

基于自适应改进的压缩域红外弱小目标检测

李安冬 林再平 安 玮 杨林娜

国防科学技术大学电子科学与工程学院, 湖南 长沙 410073

摘要 现有压缩域目标检测算法取得较好检测结果的同时,有效减少了数据存储空间,但是存在背景参数估计易受噪声影响,目标检测易对邻近目标产生漏警等问题。在原有压缩域红外小目标检测算法的基础上进行改进,提出了一种基于自适应参数估计和噪声统计模型的压缩域目标检测算法。对压缩域红外数据矩阵进行自适应的低秩稀疏分解,分离并重建背景矩阵和目标矩阵,根据分解残差推导统计模型,对目标矩阵进行基于噪声统计模型的阈值分割。结果表明,此算法较原算法具有更好的抗干扰能力,并解决了邻近目标的漏警问题。

关键词 测量;小目标检测;自适应;压缩感知;矩阵低秩稀疏分解

中图分类号 TP391.4

文献标识码 A

doi: 10.3788/CJL201542.1008003

Infrared Small Target Detection in Compressive Domain Based on Self-Adaptive Parameter Configuration

Li Andong Lin Zaiping An Wei Yang Linna

*School of Electronic Science and Engineering, National University of Defense Technology,
Changsha, Hunan 410073, China*

Abstract The existing infrared target detection algorithm in compressive domain achieves obtain good performance with low required data storage, but have its own shortcomings. One shortcoming is the difficulty to estimate background parameters, which are sensitive to noise and complex background, the other is the high false dismissal probability when targets are close to their neighbors. Considering those shortcomings, an infrared small target detection algorithm in compressive domain based on self-adaptive parameter configuration and noise statistics is proposed. The original infrared image is projected on a sensing matrix to obtain the measurement vector. The sparse target matrix and the low-rank background matrix can be recovered and separated simultaneously from the measurements based on low-rank and sparse matrix decomposition in compressive domain with adaptive parameter. The infrared small target detection is realized by threshold segmentation of statistical model of noise. Results indicate that the proposed method outperforms the previous method in both subjective and objective qualities under complex infrared background with less data storage, and solves the false dismissal probability problem when targets are close to their neighbors.

Key words measurement; small target detection; adaptive parameter; compressive sensing; low-rank and sparse matrix decomposition

OCIS codes 120.1880; 100.3008; 100.3010

1 引 言

压缩感知(CS)充分利用信号的稀疏性,在保证准确重构出原信号的前提下,降低采样所需要的采样率^[1]。稀疏性是指向量或矩阵中的大部分元素为零值。压缩域数据指的是原始数据通过测量矩阵投影得到的测量向量。压缩感知可以在保证恢复有效信息的前提下快速压缩图像,明显减小文件体积,减轻星地传输压力。

收稿日期: 2015-03-26; 收到修改稿日期: 2015-04-30

作者简介: 李安冬(1990—),男,硕士研究生,主要从事空间红外图像获取与处理方面的研究。E-mail: 594970080@qq.com

导师简介: 安 玮(1969—),女,教授,博士生导师,主要从事空间红外图像获取与处理方面的研究。

E-mail: nudtanwei@tom.com(通信联系人)

近年来,陆续有学者提出压缩域数据处理算法^[2-4]。Waters等^[5]在COSAMP算法^[6]基础上,首次提出了压缩域下矩阵低秩稀疏分解的有效算法(SpaRCS)。Guo等^[7]提出了自回归规划压缩感知算法(Prac-ReProCS),实现了在线压缩域矩阵低秩稀疏分解。在此基础上,Li等^[8]提出的基于矩阵低秩稀疏分解的压缩域下红外弱小目标检测算法(CLSDM),首次将压缩域下的低秩稀疏分解应用于红外弱小目标检测。同传统目标检测算法^[9-10]相比,基于压缩域的目标检测算法要求直接从全局测量向量中获取目标信息,对背景及前景目标进行重建,完成目标检测,降低了数据储存和传输成本,去掉了压缩、解压的中间环节,有效提高了系统效率。

