

基于改进加权核范数的红外弱小目标检测

翟昊^{1,2}, 罗晓琳^{1,2}, 吴令夏^{1,2}, 王荣昌^{1,2}

(1. 中国人民解放军陆军炮兵防空兵学院, 安徽 合肥 230031; 2. 偏振光成像探测技术安徽省重点实验室, 安徽 合肥 230031)

摘要:针对传统基于鲁棒主成分分析(RPCA)的红外弱小目标检测算法对噪声不敏感,算法运行时间长,鲁棒性不强的问题,提出一种重加权红外小目标图像模型,并用非精确增广拉格朗日乘法(AIALM)求解。该方法首先将原始红外图像转化为红外块图像模型,然后采用重加权核范数对背景块图像进行约束,较好地保留了背景边缘。针对单纯使用 l_1 范数不能抑制某些噪声或杂波的问题,引入了加权 l_1 范数,进一步增强了目标图像的稀疏性。最后,将红外块图像模型转化为重加权RPCA问题,并用AIALM求解。通过大量实验表明:该算法在抑制背景杂波以及目标检测性能方面要优于其他传统算法。

关键词:小目标检测;红外块图;低秩稀疏矩阵;鲁棒主成分分析;重加权

中图分类号:TP391 **文献标识码:**A **DOI:**10.3969/j.issn.1001-5078.2021.06.014

Infrared dim target detection based on improved weighted kernel norm

ZHAI Hao^{1,2}, LUO Xiao-Lin^{1,2}, WU Lin-Xia^{1,2}, WANG Rong-Chang^{1,2}

(1. Army Academy of Artillery and Air Defense, Hefei 230031, China;

2. Anhui Key Laboratory of Polarized Imaging Detection Technology, Hefei 230031, China)

Abstract: Aiming at the problems of the traditional Robust Principal Component Analysis (RPCA)-based infrared small target detection algorithm that is insensitive to noise, the algorithm runs for a long time, and the robustness is not strong, a re-weighted infrared small target image model is proposed, and non-precision enhancement is used, which is Wide Lagrangian multiplier method (AIALM) solution. This method first converts the original infrared image into an infrared block image model, and then uses a re-weighted kernel norm to constrain the background block image, which better preserves the background edge. Aiming at the problem that using norm alone cannot suppress some noise or clutter, a weighted norm is introduced to further enhance the sparsity of the target image. Finally, the infrared block image model is transformed into a weighted RPCA problem and solved by AIALM. A large number of experiments show that this algorithm is better than other traditional algorithms in suppressing background clutter and target detection performance.

Keywords: small target detection; infrared block diagram; low rank sparse matrix; robust principal component analysis; re-weighted

1 引言

红外小目标检测在视频监控、预警系统、军事制导等领域有着广泛的应用。检测方法一般可分为两类:单帧检测方法和序列帧检测方法。在

许多实际应用中,由于目标与成像传感器之间的相对快速运动,使得静态背景假设不一定成立,从而导致序列检测方法的性能下降。因此,单帧检测方法受到了广泛的关注。利用空间滤波器,提出了许多

作者简介:翟昊(1977-),男,硕士,主要从事红外目标检测的研究。E-mail:283944980@qq.com

通讯作者:罗晓琳(1973-),女,博士,教授,研究生导师,主要从事光电对抗的研究。E-mail:zh283944@163.com

收稿日期:2020-09-14; **修订日期:**2020-10-25

单帧检测方法,如 Top-hat 滤波器^[1]、max-mean 滤波器^[2]和 max-median^[3]。这些方法基于空间一致性假设对背景进行预测,通过从原始图像中减去滤波后的图像来实现目标检测。然而,非均匀背景中的一些强边缘也会破坏空间的一致性,并且会引起大量虚警的现象。

