

分类号 _____ 密级 _____

UDC^{注 1} _____

学 位 论 文

基于稀疏动态反演的红外弱小目标检测理论及方法研究

(题名和副题名)

王晓阳

(作者姓名)

指导教师 **彭 真 明** 教 授

电子科技大学 **成 都**

(姓名、职称、单位名称)

申请学位级别 **博士** 学科专业 **信号与信息处理**

提交论文日期 **2018.09.05** 论文答辩日期 **2018.11.08**

学位授予单位和日期 **电子科技大学** **2018 年 12 月**

答辩委员会主席 _____

评阅人 _____

注 1：注明《国际十进分类法 UDC》的类号。

**RESEARCH ON INFRARED DIM AND SMALL
TARGET DETECTION THEORY AND
METHODOLOGY BASED ON SPARSE DYNAMIC
INVERSION**

A Doctoral Dissertation Submitted to
University of Electronic Science and Technology of China

Discipline: Signal and Information Processing
Author: Xiaoyang Wang
Supervisor: Professor Zhenming Peng
School : School of Information & Communication
Engineering

摘 要

红外成像探测在精确制导/反导、红外预警、空间远距离目标探测以及天基碎片探测等多个方面都有广泛的应用。该类应用中都需要对目标进行精确检测、识别和解析。由于成像距离长、成像环境复杂以及探测器精度等原因，红外弱小目标检测是一个有挑战性的问题，一直以来也得到了广泛的关注。传统的红外弱小目标检测方法在复杂场景中容易受到背景杂波和噪声的干扰，检测精度有限，在实际应用中效果不佳。稀疏动态反演，或者称为稀疏动态优化，是信号处理领域一种常用的思路，用于从观测量中恢复出信号的成分，并进一步从中提取所需要的信息。通过对红外成像场景和红外弱小目标进行分析，结合稀疏动态反演理论，可以提升弱小目标检测的精度和稳定性，有助于红外搜索与跟踪系统的发展。

本文的研究集中于红外图像分析、模型构建、稀疏动态反演方法研究等，研究对象包括海面、天空及地面等复杂度不同的场景，研究内容主要包括以下几个方面：

(1) 分析了红外图像的背景特性以及目标特性，分析了不同场景的特点以及目标检测的难点。传统的红外弱小目标检测方法往往没有考虑到场景多样性以及目标的不同特性，因此限制了目标检测的效果。本文通过研究红外成像的特点，为后续构建针对性的目标/背景模型打下了基础，也是本文所开展的研究工作的理论基础。

(2) 提出了基于联合正则化的红外弱小目标检测方法，将正则化模型与主成分追踪模型结合，提出一种基于全变差-主成分追踪的红外弱小目标检测方法。在红外场景中，由于成像模糊、缺乏细节信息等特点，红外背景可以被认为是低秩的或者局部低秩的。而在该假设下，背景成分中的边缘等信息容易对目标检测产生干扰，而全变差项的引入可以很好地刻画背景中灰度突变的成分，避免其干扰目标检测。通过构建全变差-主成分追踪联合正则化模型，在目标检测和背景恢复中都取得了很好的效果。

(3) 提出了基于稳定多子空间学习的红外弱小目标检测方法。在复杂成像背景下，会出现图像中包含多个强辐射源或多种干扰物的情况，这些干扰会对红外目标检测造成极大的影响，而传统的红外弱小目标检测方法没有很好地针对这一情况进行设计。本文研究提出了一种基于稳定多子空间学习的红外弱小目标检测方法，针对包含多个辐射源的背景，采用多子空间学习方式，代替传统的单一子空间学习，可以找到适合于描述多个辐射源的线性子空间，更好地刻画背景细

节，进而实现精确的目标检测，在复杂场景中取得了很好的效果。

(4) 提出了基于多任务联合稀疏表示的红外弱小目标检测方法。由于红外图像成像质量差、本身可利用的信息较少等原因，传统的基于稀疏表示的目标检测算法在样本库构建、特征选取等方面难度较大，在实际应用中容易造成误检及漏检。本文采用一种新的多任务联合稀疏表示及分类方法，通过提取四种不同的特征：灰度特征，边缘特征，梯度直方图特征以及灰度分布直方图特征来构建多任务字典；同时将样本分为三类：目标类，平滑背景类以及突变背景类，结合一种新的基于平滑 L_0 范数的求解方法，构建了基于多任务联合稀疏表示的红外弱小目标检测框架。该方法在实际测试中取得了较好的效果。