CLSDM算法根据红外云层背景的空间缓变特性,将红外云层图像本身看做低秩矩阵^[11],并将目标解释为低秩矩阵外的稀疏矩阵。低秩矩阵是指矩阵的秩相对于矩阵的行数或列数而言很小,如果对矩阵进行奇异值分解,并把其所有奇异值排列为一个向量,那么这个向量的稀疏性便对应于该矩阵的低秩性。算法首先计算图像复杂度估计红外云层图像的秩,然后对红外云层图像投影的测量向量低秩稀疏分解,重建得到目标稀疏矩阵,最后对目标矩阵进行简单阈值分割。算法取得了较好的检测结果,同时有效降低了数据存储空间。但是受噪声和强起伏背景杂波影响,算法根据图像复杂度估计的背景矩阵低秩度参数与实际差别较大,影响到算法性能。另外,算法在阈值分割时未考虑邻近多目标的情况,当目标灰度值差别较大时容易造成漏警。

针对以上这些问题,本文提出了一种基于噪声统计模型的参数自适应压缩域红外弱小目标检测算法。通过自适应估计秩参数,算法可以避开预处理步骤直接处理压缩域图像,并且同原有基于图像复杂度的秩估计相比较,改进算法在复杂背景下的检测性能明显提高;通过推导噪声统计模型,算法采用基于残差高斯分布假设的阈值分割方法,同原算法简单根据灰度最大值设定阈值方法相比较,改进算法可以有效抑制多目标造成的漏警。实验表明,本算法在复杂环境下性能优于原算法,同时达到降低压缩比和提高目标检测率的目的。

2 压缩域下红外弱小目标检测算法分析

经典红外图像模型由背景,目标,噪声三部分组成^[12],可以表示为

$$D(x,y) = B(x,y) + T(x,y) + N(x,y), (1 \leq x \leq m, 1 \leq y \leq n), \quad (1)$$

式中 $D(x,y)$ 代表红外图像, $B(x,y)$ 表示背景, $T(x,y)$ 表示目标, $N(x,y)$ 表示噪声, (x,y) 表示像素点在图像中的位置, $m \times n$ 是图像的大小。相比于图像的总像素数,红外小目标占据的像素数通常只占相对小的一部分,因此可以假设目标矩阵为稀疏矩阵,即有 $\|T\|_0 \leq K$, 其中稀疏度 K 反映了目标的数量和大小,显然有 $K \ll m \times n$ 。由于红外云层背景的空域缓变特性,背景内部存在较强的线性相关性,未经预处理的背景矩阵可被假设为低秩矩阵,即有 $\text{rank}(B) \leq r$, 其中低秩度 r 取决于图像背景的复杂度。于是传统的红外图像弱小目标检测问题可以转化为从背景低秩矩阵 B 分离目标稀疏矩阵 T 。

对红外图像进行压缩感知测量,首先需要向量化二维图像,即将红外图像转化为长度为 $N = m \times n$ 的一维向量 F 。设测量数为 M , 则红外图像在测量矩阵 $A \in \mathbf{R}^{M \times N} (M < N)$ 下的线性投影为

$$y = AF = A(B + T) + e, \quad (2)$$

式中 y 表示被观测到的向量, e 表示测量噪声。当矩阵 A 同时满足矩阵的约束等距性 (RIP) 和秩约束等距性 (RRIP) 条件^[1], 可以保证 y 中包含了足够恢复背景矩阵 B 和目标矩阵 T 的信息。

整合上述合理假设,压缩域下的红外弱小目标检测问题被转化为对压缩感知的线性测量向量低秩稀疏分解问题,其代价函数可表示为

$$\min \|y - A(B + T)\|_F \text{ subject to } \text{rank}(B) \leq r, \|T\|_0 \leq K, \left(\|X\|_F = \sqrt{\sum_{ij} X_{ij}^2} \right). \quad (3)$$

上面简单介绍了 CLSDM 算法并得到了代价函数。分析代价函数可以发现,虽然 CLSDM 算法成功实现了压缩域下的弱小目标检测,但仍存在以下两个点不足:

1) 低秩度参数不易确定。由(3)式可知,算法要求稀疏度 K 和低秩度 r 两个参数以对矩阵进行低秩稀疏分解。其中低秩度 r 估计的准确与否关系到对背景的有效抑制。原文通过计算图像信息熵线性拟合估计矩阵的秩。信息熵可以有效反映图像灰度分布的复杂度,其定义如下:

$$H = - \sum_{s=0}^{255} p_s \lg p_s, \quad (4)$$

式中 p_s 代表图像中灰度值 s 出现的几率(对 256 色灰度图像, $\sum_{s=0}^{255} p_s = 1$)。文献[13]指出,信息熵仅反映了图像灰度级的个数以及每个灰度级像素的分布情况,没有反映图像灰度的空间分布情况。考虑到环境噪声对信息熵的污染,信息熵与背景矩阵的秩不完全满足线性关系,准确估计背景矩阵的秩需要大量的先验信息和平台计算量。