与上述方法不同,基于低秩假设的方法利用了红外背景图像的非局部自相关特性。在这个假设下,Gao 等人^[4]利用红外图像中的滑动窗口,提出了一种红外块图(IPI)模型,并首次提出将弱小目标检测问题转化为求解低秩稀疏矩阵的数学问题。由于低秩和稀疏假设很好地拟合了大多数场景,IPI 模型取得了很好的性能。遗憾的是,由于 l_1 范数所描述的稀疏性度量的缺陷,IPI 会过度缩小小目标,或者在目标图像中留下一些背景分量。为了解决这个问题,Dai 等人^[5]提出了一种加权 IPI(WIPI)模型,该模型将按列权重纳入分离过程。但是,该方法很耗时间,计算效率不高。

针对上述问题,本文提出了一种用于单帧弱小目标检测的重加权 IPI 模型。加权核范数最小化(WNNM)用于约束背景斑块图像,用较小的权重惩罚较大的奇异值。对于非目标稀疏点,本文引入加权 l_1 范数来约束目标块图像,并用较大的权重对其进行抑制。这样可以更好地保留包含强边缘的背景主成分,并有效地抑制一些不需要的稀疏分量。在 ReWIPI 算法的基础上,通过求解重加权 RPCA 问题来实现目标与背景的分离,最后对目标图像进行阈值分割并标定目标。

2 基于 IPI 模型红外弱小目标检测

2.1 红外图像模型

一般来说,红外图像模型可以表述如下:

$$f_D(x, y) = f_T(x, y) + f_B(x, y) + f_N(x, y) \quad (1)$$

其中, f_D, f_T, f_B, f_N 和 (x, y) 分别是原始红外图像、目标图像、背景图像、随机噪声图像和像素位置。而 IPI 模型是将传统的红外图像模型转化为分块图像模型。一幅红外图像可以看成是由背景、目标和噪声三个成分图像构成^[6],即:

$$D = B + T + N \quad (2)$$

式中, D, B, T 和 N 分别为构造的原始块图像、背景块图像、目标块图像以及噪声块图像。

2.2 块图的性质

2.2.1 目标块图 T

在实际应用中,小目标通常是不断变化的。亮度可以从暗到亮,其大小可以从 3×3 到 9×9 (以像

素为单位)。相对于整个图像来说,小目标所占比例是很小的,因此小目标图像具有稀疏性,而它相对应的目标块图 T 则是稀疏矩阵。即:

$$\|T\|_0 < k \quad (3)$$

式中, $\|\cdot\|_0$ 表示计算矩阵中非零项的个数的 l_0 范数, k 由小目标的个数及其大小决定,显然 $k \ll m \times n$ ($m \times n$ 是 T 的大小),这意味着矩阵 T 的大部分项都是零。除了这种稀疏性之外,对目标图像不做任何额外的假设。

2.2.2 背景块图 B

一般来说,背景图像被认为是缓慢变化的,这意味着局部和非局部的块图高度相关,如图 1(a) 所示。在图 1(b) 中,所有对应的块图像的奇异值迅速减小到零,这表明背景块图本质上是低秩的。因此,背景块图 B 可被视为低秩矩阵。

$$\text{rank}(B) \leq r \quad (4)$$

其中, r 是常数。本质上, r 约束背景图像的复杂度, r 值越大,背景就越复杂。

2.2.3 噪声块图 N

本文中,假设噪声是随机的,且 $\|N\|_F \leq \delta$ 对某些 $\delta > 0$ 。因此, $\|N\|_F \leq \delta$ 可以由下式表示:

$$\|D - B - T\|_F \leq \delta \quad (5)$$

其中, $\|\cdot\|_F$ 是 Frobenius 范数(如: $\|X\|_F = \sqrt{\sum_{ij} X_{ij}^2}$)。

虽然参数 k, r 和 δ 随红外图像的不同而变化,但不必直接计算它们的值。

2.3 传统 IPI 检测算法

为了在单个图像 f_D 中检测出小目标,需要获得目标图像 f_T ,由于 f_T 可以从目标块图 T 中重建,因此如何准确有效地求解目标块图 T 是目标检测的关键。通过前面对各个图像块特征的分析,可以看出弱小目标检测问题本质上是数据矩阵中恢复低秩分量和稀疏分量的数学问题。则可通过求解以下凸优化问题来求解目标块图:

$$\min_{B, T} \|B\|_* + \lambda \|T\|_1 + \frac{1}{2\mu} \|D - B - T\|_F^2 \quad (6)$$

