现来看,ASTTV-NTLA算法得到的目标图像相较于NRAM算法来说,虚警点更少,此2种算法在应对平台移动导致图像结构移动时较为敏感。综合4个序列的处理效果来说,本文算法所得到的目标处理效果图较7种对比算法来说,能够在增强目标的同时较好地抑制背景中的边缘以及角点结构,性能有比较明显的提升。

表3列出了8种算法在5个实验序列评价指标值的平均值,其中Inf代表指标数值无穷大。由表3数据可知,本文算法在序列2上的CG值低于DLCM算法,原因是算法目标与背景之间的灰度值差异较小,算法在低秩恢复时得到的目标强度较弱。Top-Hat算法以及Max-Median算法在简单场景下能较好地检测目标,具有较高的指标值,但是应对复杂场景,该2种算法的能力有待提高。而MLCM算法与DLCM算法虽然在5个序列上具有较高的CG值,但是其余3个指标表现太差,两算法可以有效地增强目标,但是对角点、强边缘干扰的识别能力差。ECA-STT在5个序列上能够较好地识别目标,且具有不错的指标值,但是对于场景中的个别虚假目标的鉴别能力稍差。NRAM算法在5个序列上的表现很好,在增强目标的同时可以很好地抑制背景,4个指标值表现都很优秀,但是结合序列5的指标值以及该序列场景而言,NRAM算法仍会将部分角点背景识别为目标。ASTTV-NTLA在5个序列上都能很好地抑制背景,但设置的目标项惩罚因子较大,恢复得到的目标强度较低。本文算法在5个序列当中都具有较好的指标值,能够较好地增强目标、抑制背景,较其他7种对比算法来说具有更好的检测性能。

表3 8种算法在5个序列上的评价指标值

Tab.3 Evaluation index values of 8 algorithms on 5 sequences

方法	序列1评价指标平均值			
	LSNRG	SCRG	BSF	CG
Top-Hat	2.37	179.27	999.43	0.17
Max-Median	3.98	1 198.51	26 700.00	0.04
MLCM	0.94	2.04	0.88	2.31
DLCM	Inf	Inf	Inf	1.40
ECA-STT	Inf	Inf	Inf	0.34
ASTTV-NTLA	Inf	Inf	Inf	0.25
NRAM	Inf	Inf	Inf	4.66
Proposed	Inf	Inf	Inf	4.87

续表

方法	序列 2 评价指标平均值			
	LSNRG	SCRG	BSF	CG
Top-Hat	1.71	52.18	40.26	1.29
Max-Median	2.17	317.96	265.20	1.14
MLCM	0.98	2.94	0.35	7.84
DLCM	0.78	12.30	1.49	5.40
ECA-STT	2.18	313.88	182.95	1.31
ASTTV-NTLA	Inf	Inf	Inf	1.81
NRAM	Inf	Inf	Inf	2.55
Proposed	Inf	Inf	Inf	3.96

续表

方法	序列 5 评价指标平均值			
	LSNRG	SCRG	BSF	CG
Top-Hat	1.48	8.73	4.09	2.07
Max-Median	1.87	37.07	22.38	1.69
MLCM	0.77	1.34	0.16	7.80
DLCM	0.44	1.44	0.48	3.18
ECA-STT	2.27	20.22	7.06	2.71
ASTTV-NTLA	Inf	Inf	Inf	12.11
NRAM	2.87	2 790.00	237.65	12.31
Proposed	Inf	Inf	Inf	12.56

序列 3 评价指标平均值

方法	序列 3 评价指标平均值			
	LSNRG	SCRG	BSF	CG
Top-Hat	1.51	11.17	14.82	0.75
Max-Median	1.55	30.30	146.39	0.22
MLCM	0.60	1.27	0.48	2.61
DLCM	0.71	40.94	35.16	1.17
ECA-STT	1.59	35.32	50.14	0.73
ASTTV-NTLA	Inf	Inf	Inf	3.07
NRAM	Inf	Inf	Inf	3.26
Proposed	Inf	Inf	Inf	3.59

序列 4 评价指标平均值

方法	序列 4 评价指标平均值			
	LSNRG	SCRG	BSF	CG
Top-Hat	1.58	3.84	4.07	0.94
Max-Median	2.60	32.74	44.98	0.72
MLCM	0.61	0.31	0.14	2.16
DLCM	0.63	1.12	0.48	2.12
ECA-STT	1.82	14.86	17.21	0.89
ASTTV-NTLA	Inf	Inf	Inf	3.01
NRAM	Inf	Inf	Inf	3.25
Proposed	Inf	Inf	Inf	3.33