2) 邻近目标漏警。(3)式没有噪声的定量分析,原文未使用传统基于邻域信噪比的检测方法,而是以局部最大能量为阈值,对重建得到的稀疏目标矩阵进行目标检测,算法如下:

$$T(x,y) = \begin{cases} 1, & \text{if } T(x,y) \geq \beta M \\ 0, & \text{others} \end{cases}, \quad (5)$$

式中 M 表示局部最大能量, β 表示阈值系数。原文并未给出阈值系数的物理意义和设定证明。在实际应用中,这种简单的阈值判断虽然可以有效滤去噪声,但是在多目标检测时容易产生漏警。受观测条件影响,红外小目标的能量起伏明显,对于相邻的强目标与弱目标,算法容易将弱目标判定成噪声。

3 改进的压缩域下红外弱小目标多帧检测算法

针对上面 CLSDM 算法存在的问题,提出一种新的压缩域下红外弱小目标多帧检测算法。算法包括自适应图像重建和噪声统计目标检测两个阶段,流程图如图 1 所示。

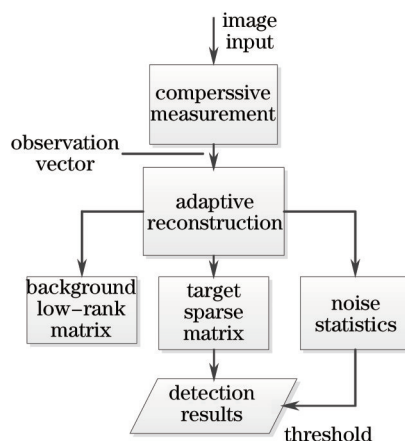


图 1 压缩域下红外弱小目标检测算法流程图

Fig.1 Schematic of infrared small target detection process in compressive domain

图像重建是通过压缩域下的低秩稀疏分解算法直接重建背景矩阵和目标矩阵,并得到噪声的统计信息。在图像重建过程中,首先对观测向量进行低秩矩阵恢复,得到背景低秩矩阵;再计算背景低秩矩阵关于测量矩阵的投影,对观测向量和投影进行差值,对差值后的向量进行稀疏向量恢复,得到目标稀疏矩阵;最后对剔除低秩主成份和稀疏主成份的残差进行统计分析,得到噪声统计信息。

3.1 自适应参数图像重建

由(3)式可知,对线性测量向量低秩稀疏分解前,SpaRCS算法需要背景矩阵的秩和目标矩阵的稀疏度作为贪婪求解问题的先验信息^[6]。在压缩率允许的范围内,设定的目标稀疏度越高,背景秩估计越准确,算法的恢复效果越好。对于稀疏度 K ,参考 CLSDM 算法,认为 $K = 0.15\% \times m \times n$ 是目标矩阵的稀疏度上限。对于矩阵的秩 r ,则通过图像重建误差进行自适应估计。

受压缩比和噪声影响,图像背景实际的秩难以准确估计。当矩阵的低秩度设定明显小于矩阵实际的秩时,算法重建的低秩图像将损失大量杂波细节,重建误差变动较大,目标可能被杂波干扰造成漏警;当矩阵的秩设定接近或者大于矩阵实际的秩时,重建图像精度增加,重建误差明显下降后趋于稳定,但是弱目标可能混入背景矩阵中造成漏警。因此选择重建误差平稳后的范围区间,保证目标和背景杂波能够有效区分。算法根据重建误差的变化趋势确定低秩度参数的上下界,具体流程如图 2 所示。

累加低秩度,在各低秩度参数下分别进行矩阵低秩稀疏分解,得到重建图像和重建误差。设重建误差

为 $\|N\|_F = \|y - A(B + T)\|_F$, 其变化量为 ΔN 。当重建误差平稳时, 有 $\|\Delta N\|_F \leq \varepsilon$, 其中 $\varepsilon = \|N\|_F \times 5\%$ 。最后选取重建误差平稳后的 M 帧重建矩阵序列, 记为 $T_i, 1 \leq i \leq M$ 。