(5) 提出了一种基于非负变分模态分解的红外弱小目标检测方法。红外图像中的不同成分，包括背景、目标及噪声，其区别不仅表现在灰度分布的不同，也表现在其频域分布的区别。模态分解是一种常用的信号分量分解方法，可以根据信号的不同性质将其分解为不同的子信号。我们采用了一种自适应窄带信号分解方法，称为变分模态分解，并考虑红外目标的非负性，在其中加入非负约束。该算法将经过预处理的红外图像自适应地分解为不同的窄带信号，而红外弱小目标就包含在其中一个窄带之中。该方法计算量较小，检测结果中杂波很少，虚警率很低，在特定场景中可以取得很好的效果。

(6) 提出了两种基于视觉显著性的红外弱小目标检测方法，采用了两种不同的显著性检测思路。其中之一利用了红外弱小目标局部对比度高的特点，首先采用局部熵以及图像块相似度筛选出图像中的潜在目标区域，即显著性高的区域，再在该区域中计算局部对比度，可以高效地得到红外弱小目标检测结果。另一种思路是结合红外弱小目标的灰度显著性和运动显著性，提出一种二值图显著性结合运动信息的红外弱小目标检测方法，通过计算目标的灰度二值图显著性以及运动显著性，可以很好地捕捉到场景中的动态目标。

实际数据测试以及多种评价指标表明，上述提出的方法可以在一定程度上解决红外弱小目标检测中虚警率高、检测率低以及有时存在误检及漏检的问题，结合我们所进行的场景特性分析，本文所提出的方法具有较强的场景针对性，适合于红外搜索与跟踪系统中的应用。此外，本文构建了基于稀疏动态反演检测的全新体系，为后续相关研究打下了坚实的理论基础。

关键词： 红外弱小目标检测，稀疏表示，动态反演，矩阵分解，显著性检测

ABSTRACT

Infrared imaging and detection has been widely used in infrared guidance and anti-missile system, infrared early warning system, long-distance detection and space debris detection, etc. Target detection and intelligent recognition are necessary in such applications. Due to the long imaging distance, complex imaging situation and the quality of infrared sensors, the detection of infrared small targets has become a challenging problem, which draws wide attention. Traditional infrared small target detection methods have their drawbacks, such as the unstable performance against background clutter and noise, which is not suitable for extensive usage in practical. Sparse dynamic inversion, or sparse dynamic optimization, is a common approach in signal processing used for extracting certain components from input signals, which could further reveal important information. By analyzing infrared imaging background and infrared small targets, infrared small target detection performance could be improved, combining the sparse dynamic inversion theory. The stability and the effectiveness of infrared search and tracking systems would also benefit from this research.

The content of this thesis focuses on the analysis of infrared images, model construction, sparse dynamic inversion approach, etc. The scenes include sea background, sky background and ground background, with various distribution and complexity. The main contents are listed as follows:

(1) The infrared imaging background and target features are fully analyzed. The characteristics of different backgrounds and the difficulties of detection tasks are cleared. Traditional infrared small target detection methods didn't consider much about the diversity of backgrounds and infrared targets, which leads to the instability under clutter scenes. In this thesis, by starting from the infrared imaging theory and system, the solid foundation of target/background model construction is build, which also serves as the theoretical base of the research work in this thesis.

(2) An infrared small target detection approach based on joint regularization is proposed. The principal component pursuit (PCP) model is combined with the total variation (TV) regularization method, named as TV-PCP method. In infrared scenes, due to the blurring features and the lack of detailed information, the infrared background could be considered as low-rank, or partly low-rank. Under this assumption, the edges within back-

ground component could be the interruption for target detection. By introducing the total variation term into the PCP model, the changing components in background can be well described, which prevents it from interrupting the target detection. By building the TV-PCP joint regularization model, the performance of target detection as well as background estimation has been improved.

(3) An infrared small target detection method based on stable multi-subspace learning is proposed. Multiple infrared radiation sources could exist in complex infrared background, which would interfere the detection of infrared small targets. The scenes with multiple radiatio sources were not fully considered in traditional infrared small target detection methods. In this thesis, we propose to use the multi-subspace learning based methods to deal with highly complex background. Different from the single subspace learning, multiple subspace learning is more suitable for dealing with the afore-mentioned complex scenes. The details in background can be well modelled, which would help with the detection of infrared small targets. The proposed method has been proved to be effective.