表 4 为 8 种算法对 5 个实验序列进行处理所需要的时间。由表 4 可知,Top-Hat 算法采用单一结构元对图像进行滤波处理,速度极快,MLCM 和 DLCM 算法也具有较快的处理速度,Max-Median 算法比 Top-Hat 算法、MLCM 算法、DLCM 算法的处理速度明显低一些,但是这 4 种算法对杂波和噪声的抑制能力很差,ECA-STT 算法所需的处理时间最长,NRAM 算法、ASTTV-NTLA 算法以及本文算法在处理时间上无太大差别,但是 NRAM 算法、ASTTV-NTLA 算法在背景抑制、信噪比增强等方面与本文算法仍存在一定差距。

图 12 为 8 种算法在 5 个序列上的 ROC 曲线图。由图 12 可知,对于 5 个序列来说,结合图 7~11,DLCM 算法和 MLCM 算法的虚警率较高,在较低虚警率要求下,其检测率无法在图 12 中表示,表现较差。ASTTV-NTLA 算法在序列 1 上也表现不佳(在图中与坐标轴重合),原因是其较大的目标项惩罚因子导致恢复的目标图像序列中存在大量的目标丢失帧,这导致其在该序列上的表现差。Max-Median 算法得到的目标图像中也存在较多的虚警点,因此在低虚警率情况下效果有待提高。本文算法在序列 1 上的表现稍逊于

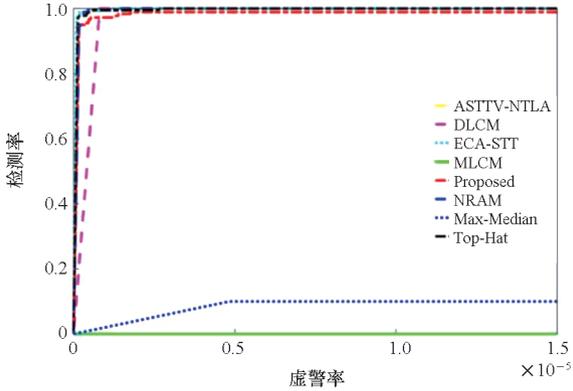
表 4 8 种算法对各序列处理时间表

Tab. 4 Processing time of 8 algorithms for each sequence

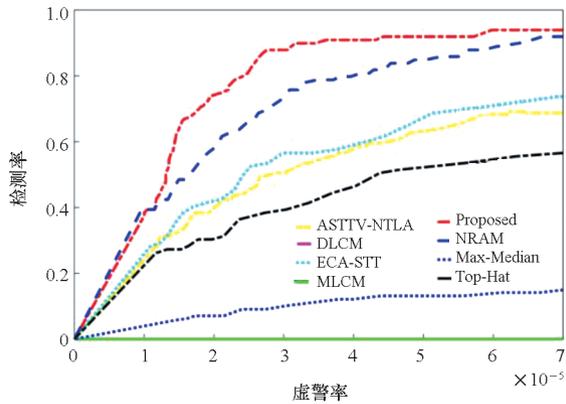
单位:s

图像数据	Top-Hat	Max-Median	MLCM	DLCM	NRAM	ECA-STT	ASTTV-NTLA	Proposed
序列 1	0.83	574.42	20.84	31.92	2 174.27	6 049.10	1 866.69	2 231.89
序列 2	0.16	62.88	2.74	3.23	139.02	620.42	212.80	234.41
序列 3	0.24	93.67	4.15	4.92	165.07	856.83	319.97	336.59
序列 4	0.31	124.41	5.46	6.46	295.86	1 132.85	422.25	476.85
序列 5	0.25	93.26	4.16	4.87	183.95	867.06	335.09	338.68