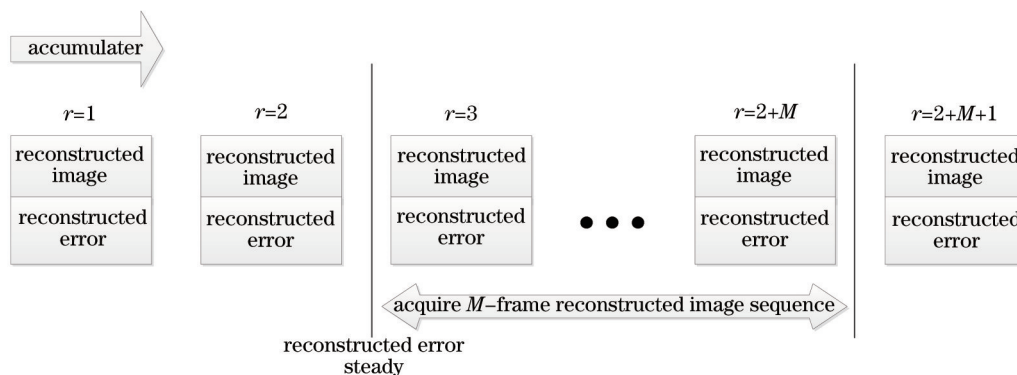


图2 自适应图像重建流程图

Fig.2 Schematic of adaptive image reconstruction process

由于重建目标矩阵的稀疏性, 受重建误差影响的目标像素直接为零, 因此不能直接对重建矩阵序列求平均值。算法根据区间内的多帧目标出现的次数, 对重建矩阵序列统计平均得到目标矩阵, 以保证弱目标的检测率。统计各位置目标强度为非零值的出现次数为

$$c(x, y) = \sum_{i=1}^M \{u[T_i(x, y)] + u[-T_i(x, y)]\}, \quad (6)$$

式中阶跃函数 $u(t) = \begin{cases} 1, & t > 0 \\ 0, & t \leq 0 \end{cases}$ 。设定出现次数门限 $t_{hc} = M/2$, 当该位置目标出现次数小于门限时, 将判断为重建带来的误差; 次数超过门限时, 则保留目标平均值为该位置灰度值。目标矩阵最终表示为

$$T(x, y) = \begin{cases} \frac{\sum_{i=1}^M T_i(x, y)}{c(x, y)}, & \text{if } c(x, y) \geq t_{hc} \\ 0, & \text{others} \end{cases} \quad (7)$$

同原方法相比, 基于自适应估计秩参数的图像重建算法可以避免预处理步骤直接处理压缩域图像, 并且在复杂背景下的检测性能明显提高。

3.2 基于噪声统计的阈值分割

将噪声分析引入检测算法, 通过矩阵低秩稀疏分解的误差得到测量噪声方差的估计, 根据测量噪声方差设定检测算法的阈值, 最终对目标稀疏矩阵进行阈值分割确定目标位置。下面分析图像噪声特点, 建立噪声统计模型并定量地表示出来, 假定各帧图像测量噪声相互独立, 且满足 $\|N\|_F \leq \delta$, 对传统红外目标与背景模型有限定条件为

$$\|D - B - T\|_F \leq \delta, \quad (8)$$

设压缩比为 p , 测量向量的大小为 m_{np} , 压缩域下模型限定条件更新为

$$\|y - A(B + T)\|_F \leq \|A\|_F \cdot \sqrt{m_{np}} \cdot \delta. \quad (9)$$

基于低秩稀疏分解的目标检测算法得到的目标矩阵是稀疏的, 噪声和杂波并不是平均分布在像平面上。噪声点的数量由算法稀疏度参数决定, 噪声点的强度则取决于相机噪声的大小和背景杂波估计精度。考虑低秩稀疏分解算法有效抑制了背景杂波, 假设相机噪声灰度值服从高斯分布规律。首先设置虚警率 P_f , 根据(10)式计算过门限阈值, 式中 $\Phi(\cdot)$ 表示求均值为零、方差为1的高斯分布累积概率函数, $\Phi^{-1}(\cdot)$ 为 $\Phi(\cdot)$ 的逆函数。门限计算公式为

$$T_h = \Phi^{-1}(P_f) \cdot \delta, \quad (10)$$

由(9)式可知 $\delta = \frac{\|y - A(B + T)\|_F}{\|A\|_F \times \sqrt{m_{np}}} = \frac{1}{\sqrt{m_{np}}} \frac{\|N\|_F}{\|A\|_F}$ 。和原阈值分割方法相比,基于噪声统计的阈值分割可以在保证较低虚警率的情况下减少原算法的漏警问题。