(4) A multi-task joint sparse representation based infrared small target detection approach is proposed. Because of the lack of information in infrared images, sparse representation-based detection approaches always face difficulties in the construction of samples and the choice of features. In practical, it would lead to false detection or missed detection. We propose to use a novel multi-task joint sparse representation and classification method to build the infrared small target detection system. Four features are used, including grey feature, edge feature, histogram of gradient feature and grey histogram, to classify all samples into three classes: target class, smooth background class and changing background class. An optimization solver based on smoothed L0 norm is also introduced in the proposed approach. Experimental results show good target detection performance of the proposed method.

(5) A non-negativity constrained variational mode decomposition method is proposed. Different components in infrared images, including background, targets and noise, they have different grey level distribution in spatial domain. As a result, the frequency distribution is also different. Mode decomposition is a common approach for signal decomposition, which is widely used for decomposing input signal into sub-signals with different features. An adaptive narrow-band signal decomposition method, variational mode decomposition (VMD), is used for infrared small target detection. Considering the non-negativity feature of infrares bright targets, the corresponding constraint is introduced

to the VMD method. The pre-processed infrared image is adaptively decomposed into narrow-band sub-signals. The infrared small target is distributed in one of the sub-signals. By this means, the proposed method is computational efficient, with small amount of clutter in the detection results, as well as with low false alarm rate. It outreaches the existing methods under certain types of infrared background.

(6) Two visual-saliency based infrared small target detection methods are proposed, using two different ways to detect the infrared small targets. One of the approaches uses the local contrast of infrared small targets. The potential target area is located by using local entropy and the local similarity of infrared images. After that, the local contrast is computed in the potential area, which is a highly efficient approach. Another saliency detection approach is based on the grey saliency and the motion saliency of infrared small targets. A boolean map saliency method combined with motion feature is proposed. By computing the boolean map saliency as well as the motion saliency, the infrared small target can be easily located, especially in dynamic scenes.

Experiments results on real dataset and the evaluation results show that, the proposed approaches in this thesis solve the problem of infrared small detection with low false alarm rate and high detection rate. It also solves the problem of missed detection in some scenes. Combined with the infrared background analysis we did in this thesis, the proposed approaches are well designed for certain backgrounds, which can be further applied in infrared search and track systems. Additionally, we build a theoretical system of infrared small target detection based on sparse dynamic inversion, which is a good starting point for the follow-up applications.

Keywords: infrared small target detection, sparse representation, dynamic inversion, matrix decomposition, saliency detection

目 录

第一章 绪 论	1
1.1 研究背景及意义.....	1
1.2 国内外研究现状及发展动态.....	5
1.2.1 红外弱小目标检测技术.....	5
1.2.2 图像的稀疏反演技术.....	9
1.3 主要研究工作及技术路线.....	11
1.4 论文结构安排.....	13
第二章 红外弱小目标反演及检测	15
2.1 复杂背景红外成像特性.....	15
2.2 红外弱小目标成像特性.....	21
2.3 动态反演方法.....	22
2.3.1 预备知识.....	23
2.3.2 反演方法.....	25
2.4 本章小结.....	29
第三章 联合正则化红外弱小目标检测	30
3.1 联合正则化理论.....	30
3.2 基于全变差-主成分追踪的红外弱小目标检测.....	31
3.2.1 全变差理论.....	31
3.2.2 主成分追踪理论.....	32
3.2.3 全变差-主成分追踪红外弱小目标检测算法.....	33
3.3 实验与结果分析.....	39
3.3.1 算法参数设置.....	39
3.3.2 评价指标.....	40
3.3.3 检测结果与分析.....	42
3.4 本章小结.....	48
第四章 基于子空间学习的红外弱小目标检测	49
4.1 子空间学习理论.....	49
4.2 基于稳定多子空间学习的红外弱小目标检测.....	49
4.2.1 低秩表示与子空间聚类.....	49
4.2.2 基于稳定多子空间学习的红外弱小目标检测.....	51