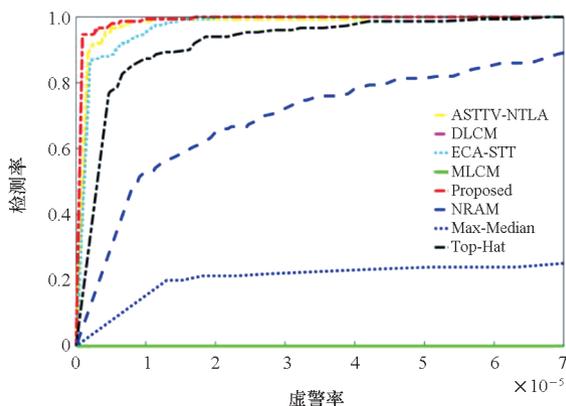
NRAM 算法与 ECA-STT 算法,原因是目标项惩罚因子导致个别帧出现了目标丢失的情况。在序列 2 中存在大量建筑物、道路等边缘结构,并且该序列采集时平台多次大幅移动,上述强边缘结构导致时域维度上的变分算子作用减弱,从而增加了算法的虚警率。但从序列 2~5 各算法的 ROC 曲线来看,本文算法在相同的虚警率下,检测率都高于其他 7 种算法,而且本文算法在检测率达到极限时的虚警率较其他 7 种算法更低。因此,在同样的虚警率要求下,本文算法的表现要优于其他算法。



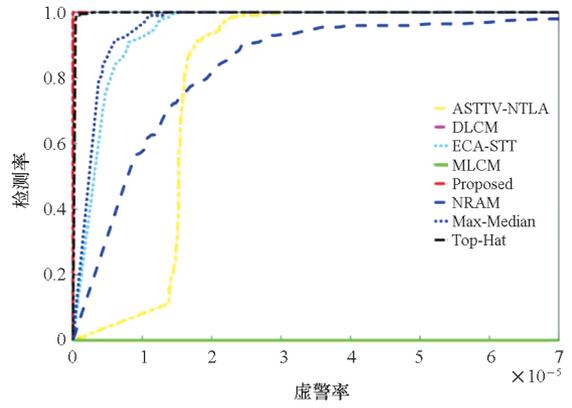
(a) 序列 1 的 ROC 曲线图
(a) ROC curve of sequence 1



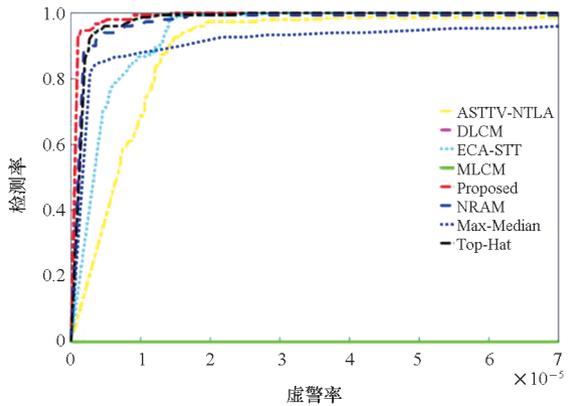
(b) 序列 2 的 ROC 曲线图
(b) ROC curve of sequence 2



(c) 序列 3 的 ROC 曲线图
(c) ROC curve of sequence 3



(d) 序列 4 的 ROC 曲线图
(d) ROC curve of sequence 4



(e) 序列 5 的 ROC 曲线图
(e) ROC curve of sequence 5

图 12 8 种算法在 5 个序列上的 ROC 曲线图
Fig. 12 ROC curves of 8 algorithms on 5 sequences

4 结论

本文对红外图像中的小目标检测问题,在 ASTTV-NTLA 算法的基础上,定义了一种基于指数倒数加权的背景张量核范数,能够很好地逼近 l_0 范数来估计背景张量的秩。然后提出了一种基于结构张量与多结构元 Top-Hat 滤波的目标自适应权重来约束目标张量,增加目标张量的稀疏性。改进的 ASTTV-NTLA 算法能够很好地检测图像中的小目标,较原算法具有较低的虚警率,但是对于湮没在图像中的小目标检测以及高亮点死像元噪声的剔除,本文算法的表现效果还有待提高。

参考文献 (References)

[1] WANG C C, SHEN Y H, ZHANG D, et al. A dynamic queue based pipeline filter for infrared dim small target detection[C]// Proceedings of the 34th Chinese Control Conference (CCC), 2015: 3770 - 3775.
[2] 陈莹, 郝应光, 王洪玉, 等. 基于局部梯度强度图的动态规划检测前跟踪算法[J]. 计算机科学, 2022, 49(8): 150 - 156.