4 实验结果与分析

使用 Matlab R2013a 软件,在配置有 3.20 GHz Intel i5 处理器的计算机上完成。

4.1 场景仿真测试

图像数据采用起伏剧烈的红外云层图像,通过添加不同强度的噪声和目标,对目标进行检测,以验证算法性能,如图 3 所示,其中红外仿真图像大小为 256 pixel × 256 pixel。合成的仿真目标大小设为 3 pixel × 3 pixel,位置均匀分布,同时通过高斯滤波对合成目标进行模糊处理,使目标更接近真实情况。定义目标信噪比 S_{SNR} 和信杂比 S_{SCR} 分别为

$$\begin{cases} S_{SNR} = \frac{S}{\sigma_1} \\ S_{SCR} = \frac{S}{\sqrt{\sigma_1^2 + \sigma_b^2}} \end{cases}, \quad (11)$$

式中 S 为原始目标信号强度, σ_1 为噪声标准差, σ_b 为背景杂波起伏标准差。本仿真中设定图像信噪比 S_{SNR} 为 11,对应图像信杂比 S_{SCR} 为 9。

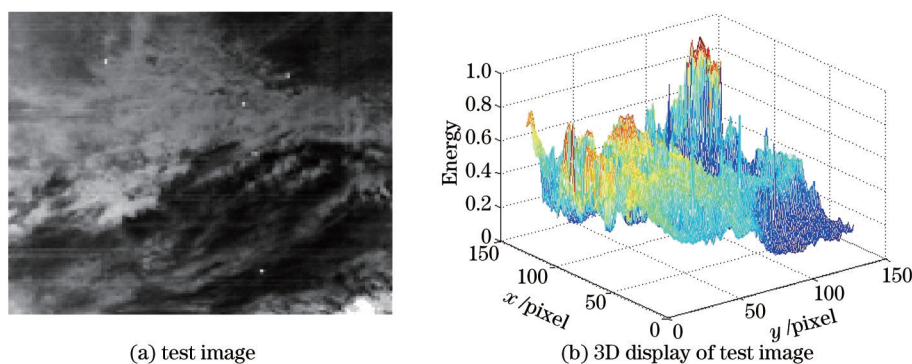


图 3 红外仿真图像

Fig.3 Infrared simulation images

在仿真实验中,选择随机重排列的 Noiselets 矩阵^[14]作为测量矩阵 Φ ,图像压缩比设为 0.5。Noiselets 矩阵具有运算简单且不用储存的性质,适合空间平台处理。自适应参数图像重建过程和阈值分割仿真结果如图 4 所示。

本次仿真中设 $M = 10$ 。图 4(a)是不同低秩度参数下低秩稀疏分解算法重建图像产生的误差变化量 $\|\Delta N\|/\|N\|$,根据误差变化量对第 3 帧到 12 帧进行加权平均。图(b)为自适应图像重建得到的部分帧重建背景矩阵和目标矩阵。上方为背景重建图像,下方为目标重建图像及检测结果,其中蓝色框表示检测到的目标,红色框表示未检测到的目标。从图中可以看出,低秩度参数越高,重建的背景矩阵越清晰。但是在不同的低秩度下,对目标矩阵的单帧检测均出现了漏警的情况。图 4(c)为不同低秩度参数下目标被发现的次数统计, x 坐标表示目标所在图片对应的重建低秩度参数, y 坐标表示目标在各图片中的编号(各编号对应目标位置参考表 1)。图中的蓝点表示目标能被检测到,空白则表示未被检测到。由于各目标位置和强度不同,不存在使 5 个目标同时被发现的低秩度,但算法通过 10 选 5 的方式确保了目标的检测率。对表 1 中的数据和图 4(d)、(e)的实验结果综合分析, CLSDM 算法的阈值分割方法虽然有效去除了稀疏项中的虚警噪声,但是对邻近弱目标(目标 2,目标 4)出现了漏检;对背景估计更加准确,在保证检测率的同时有效降低了虚警噪声。