4.3	实验与结果分析.....	56
4.3.1	参数设置.....	57
4.3.2	仿真数据测试.....	57
4.3.3	实际场景数据测试.....	62
4.3.4	计算效率测试.....	66
4.4	本章小结.....	67
第五章	基于稀疏表示的红外弱小目标检测	68
5.1	红外图像稀疏表示理论.....	68
5.1.1	稀疏表示理论.....	68
5.1.2	稀疏表示在红外目标检测中的应用.....	69
5.2	基于多任务联合稀疏表示的红外弱小目标检测.....	70
5.2.1	多任务联合稀疏表示理论.....	70
5.2.2	基于 MTJSRC 的红外弱小目标检测方法.....	74
5.3	实验与结果分析.....	79
5.3.1	样本库构建.....	79
5.3.2	评价指标.....	80
5.3.3	检测结果与分析.....	82
5.4	本章小结.....	84
第六章	基于变分模态反演的红外弱小目标检测	86
6.1	模态分解与变分理论.....	86
6.1.1	经验模态分解.....	86
6.1.2	变分模态分解.....	87
6.2	非负约束变分模态分解红外弱小目标检测.....	88
6.2.1	模型构建.....	89
6.2.2	求解方法.....	92
6.3	实验与结果分析.....	93
6.4	本章小结.....	97
第七章	基于显著性的红外弱小目标检测	99
7.1	显著性检测理论.....	99
7.2	局部对比度结合区域显著性红外弱小目标检测.....	100
7.2.1	红外图像区域显著性度量.....	100
7.2.2	局部对比度策略.....	102
7.2.3	LCM 结合区域显著性红外弱小目标检测算法.....	104

7.3 基于二值图显著性与运动信息的红外弱小目标检测.....	105
7.3.1 二值图显著性.....	105
7.3.2 BMS 结合运动信息的红外弱小目标检测	106
7.4 实验结果与分析.....	109
7.4.1 局部对比度结合区域显著性方法.....	109
7.4.2 二值图显著性结合运动信息方法.....	112
7.5 本章小结	114
第八章 总结与展望	115
8.1 全文总结.....	115
8.2 后续工作展望	117
致 谢	119
参考文献	120
攻读博士学位期间取得的成果	134

第一章 绪论

1.1 研究背景及意义

红外线 (Infrared), 又称为红外光, 是波长介于微波和可见光之间的电磁波, 其波长在 760 纳米 (nm) 至 1 毫米 (mm) 之间, 是波长比红光长的非可见光, 对应的频率约在 430 THz 到 300 GHz 的范围内。对于室温下的物体, 一般来说, 其所发出的热辐射大多都在此波段。红外线是在 1800 年由天文学家及音乐家威廉·赫歇尔 (William Herschel) 所发现的。因为红外线具有极好的热效应和极强的穿透能力, 200 多年来, 红外线被成功应用在军事、工业、科学及医学等领域。

物体通常会辐射出跨越不同波段的红外线, 但是红外探测装置通常只能接收特定频谱宽度以内的辐射, 在实际应用中, 红外线会被区分成不同波长的较小区段。通常人们将红外辐射按照波长的不同, 划分为近、中、远及极远红外四部分。根据 ISO 20473 标准, 近红外指的是波长为 0.78-3 μm 的红外辐射; 中红外指的是波长为 3-5 μm 的红外辐射; 远红外则指波长为 5-15 μm 的红外辐射, 极远红外指的是波长大于上述值的红外辐射。对于大气层而言, 由于传输过程中大气对红外辐射的吸收, 只留下三个波长区间可以允许红外辐射通过, 被称为“窗口”区, 即 1-3 μm 、3-5 μm 和 8-13 μm 。因此, 这三个波段的红外线也分别称为短波红外线、中波红外线和长波红外线。

由于红外线具有诸多良好的物理性能与应用前景, 与可见光成像类似的红外线的探测与成像也成为了各国所感兴趣的方向和课题。第二次世界大战期间, 各国都开始加大投入, 进行相关方向的初步研究与小规模应用。20 世纪 50 年代初, 钽化铟热成像仪被发明出来。其基本原理与可见光成像系统类似: 外界的红外线通过光学系统的聚焦, 然后通过感光元件阵列得以成像。在此之后, 相关研究在多个领域大规模展开, 红外热像仪的尺寸和使用复杂程度也随着技术进步而双双降低。今日, 由于红外热像仪拥有夜间成像、全天候视物等能力, 红外成像技术在现代军事、交通、安防监控等领域得到了广泛的应用。同时, 应用于不同领域的红外图像综合处理系统也成为了近年来的研究热点与难点。因此, 开展对于红外图像综合处理系统的研究便具有了很重要的意义与应用价值。

红外图像处理系统包括红外探测器阵列、信号处理系统以及显示器三部分; 红外探测器阵列涉及到气敏材料、光敏材料以及器件设计; 信号处理系统则涉及到信号降噪、预处理、目标检测与跟踪以及识别等; 显示器用于展示红外监控结果。其中, 红外目标检测与跟踪是红外成像系统的关键技术和核心模块之一。随着