- CHEN Y, HAO Y G, WANG H Y, et al. Dynamic programming track-before-detect algorithm based on local gradient and intensity map[J]. *Computer Science*, 2022, 49(8): 150–156. (in Chinese)
- [3] ZHANG T X, LI M, ZUO Z R, et al. Moving dim point target detection with three-dimensional wide-to-exact search directional filtering[J]. *Pattern Recognition Letters*, 2007, 28(2): 246–253.
- [4] CHEN Z, DENG T, GAO L, et al. A novel spatial-temporal detection method of dim infrared moving small target[J]. *Infrared Physics & Technology*, 2014, 66: 84–96.
- [5] RIVEST J F, FORTIN R A. Detection of dim targets in digital infrared imagery by morphological image processing[J]. *Optical Engineering*, 1996, 35(7): 1886–1893.
- [6] DESHPANDE S D, ER M H, VENKATESWARLU R, et al. Max-mean and max-median filters for detection of small targets[C]//*Proceedings of SPIE's International Symposium on Optical Science, Engineering, and Instrumentation*, 1999: 74–83.
- [7] HADHOUD M M, THOMAS D W. The two-dimensional adaptive LMS (TDLMS) algorithm[J]. *IEEE Transactions on Circuits and Systems*, 1988, 35(5): 485–494.
- [8] LI H, WANG Q, WANG H, et al. Infrared small target detection using tensor based least mean square[J]. *Computers & Electrical Engineering*, 2021, 91: 106994.
- [9] CHEN C L P, LI H, WEI Y T, et al. A local contrast method for small infrared target detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(1): 574–581.
- [10] WEI Y T, YOU X G, LI H. Multiscale patch-based contrast measure for small infrared target detection[J]. *Pattern Recognition*, 2016, 58: 216–226.
- [11] DENG H, SUN X P, LIU M L, et al. Small infrared target detection based on weighted local difference measure[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(7): 4204–4214.
- [12] LI Q, NIE J Y, QU S C. A small target detection algorithm in infrared image by combining multi-response fusion and local contrast enhancement[J]. *Optik*, 2021, 241: 166919.
- [13] REN L, PAN Z B, NI Y. Double layer local contrast measure and multi-directional gradient comparison for small infrared target detection[J]. *Optik*, 2022, 258: 168891.
- [14] GAO C Q, MENG D Y, YANG Y, et al. Infrared patch-image model for small target detection in a single image[J]. *IEEE Transactions on Image Processing*, 2013, 22(12): 4996–5009.
- [15] DAI Y M, WU Y Q. Reweighted infrared patch-tensor model with both nonlocal and local priors for single-frame small target detection[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, 10(8): 3752–3767.
- [16] SUN Y, YANG J G, LONG Y L, et al. Infrared small target detection via spatial-temporal total variation regularization and weighted tensor nuclear norm[J]. *IEEE Access*, 2019, 7: 56667–56682.
- [17] LIU T, YANG J G, LI B Y, et al. Nonconvex tensor low-rank approximation for infrared small target detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 60: 1–18.
- [18] DU L, GAO C Q, FENG Q, et al. Small UAV detection in videos from a single moving camera[C]//*Proceedings of CCF Chinese Conference*, 2017: 187–197.
- [19] LIN L K, WANG S Y, TANG Z X, et al. Using deep learning to detect small targets in infrared oversampling images[J]. *Journal of Systems Engineering & Electronics*, 2018, 29(5): 947–952.
- [20] 蒋昕昊, 蔡伟, 杨志勇, 等. 基于 YOLO-IDSTD 算法的红外弱小目标检测[J]. *红外与激光工程*, 2022, 51(3): 502–511.
- JIANG X H, CAI W, YANG Z Y, et al. Infrared dim and small target detection based on YOLO-IDSTD algorithm[J]. *Infrared and Laser Engineering*, 2022, 51(3): 502–511. (in Chinese)
- [21] ZHANG L D, PENG Z M. Infrared small target detection based on partial sum of the tensor nuclear norm[J]. *Remote Sensing*, 2019, 11(4): 382–1–382–34.
- [22] 潘胜达, 张素, 赵明, 等. 基于双层局部对比度的红外弱小目标检测方法[J]. *光子学报*, 2020, 49(1): 184–192.
- PAN S D, ZHANG S, ZHAO M, et al. Infrared small target detection based on double-layer local contrast measure[J]. *Acta Photonica Sinica*, 2020, 49(1): 184–192. (in Chinese)
- [23] ZHANG P, ZHANG L Y, WANG X Y, et al. Edge and corner awareness-based spatial-temporal tensor model for infrared small-target detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 59(12): 10708–10724.
- [24] ZHANG L D, PENG L B, ZHANG T F, et al. Infrared small target detection via non-convex rank approximation minimization joint $I_{2,1}$ norm[J]. *Remote Sensing*, 2018, 10(11): 1821–1–1821–26.