其中, $\|\cdot\|_1$ 是 l_1 范数,即矩阵各项的绝对值之和; $\|\cdot\|_*$ 表示核范数,即矩阵奇异值之和; λ 为一个正则参数。为了便于计算,这里用 $\|B\|_*$ 和 $\|T\|_1$ 分别替代(4)中的 $\text{rank}(B)$ 和(3)中的 $\|T\|_0$ 。一般式(6)被称为鲁棒主成分分析(RPCA)。

基于 IPI 模型的红外弱小目标检测方法的具体流程如图 2 所示^[7]。

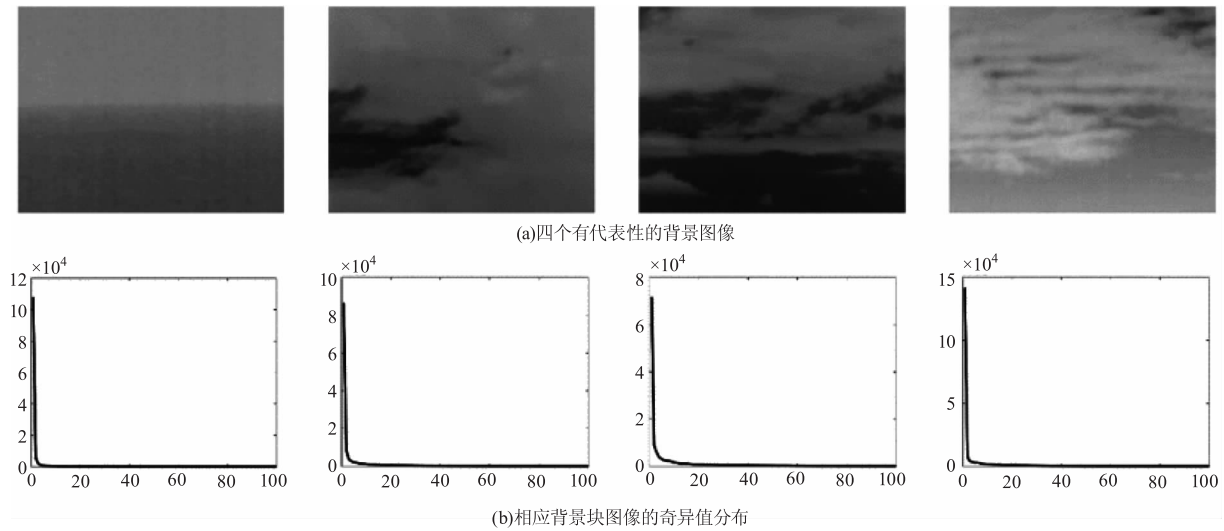


图 1 背景块图像的低秩特性

Fig. 1 Low-rank property of infrared background patch-image

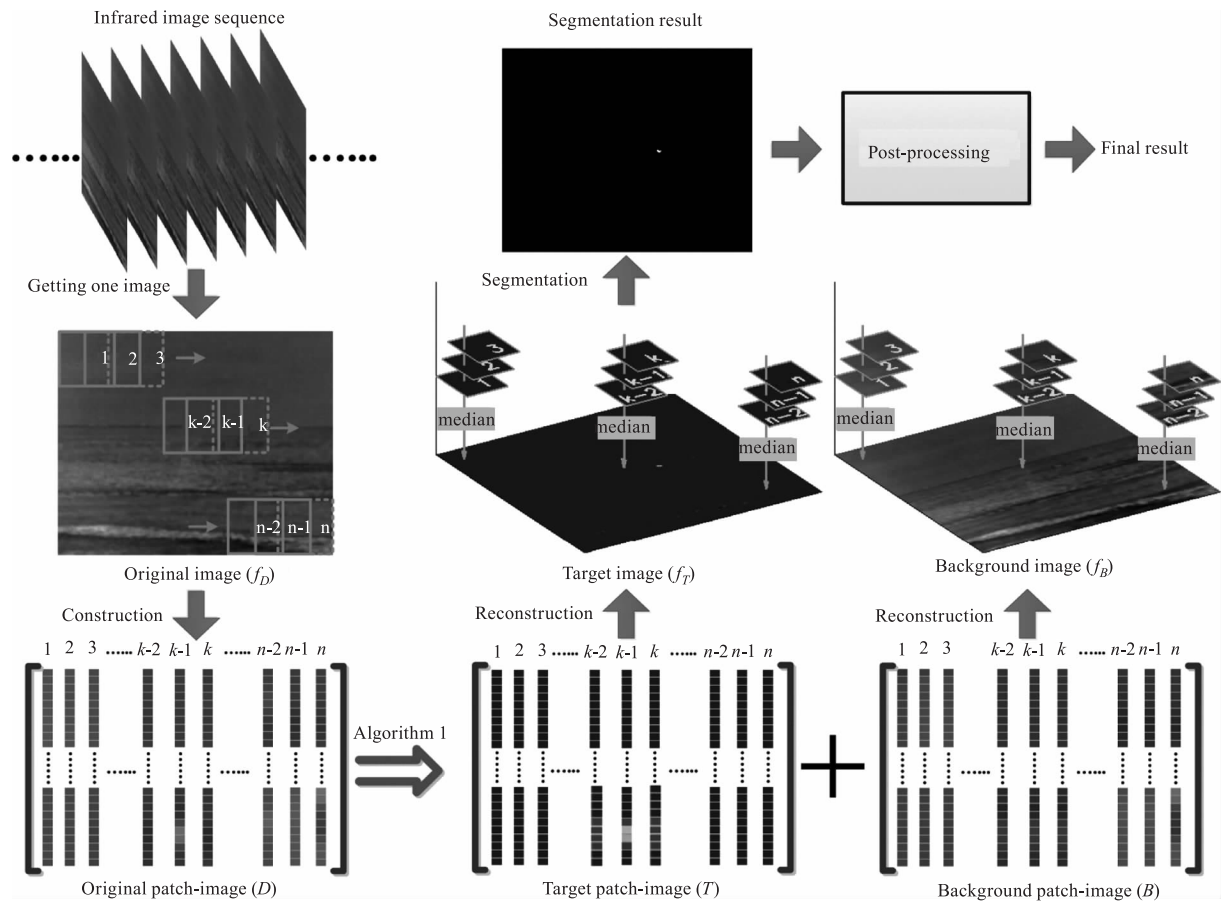


图 2 IPI 方法整体流程

Fig. 2 The overview of the IPI method

3 基于改进 WIPI 红外弱小目标检测

3.1 WIPI 模型

在传统 IPI 检测算法中,对背景块图进行重建时,对不同背景块通常使用相同的权值进行重建,使得恢复的背景图像容易引入噪声等信息的干扰,使

得在后续目标检测中,容易产生虚警现象。为了解决这一问题,本文引入了加权核范数^[8]的定义,对矩阵 B ,加权核范数定义为:

$$\|B\|_{w^*} = \sum_j w_j \sigma_j(B) \quad (7)$$

$$w_j^{k+1} = \frac{1}{\sigma_j^k(B) + \varepsilon_B} \quad (8)$$

其中, k 表示迭代次数; $\sigma_j(B)$ 为矩阵 B 的第 j 个奇异值; $w = [w_1, w_2, \dots, w_n]^T$, w_i 为矩阵 B 的奇异值 $\sigma_j(B)$ 对应的权重大小, 该值通常为非负常数; ε_B 是一个正常数。