现代军事科技的进步与现代军事应用的逐步复杂化, 红外预警、制导以及反导系统等都对相应的信号处理系统及算法提出了更高的要求, 对虚警率的要求非常严格, 同时必须要满足目标检测准确率大于 90%。其中, 复杂背景以及动态场景下弱小目标的检测和跟踪得到了越来越多的重视。这里, 红外弱目标 (Infrared Dim Target) 指的是红外图像中辐射能量较弱的目标, 与背景的对比度很低, 通常认为其信杂比 (Signal-to-Clutter Ratio, SCR) 小于 3, 被大量背景杂波及噪声淹没^[1]; 红外小目标 (Infrared Small Target) 指的是在图像中所占面积小的目标, 这类目标通常不具有形状信息, 面积介于 2×2 到 9×9 像素之间, 直观表现为点目标等^[2]。该类目标的检测问题具有以下几个特性和难点: (1) 目标缺乏特征: 因为目标较小, 因此该类目标不存在精细的结构, 如形状, 纹理等信息, 因此, 基于形状和纹理分析的可见光图像中的目标检测手段无法被直接应用在红外弱小目标的检测之中; (2) 目标强度较低: 与可见光成像系统相比, 红外成像系统所捕获的图像往往存在对比度较差的问题。同时, 相较通常的可见光成像系统而言, 目前大多数红外热像仪的驱动电路与散热系统都会导致更大的噪声与杂波, 因此造成了红外弱小目标更容易被杂波淹没和干扰; (3) 成像环境复杂: 红外成像系统较多应用于军事与安防领域, 在这些应用场景下, 其成像的环境往往极为复杂, 其中包含了多种干扰, 如战场环境下的烟尘导致目标强度变化以及被遮挡, 海面环境下的水面波纹对目标的干扰等等, 这对目标检测系统的鲁棒性就有着更高的要求; (4) 目标运动情况复杂: 在军事应用和安防应用场景下, 目标的高机动性对于检测方法的实时性和准确性也提出了更高的要求。这些难点的存在, 对红外弱小目标的检测与跟踪算法造成了更大的挑战, 这一直以来也是国内外学者研究的热门课题。在过去几十年里, 红外目标检测与跟踪已经发展出了一些传统的、应用广泛并具有一定效果的方法。但由于上述种种特点和难点的存在, 给检测和识别工作带来了一定困难。探索新的红外弱小目标检测框架, 提高目标检测的精度, 进而提高目标跟踪的性能和系统的鲁棒性, 具有极大的理论和现实意义。

一般来讲, 含有弱小目标的红外图像可以被表示为背景与目标的叠加, 同时图像中含有噪声, 为了方便起见, 一般认为是加性噪声。在红外图像中检测弱小目标的问题就是从原始图像中分离背景与目标的问题, 同时避免被噪声干扰。因此, 该问题便可以被视为一个二分类问题, 即将所有的像素逐一分类为目标或者非目标。并且由于目标面积很小, 因此必须达到精确的像素级分类。在该理论模型下, 我们可以采用信号反演的思路来处理弱小目标的检测问题。反演问题, 可以被简单地概括为已知观测信号以及信号与参数集之间的映射, 从中反求参数集的问题, 即从观测数据及某些一般原理或模型出发, 来估计模型中的参数, 其最

终目的是求解出模型中的未知数，在观测数据与模型之间建立某种联系。地球物理学中正演及反演问题的研究，最初起源于物理和地质学家探索地球内部构造的愿望。正演理论，指的是根据某些一般原理或模型，以及一系列与所处理的问题有关的已知具体条件来推测和计算观测结果的方法^[3]。经过数十年不间断地发展，这一类问题在理论和实践层面都取得了巨大的进展：反演理论逐步完善，各类优化方法被不断地提出，同时反演问题也渗透入了各个应用领域。具体到弱小目标检测问题，我们的观测为红外图像，参数集为对图像不同部分的目标/背景分类。根据输入信号中的不同成分所具有的不同性质，针对性地进行建模及表示，继而进行求解以得到目标检测结果。我们可以据此获得准确的弱小目标检测结果。采用反演的方法来完成弱小目标的检测，是红外弱小目标检测领域一个新的框架，也是对反演理论的一种推进。其中，最优化研究领域的最新进展可以应用于弱小目标反演检测。此外，信号处理领域中的最新理论成果，例如压缩感知、模态分解以及显著性检测等，都可以被用于弱小目标检测。这些新方法和新思路可以更好地解决复杂场景下红外弱小目标的检测精度问题。