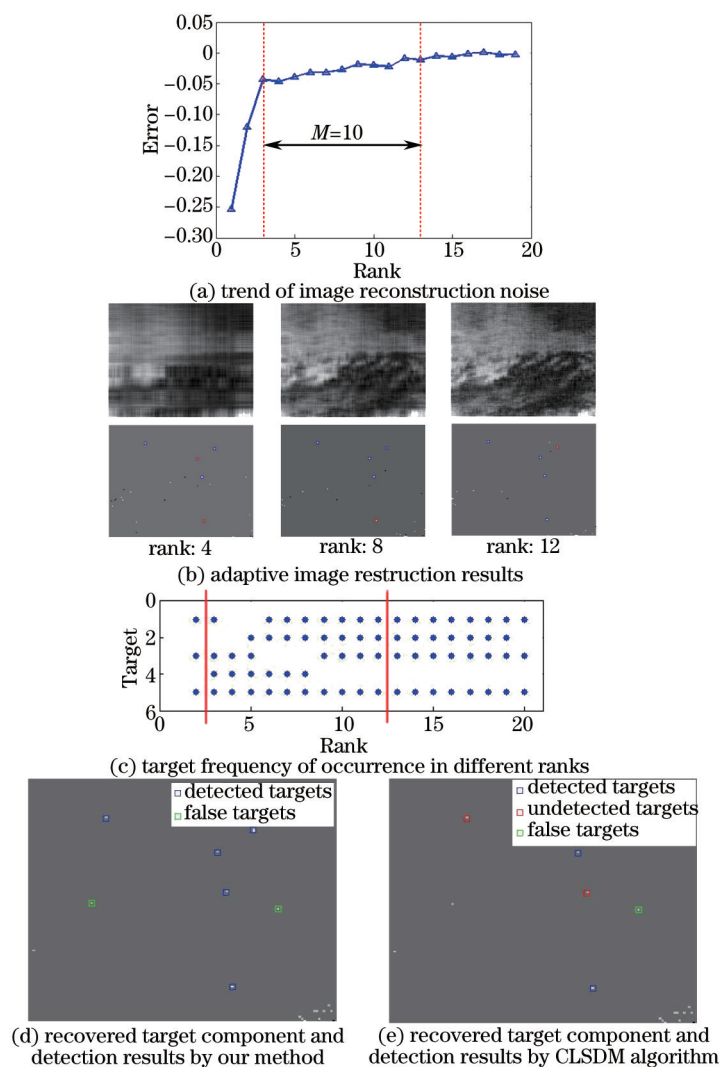


图4 检测结果

Fig.4 Detection results

表1 目标信息统计

Table 1 Target information statistic

Target	Coordinate	Occurrence	Normalized scale
1	(21,33)	8	0.6200
2	(27,94)	8	0.5218
3	(39,79)	7	0.8481
4	(60,83)	5	0.3808
5	(110,85)	10	1.0000

4.2 不同参数和环境下算法性能分析

为了更好地研究改进算法的有效性,将其与改进前的 CLSDM 算法作比较。对于 CLSDM 算法的参数选取采用文献[8]给的选取方法,其中稀疏度 $K=0.15\% \times m \times n$,秩约束 r 则根据稳健主成分分析算法(RPCA)^[15]估计。以受试者工作特征(ROC)曲线为主分析算法性能。采用 Monte Carlo 仿真分别绘制用两种算法做目标检测的 ROC 曲线, Monte Carlo 仿真次数设为 100。在多帧典型场景下进行仿真测试,并统计目标的检测概率和虚警率。这里定义目标检测概率 P_d 和虚警率 P_f 分别为

$$\begin{cases} P_d = (D_i/N_i) \times 100\% \\ P_f = F_i/N \end{cases}, \quad (12)$$