通过重加权运算, 得到合适的权重, 既能鼓励较大的单元, 又能抑制较小的单元。

与重加权核范数相似, 考虑到大多数非目标稀疏点的亮度低于小目标的亮度, 我们采用重加权 l_1 范数来描述目标斑块图像, 其表达式如下:

$$\|T\|_{w,1} = \|W \odot T\|_1 \quad (9)$$

$$W_{ij}^{k+1} = \frac{1}{|T_{ij}^k| + \varepsilon_T} \quad (10)$$

其中, $W = \{W_{ij}\}$ 是 T 的元素 T_{ij} 的权重; $\|\cdot\|$ 表示绝对值运算符; \odot 表示哈达玛积; ε_T 是一个正常数。

然后, 基于所提出的 WIPI 的检测模型可以公式化为:

$$\min_{B,T} \|B\|_{w^*} + \lambda \|T\|_{w,1} \quad \text{s.t.} \quad \|D - B - T\|_F \leq \delta \quad (11)$$

该算法既解决了背景细节被错当成目标的问题, 也有效地抑制了亮度较低的稀疏分量。

3.2 模型优化算法

本文采用 AIALM^[9] 求解式(11), 将目标 - 背景

分离问题转化为一个重加权的 RPCA 问题。

式(11)的增广拉格朗日函数公式如下:

$$L(B, T, Y, \mu) = \|B\|_{w^*} + \lambda \|T\|_{w,1} + \langle Y, D - B - T \rangle + \frac{\mu}{2} \|D - B - T\|_F^2 \quad (12)$$

其中, Y 是拉格朗日乘子矩阵; $\langle \cdot, \cdot \rangle$ 表示内积运算符; μ 是正的惩罚标量。

(B, T) 交替求解如下:

$$\begin{aligned} B_{k+1} &= \operatorname{argmin}_B L(B, T_k, Y_k, \mu_k) \\ &= \operatorname{argmin}_B \|B\|_{w^*} + \frac{\mu_k}{2} \|B + D - T_k + \mu_k^{-1} Y_k\|_F^2 \end{aligned} \quad (13)$$

$$\begin{aligned} T_{k+1} &= \operatorname{argmin}_T L(B_{k+1}, T, Y_k, \mu_k) \\ &= \operatorname{argmin}_T \lambda \|T\|_{w,1} + \frac{\mu_k}{2} \|T + D - B_{k+1} + \mu_k^{-1} Y_k\|_F^2 \end{aligned} \quad (14)$$

矩阵 Y 通过:

$$Y_{k+1} = Y_k + \mu_k (D - B_{k+1} - T_{k+1}) \quad (15)$$

通过 AIALM 算法将(13)和(14)可解为:

$$B_{k+1} = D_{\mu_k^{-1}w} [D - T_{k+1} + \mu_k^{-1} Y_k] \quad (16)$$

$$T_{k+1} = S_{\lambda \mu_k^{-1}w} [D - B_{k+1} + \mu_k^{-1} Y_k] \quad (17)$$

其中, $D_{\mu^{-1}w}(\cdot)$ 和 $S_{\lambda \mu^{-1}w}(\cdot)$ 是软阈值运算符。

算法 1 描述了整个求解过程, 如表 1 所示。

表 1 本文算法

Tab. 1 The algorithm of proposed

算法 1 非精确增广拉格朗日乘子法	
输入: 矩阵 $D \in R^{m \times n}$, 参数 λ	
步骤 1: 设置迭代次数 $k = 0$, 最大迭代次数 k_{\max} ; $w^0 = 1 \in R^n, W^0 = 1 \cdot 1^T \in R^{m \times n}$; $\varepsilon_B, \varepsilon_T$ 为正常数; 当 $k \leq k_{\max}$ 时执行步骤 2;	
步骤 2: 使用 IALM 求解(11); 初始化 $B_0 = T_0 = 0 \in R^{m \times n}, Y_0 \in R^{m \times n}, \mu_0 > 0, \rho > 1, t = 0$;	
while not converged do	
	$B_{k+1} = D_{\mu_k^{-1}w} [D - T_{k+1} + \mu_k^{-1} Y_k]$ $T_{k+1} = S_{\lambda \mu_k^{-1}w} [D - B_{k+1} + \mu_k^{-1} Y_k]$ $Y_{k+1} = Y_k + \mu_k (D - B_{k+1} - T_{k+1})$ $\mu_{k+1} = \rho \mu_k$ $k = k + 1$
end	
输出: $B^k = B^*, T^k = T$;	
步骤 3: 权重 (w, W) 通过以下方式更新	
	$w_j^{k+1} = \frac{1}{\sigma_j^k(B) + \varepsilon_B}$ $W_{ij}^{k+1} = \frac{1}{ T_{ij}^k + \varepsilon_T}$ $k = k + 1$
步骤 4: 当 $k > k_{\max}$ 时, 算法终止;	
输出: $B = B^{k_{\max}}, T = T^{k_{\max}}$;	

3.3 后处理

通过 AIALM 算法求解出目标图像后,需要进行阈值分割来进一步提取目标。由于通过 IPI 算法处理后的目标图像信噪比较高,对阈值分割方法要求不高,所以本文直接采用 Otsu's 方法进行阈值分割。

4 实验结果与分析

为了验证改进的检测算法的可行性与有效性,将其与经典的传统检测算法(Max-mean、Max-medi-

an、Top-Hat)和改进前的 IPI 算法进行了比较。表 2 为本章实验中各检测算法的参数设置。

为了对比不同类别的小目标检测方法的性能,本文使用红外探测器在真实中获取 4 个连续的红外图像序列。4 个红外图像序列的详细说明如表 3 所示。所有实验均在 4GB RAM 和 2.5 GHz AMD A10-5750M APU 处理器的计算机上进行,并且检测方法的代码在 MatlabR 2016b 中实现。

表 2 各算法的参数设置

Tab. 2 Parameter settings of each algorithm

序号	方法	参数设置
1	Top-Hat	结构元素形状:矩形;大小:5×5
2	Max-mean	滤波器大小:3×3
3	Max-median	滤波器大小:3×3
4	传统 IPI	Patch size:25×25, sliding step:5, $\lambda = 1/\sqrt{\min(m,n)}$
5	本文算法	Patch size:25×25, sliding step:5, $\lambda = 1/\sqrt{\min(m,n)}$, $\mu_0 = 1.25/\max(\text{svd}(D)) \times 10^7$, $\rho = 0.02$

表 3 三个红外图像序列的详细说明

Tab. 3 Detailed description of three infrared image sequences

	帧数	弱小目标描述	背景描述
序列 1	300	无人机:目标对比度较高;大小:3×3 像素到 9×9 像素	空天场景;较弱的云杂波
序列 2	300	无人机:目标对比度适中;大小:3×3 像素到 9×9 像素	复杂的海天场景
序列 3	300	无人机:目标对比度较低;大小:3×3 像素到 9×9 像素	复杂的空天场景较强的云杂波
序列 4	300	无人机:目标对比度较低;大小:3×3 像素到 9×9 像素	海面场景

检测结果如表 4 所示,经过 Top-Hat、Max-mean 以及 Max-median 处理后的结果图,可以看到它们虽然有效地去除了背景信息,但是图像目标信息缺失比较严重,严重影响目标检测的准确率。而经过传统 IPI 算法和本文算法处理后的结果图,都有效地保留了目标区域,去除了背景和噪声信息,但经传统 IPI 算法处理后的图像噪声较为严重,容易造成虚警率,本文算法较为完整地保留了目标信息,效果最好。