本文在充分分析红外图像成像机理以及海面、空中以及地面等应用场景的基础上，进一步研究了基于稀疏表示、动态反演以及信号处理中其他一些新思路的红外弱小目标检测方法，利用红外背景和红外目标的差异性，提出并构建了基于联合正则化以及基于多子空间学习的红外弱小目标检测方法。同时，本文还研究了基于多任务联合稀疏表示的红外弱小目标检测方法以及基于频域模态分解的红外弱小目标检测方法，其中涉及到稀疏表示及动态反演方法。此外，本文还研究了基于视觉显著性的检测方法，在理论上有较大突破，研究成果具有很高的实际应用价值。具体来说，其应用领域包括但不限于以下几个方面：

1. 空间目标探测

近年来，伴随着人类探索太空的步伐，太空活动也在不断地增加，这导致了太空中，特别是地球轨道上的空间目标逐年增多。空间目标，主要可以分为航天器与空间碎片两类。这两类空间目标均为我们感兴趣的目标。其中对于航天器的类型，型号以及功能的探测和分析可以获取空间态势以及其他重要的战略信息。而太空中的空间碎片则是航天器正常运行的大敌：航天器和空间碎片的碰撞和刮擦都可以导致航天器的不正常运行甚至坠毁。因此，对这些空间目标进行检测和分析成为了一个极重要的应用场景。同时，由于探测距离较远，目标实际尺寸较小，这些空间目标的成像均呈现了小目标的形态。传统的基于可见光图像和雷达的目标探测系统存在着成本过高或不能全天时、全天候工作等问题。同时，因为红外线有更宽的频谱范围，比可见光拥有更强的穿透大气层的能力，因此基于红外图像的

空间目标探测系统在近十年来受到了更广泛的关注。美国于 2011 年提出了空间轨道碎片检测、捕获和跟踪 (Small Orbital Debris Detection, Acquisition and Tracking, SODDAT) 计划, 旨在实现对尺寸很小的空间近地轨道目标的检测、捕获与跟踪; 同时为该计划设立了位于加州的空间目标跟踪设施 (Space Object Tracking, SPOT), 该跟踪设施拥有三个红外望远镜, 可以从各个角度准确地捕捉到空间目标的红外特征。英国也设立了类似的设备, 称为英国红外望远镜 (United Kingdom Infrared Telescope, UKIRT)。美国国家航空航天局以及其他机构使用上述设施获取地球同步轨道的空间碎片信息。而国内对于空间目标的红外探测起步较晚, 在准确率以及信息获取能力上都有很大的进步空间。高性能的红外弱小目标检测方法在该类系统中具有重要的研究价值与实用价值。

2. 红外预警

前文我们曾介绍过, 自然界中任何温度超过绝对零度的物体都会向外辐射红外线, 其辐射频率和强度是不同的。红外热像仪则是被动地接受这些物体散射出的红外线。正是由于该方法的被动探测性质, 使得其不容易被其他探测设备所发现。随着近年来反辐射技术、导弹/飞机隐身技术、综合电子干扰等技术的迅猛发展, 传统的雷达探测技术虽暂时不能被取代, 但也出现了生存能力低和预警能力下降的问题。基于红外的被动工作方式, 红外预警成为了现代预警技术的发展方向。同时, 红外预警系统由于其高穿透性和高分辨能力, 其在杂波较多的森林, 海域以及烟尘污染的环境中具有良好的侦测能力, 因此基于红外的预警系统也成为了各国争相发展的对象。目前, 美俄两国均拥有先进的星载红外预警系统, 其中美国的天基红外系统 (Space-based Infrared System, SBIRS) 代表了目前的最高水平。相比而言, 我国的红外预警系统响应较慢、预警准确率有限, 在这些方面还有很大的发展空间。同时, 由于红外探测器的成像范围远, 穿透力强, 在红外预警环境中的大部分目标都可以被归类为弱小目标。因此, 高性能的红外弱小目标检测方法在红外预警系统中有着很重要的价值。

3. 红外制导及反导

红外制导技术是实现精确打击、导弹抗干扰的必要手段, 由于战场环境日益复杂, 干扰技术和抗干扰技术的重要性凸显, 二者相辅相成, 在抗衡中不断进步。红外制导技术也经历了从单元到多元, 再到成像制导的发展路径, 在此之中, 对红外探测中的目标检测技术也相应提出了更高的要求。在红外反导方面, 装备了红外制导的导弹, 包括空空导弹和地空导弹, 对战斗机等飞行设备造成了很大的威胁。正是由于这个原因, 各国都非常重视开发相关的红外对抗以及反导系统。其中, 以美国所开发的国家导弹防御系统 (National Missile Defense, NMD) 和战区