式中 D_i 代表正确检测出的目标数, N_i 代表目标总数, F_i 代表检测出的虚警点, N 代表图像像素总数。实验结果如图 5 所示。

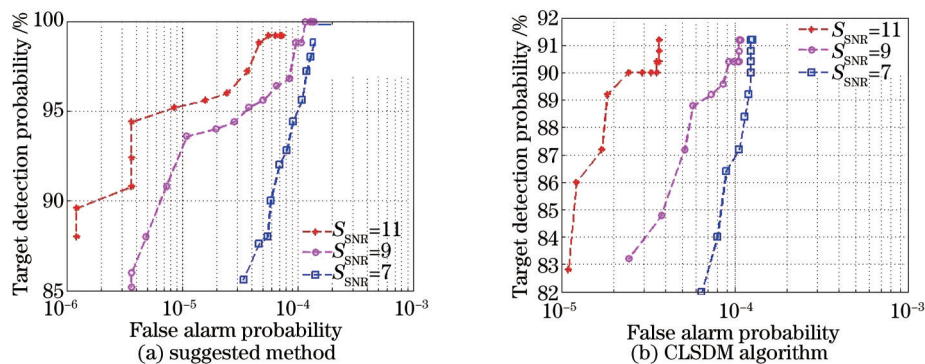


图 5 不同信噪比下 ROC 曲线图

Fig.5 ROC curves of simulation experiments with different SNR

图 5 是两种算法在压缩比 0.8, 不同信噪比下的 ROC 曲线图。随着信噪比降低, 目标被噪声淹没, 算法检测率有所下降。根据实验结果, 当信噪比为 7 时, 本文方法在虚警率为 1×10^{-4} 下仍达到 94% 以上的检测率。可以看出, 本文方法对噪声的稳健性明显优于原算法。

图 6 是两种算法在不同压缩比下的 ROC 曲线图。随着压缩比的降低, 重建算法的迭代次数明显增加, 性能和速度均有所下降。根据实验结果, 算法的虚警率受压缩比影响明显, 当压缩比达到 0.6 时, 本文方法在虚警率 1×10^{-4} 附近仍达到 93% 以上的检测率, CLSDM 算法则已经出现较明显的丢失目标情况。

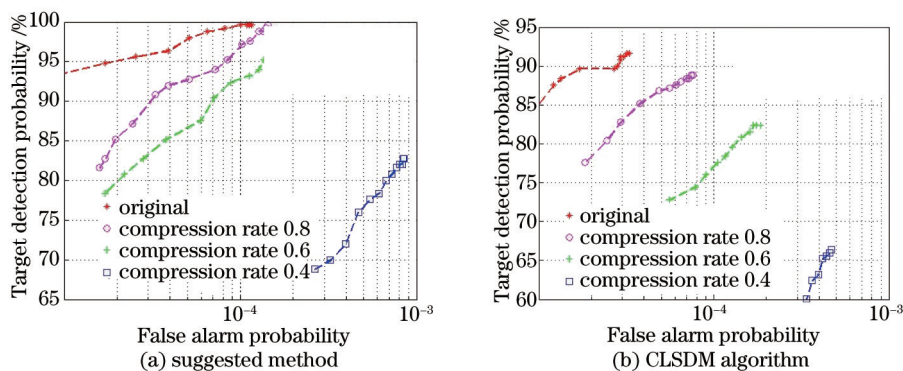


图 6 不同压缩比下 ROC 曲线图

Fig.6 ROC curves of simulation experiments with different compression ratios

图 7 为本算法在检测性能上与其他经典弱小目标检测算法对比的 ROC 曲线图。对比算法选择 max-mean 算法和 top-hat 算法。对比四种算法, 本文提出的算法在检测性能上相比 max-mean 算法、top-hat 算法都有所提升, 相比原文献的 CLSDM 算法, 本文算法检测率进一步提高, 抗噪声能力也较强。

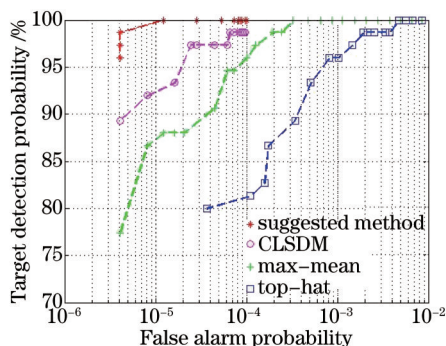


图 7 不同小目标检测算法 ROC 曲线图

Fig.7 ROC curves of different small target detection algorithms

5 结 论

实现了一种基于噪声统计模型的自适应压缩域红外弱小目标检测方法,将噪声统计模型和自适应估计引入原有的低秩稀疏分解算法,同时实现了参数自适应压缩域红外弱小目标检测。结果表明,该算法适合在复杂背景和条件下的压缩域弱小目标检测,能较好实现目标的检测和定位,便于系统后续处理。将来需要进一步考虑的问题是设计更具有显著性特征的目标模型和背景低秩模型,以提高压缩域下红外弱小目标检测的精度与适应性。