检测率和虚警率是客观反映目标检测性能的重要指标,而运行时间常常用于比较算法运行效率。表 5 给出了 5 种不同算法对不同天空、海面背景情况下红外小目标检测的检测率、虚警率以及运行时间的平均结果。可以看出,本文算法的检测性能要优于比其他算法,而运行速度相比于传统滤波算法稍慢,但是相比于传统 IPI 算法有着明显提升。

表 5 各种算法检测结果









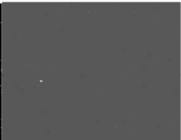


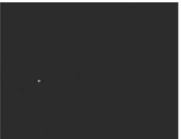











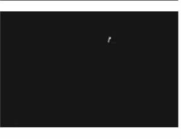
Tab. 5 Test results of various algorithms

检测算法	检测率/%	虚警率/%	时间/s
Top-Hat	88.5	14.6	4.87
Max-mean	82.7	12.4	4.25
Max-median	86.8	13.5	4.28
APG	91.2	8.9	156.38
本文算法	95.8	5.8	11.86

5 结论

为了提高复杂背景下红外小目标检测的精度,提出了一种基于加权核范数和加权 l_1 范数约束的小目标检测 ReWIPI 模型。最后的迭代结果得到了合适的权重。这样,在抑制非目标稀疏点的同时,保留了背景边缘。最后,通过求解一个重加权的 RPCA 模型来实现目标-背景的分离。实验结果表明,该方法在背景抑制和目标检测方面优于其他方法。但所提出的算法由于需要迭代运算,不能很好的满足目标检测实时性的需求,有待进一步改进。

表4 红外图像及不同算法处理的结果
Tab.4 Infrared images and the results of different algorithms

场景	原始图像	Top -Hat	Max -mean	Max -median	传统 IPI	本文算法
空天						
海天						
天云						
海面						

参考文献:

- [1] Bai X, Zhou F. Analysis of new top-hat transformation and the application for infrared dim small target detection[J]. Pattern Recognition, 2010, 43(6): 2145 - 2156.
- [2] Deshpande S D, Er M H, Ronda V, et al. Max-mean and max-median filters for detection of small targets[J]. Proceeding of SPIE-the International Society for Optical Engineering, 1999, 3809.
- [3] Su Zelin, Gao Chenqiang. Detection algorithm of small IR target based on 3D Max-median and 3D Max-mean filter [J]. Video Engineering, 2014, (9): 235 - 238. (in Chinese)
苏泽林, 高陈强. 基于 3D Max-median 和 3D Max-mean 滤波的红外小目标检测[J]. 电视技术, 2014, (9): 235 - 238.
- [4] Gao C, Meng D, 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.
- [5] Dai Y, Wu Y, Song Y. Infrared small target and background separation via column-wise weighted robust principal component analysis[J]. Infrared Physics & Technology, 2016, 77: 421 - 430.
- [6] Yang Z, Xu Changbin, Ma Yuying, et al. A review of infrared dim small target detection algorithms with low SNR [J]. Laser & Infrared, 2019, 49(6): 643 - 649. (in Chinese)
杨旻, 徐长彬, 马玉莹, 等. 低信噪比下的红外弱小目标检测算法研究综述[J]. 激光与红外, 2019, 49(6): 643 - 649.
- [7] Lin Z, Liu R, Li H. Linearized alternating direction method with parallel splitting and adaptive penalty for separable convex programs in machine learning [J]. Machine Learning, 2015, 99(2): 287 - 325.
- [8] Gu S, Xie Q, Meng D, et al. Weighted nuclear norm minimization and its applications to low level vision[J]. International Journal of Computer Vision, 2017, 121(2): 183 - 208.
- [9] Dai Y, Wu Y, Song Y, et al. Non-negative infrared patch-image model: robust target-background separation via partial sum minimization of singular values [J]. Infrared Physics & Technology, 2017, 81: 182 - 194.