导弹防御系统 (Theater Missile Defense System, TMDS) 最为成熟。此外, 俄罗斯、印度、日本等国家也都开发了红外反导系统。在红外制导与反导系统中, 由于探测距离较远, 图像中的大部分感兴趣的目标都可以被归类为红外弱小目标。因此, 高性能红外弱小目标检测技术将在光学制导、反导系统中发挥重要作用。

本研究得到了国家自然科学基金 (61571096, 41274127, 41301460, 61575038), 中科院光束控制重点实验室基金 (2017LBC003, 2014LBC002), 中央高校基本科研业务费 (A03012099901013) 以及国家留学基金委“建设高水平大学公派研究生项目”的资助。

1.2 国内外研究现状及发展动态

红外弱小目标检测是多种现代军事系统的关键模块, 包括红外搜索与跟踪系统、红外成像制导系统以及红外预警系统等, 其中, 弱小目标的探测精度与系统性能往往息息相关。与可见光图像不同的是, 在红外成像系统中, 由于成像距离长, 红外图像中的弱小目标往往不具有确定的形状信息以及纹理信息; 并且, 在天空 (含云层)、地面以及海面等相对复杂多变的背景下, 小目标往往淹没在背景噪声中, 直观表现为一个边缘较模糊的光斑。这些因素使得红外弱小目标的检测成为了一个有挑战性的问题, 国内外诸多学者都针对此问题进行了研究。近年来, 随着信号表示中稀疏表示 (Sparse Representation, SR)、压缩感知 (Compressed Sensing, CS) 以及矩阵分解 (Matrix Decomposition, MD) 等理论的兴起, 目标检测这一问题也被注入了新的活力。下面将分别介绍红外弱小目标检测的发展历程和现状以及反演问题发展历程及现状两个方面。

1.2.1 红外弱小目标检测技术

当前, 全球军备竞争日益激烈, 同时出于国家安全以及战略发展的考虑, 地球外层空间的开发和利用也得到了越来越多的重视, 各国都投入到空间竞争的行列当中。在军事方面, 由于红外探测系统与雷达探测相比具有诸多优势, 发展红外系统, 意味着保持军事竞争中的优势。1992年起, 美国大力开发了天基红外系统 (Space-Based Infrared System, SBIRS), 可以覆盖到全球范围, 用于探测导弹发射、跟踪飞行中的敌方导弹等, 同时兼具指引反导武器以及对探测到的敌方目标加以摧毁的功能。此外, 红外精确制导技术也属于兵家必争之地, 成为各国争相发展的对象, 具有重要的战略价值。因此, 红外弱小目标的检测技术具有多方面的意义。此外, 该技术也广泛地应用于民用场景中。从上世纪七十年代起, 弱小目标检测的相关研究逐步开展, 自 1989 年开始, 光学工程学会 (International Society

for Optical Engineering, SPIE) 开始举办“小目标信号和数据处理 (Signal and Data Processing of Small Targets)”的年度国际会议, 主要针对一些难点问题, 例如弱小目标的特征提取, 弱小目标识别, 杂波抑制, 弱小目标长时间连续跟踪等问题进行讨论和交流^[4]。我国对于红外弱小目标检测的研究相对国际而言起步较晚, 现阶段主要有中国科学院、国防科技大学、哈尔滨工业大学、电子科技大学、西安电子科技大学以及中国航天工业集团等单位对相关技术以及系统进行了较深入的研究。

一般而言, 根据利用输入信息的方法的不同, 我们将红外弱小目标检测方法分为两大类: 跟踪前检测 (Detection Before Track, DBT) 方法, 以及检测前跟踪 (Track Before Detection, TBD) 方法。DBT 方法的潜在思路是单帧目标定位以及多帧关联。具体来说, 首先在当前帧中用目标检测算法检测出初步的目标区域, 再将多帧中的目标区域进行关联, 剔除虚假目标, 以此得到真正的目标区域; TBD 方法对所有可能的目标区域都进行跟踪, 再根据后验概率确定该轨迹是否属于真实的目标。简单来说, DBT 算法先利用单幅图片的空间信息进行检测, 再利用序列图片的时间信息来进行确认; TBD 算法利用了序列图片的时间信息, 先进行轨迹跟踪和能量累加, 再进行目标的检测^[4]。