参 考 文 献

- 1 Peng Yigang, Suo Jinli, Dai Qionghai, *et al.*. From compressed sensing to low-rank matrix recovery: theory and applications[J]. *Acta Automatica Sinica*, 2013, 39(7): 981-994.
彭义刚, 索津莉, 戴琼海, 等. 从压缩传感到低秩矩阵恢复: 理论与应用[J]. *自动化学报*, 2013, 39(7): 981-994.
- 2 Yang Sa, Yang Chunling. Image registration algorithm based on sparse random projection and scale-invariant feature transform[J]. *Acta Optica Sinica*, 2014, 34(11): 1110001.
杨 飒, 杨春玲. 基于压缩感知与尺度不变特征变换的图像配准算法[J]. *光学学报*, 2014, 34(11): 1110001.
- 3 Han Chao, Wu Wei, Li Mengmeng. Encoding and reconstruction of lensless off-axis Fourier hologram based on the theory of compressed sensing[J]. *Chinese J Lasers*, 2014, 41(2): 0209015.
韩 超, 吴 伟, 李蒙蒙. 基于压缩感知理论的无透镜离轴傅里叶全息编码与重建[J]. *中国激光*, 2014, 41(2): 0209015.
- 4 Liu Xiaoyong, Cao Yiping, Lu Pei. Research on optical image encryption technique with compressed sensing[J]. *Acta Optica Sinica*, 2014, 34(3): 0307002.
刘效勇, 曹益平, 卢 佩. 基于压缩感知的光学图像加密技术研究[J]. *光学学报*, 2014, 34(3): 0307002.
- 5 Waters A E, Sankaranarayanan A C, Baraniuk R. SpaRCS: Recovering Low-Rank and Sparse Matrices From Compressive Measurements [C]. *Advances in Neural Information Processing Systems*, 2011: 1089-1097.
- 6 Needell D, Tropp J A. Cosamp: iterative signal recovery from incomplete and inaccurate samples[J]. *Appl Comput Harmon Anal*, 2009, 26(3): 301-321.
- 7 Guo H, Qiu C, Namrata V. An online algorithm for separating sparse and low-dimensional signal sequences from their sum[J]. *IEEE Transactions on Signal Processing*, 2014, 62(16): 4284-4296.
- 8 Li L, Li H, Li T, *et al.*. Infrared small target detection in compressive domain[J]. *Electron Lett*, 2014, 50(7): 510-512.
- 9 Chen Yin, Ren Kan, Gu Guohua, *et al.*. Moving object detection based on improved single gaussian background model[J]. *Chinese J Lasers*, 2014, 41(11): 1109002.
陈 银, 任 侃, 顾国华, 等. 基于改进的单高斯背景模型运动目标检测算法[J]. *中国激光*, 2014, 41(11): 1109002.
- 10 Zhang Libao, Li Hao. Detection of interest image region based on adaptive radius search[J]. *Chinese J Lasers*, 2013, 40(7): 0714001.
张立保, 李 浩. 基于自适应半径搜索的图像感兴趣区域检测[J]. *中国激光*, 2013, 40(7): 0714001.
- 11 Zheng C, Li H. Small infrared target detection based on harmonic and sparse matrix decomposition[J]. *Opt Eng*, 2013, 52(6): 66401-66410.
- 12 Gu Y, Wang C, Liu B, *et al.*. A kernel-based nonparametric regression method for clutter removal in infrared small-target detection applications[J]. *IEEE Geosci Remote Sens Lett*, 2010, 7(3): 469-473.
- 13 Gao Zhenyu, Yang Xiaomei, Gong Jianming, *et al.*. Research on image complexity description methods[J]. *Journal of Image and Graphics*, 2010, 15(1): 129-135.
高振宇, 杨晓梅, 龚剑明, 等. 图像复杂度描述方法研究[J]. *中国图象图形学报*, 2010, 15(1): 129-135.
- 14 Coifman R, Geshwind F, Meyer Y. Noiselets[J]. *Applied and Computational Harmonic Analysis*, 2001, 10(1): 27-44.
- 15 Candès E, Li X, Ma Y, *et al.*. Robust principal component analysis?[J]. *Journal of the Association for Computing Machinery*, 2011, 58(3): 1-37.

栏目编辑: 何卓铭