常见的红外弱小目标检测方法中, 基于图像滤波的方法是一种典型的 DBT 方法, 此外, 基于模式识别的思路也是先利用了单帧信息, 因此也属于 DBT 方法。典型的基于图像滤波的方法包括二维最小均方差方法 (Two Dimensional Least Mean Square, TDLMS)^[5]、基于顶帽滤波 (Top-hat Filter) 的方法^[6-8] 以及小波变换方法等^[9,10]。而基于模式识别的方法, 则是利用了图像分类的思想, 将弱小目标的检测看作一个分类问题, 判断出某一个点出的图像信号属于目标类或是背景类, 例如 Y. Cao 等 (2008) 提出了一种弱小目标检测方法, 称为概率性主成分分析 (Probabilistic Principal Component Analysis, PPCA), 通过将原图像投影到新的子空间, 可以判断出原像素属于目标或背景的概率^[11]; Y. Gu 等 (2010) 提出了一种基于核回归的弱小目标检测方法, 其思路同样是对输入图像进行像素级分类, 来判断目标所在位置^[12]; K. Xie 等 (2015) 构建了局部线性化的参数模型, 同时引入核方法将线性模型扩展成了非线性模型, 再通过背景减除获得最终检测结果^[13]; C.Q. Gao 等 (2018) 提出了基于马尔科夫随机场的像素分类方法, 应用于红外弱小目标检测, 在弱目标环境下取得了很好的效果^[14]。上述均为典型的 DBT 方法, 在单帧图像中利用滤波或者模式识别的思路进行目标检测。

随着该研究内容的不断发展, 传统方法在某些应用场景中可能不再适用, 大量的改进算法随之涌现, 理论体系也得到了更新和发展。此外, 针对弱小目标检测问题, 近年来也出现了一些跳出传统方法框架的新思维模式, 给这个问题注入

了新的活力。其中的代表性研究成果包括重庆大学 C.Q. Gao 等（2012）提出的基于稀疏环表示（Sparse Ring Representation, SRR）的检测方法^[15]，以及其团队在 2013 年提出的基于图像块模型（Infrared Patch Image Model, IPI Model）的红外弱小目标检测方法，将红外弱小目标检测问题转化为矩阵分解问题，采用主成分追踪算法进行求解^[16]。H. Wang 等（2018）在此基础上提出了张量块模型，将更多有用的信息加入了局部块模型的构建中，提高了算法的自适应性^[17]。此外，基于视觉显著性的 DBT 方法也得到了一定的关注与发展，典型的成果包括华中科技大学 S. Qi 等（2013）提出的一种基于四元数傅里叶变换的红外图像小目标增强方法^[18]，通过将输入红外图像采用不同的滤波器进行预处理，再进行四元组傅里叶变换，突出其在不同表示域中的显著性特征；X. Dong 等（2014）研究提出了一种专门针对运动目标的检测方法，以兴趣点跟踪为基础，假设运动中的红外目标属于人眼的感兴趣区域，进而实现感兴趣区域提取和目标跟踪^[19]；C. L. Chen 等（2014）提出了一种基于视觉显著性的方法，利用红外弱小目标的局部对比度特征，构造局部对比度图，进行红外弱小目标检测^[20]。该方法用非常简洁的模型表示出了红外图像的多尺度局部对比度，可以很好地增强目标；J. Han 等（2018）在此基础上，同样利用红外弱小目标的视觉显著性，提出了多尺度局部对比度检测算法^[21]。综合上述讨论可以看出，这些方法往往集中于单幅图像的处理，几乎没有利用任何时间信息。在某些红外场景及应用中，也可以取得很好的效果。

从上述分析可知，由于 DBT 方法采用了单幅图片检测机制，因此最终检测效果与单幅图片检测的效果关系密切。但红外系统的应用场景多变，有时会出现单幅图片信杂比很低、难以准确定位目标的情况，此时适当地利用空间信息对目标进行提取，可以提高检测精度。TBD 方法就是基于这样的思路，通过处理连续的图像帧，进行目标定位及关联，在一定程度上避免 DBT 方法的不足。输入的图像序列中包含着每一幅图像的空间信息，同时也包含连续帧之间的时间等信息。配合一些先验信息，例如目标的运动方向、运动速率等，该类方法往往可以在一定程度上取得较好的检测效果。其中的典型算法包括了 I.S. Reed（1988）提出的三维匹配滤波方法^[22]，R.W. Fries（1989）提出的改进三维匹配滤波方法^[23]，以及 T. Aridgides（1990）提出的自适应三维时空滤波算法等^[24]，上述基于三维匹配滤波的算法主要用于抑制背景，以及突出目标。此后，也有一些学者沿用这个思路做了不同程度的改进，如 M. Li 等人（2005）提出的三维双向滤波算法^[25]，以及 T. Zhang（2007）提出的由粗略搜索到精确搜索的三维双向滤波算法等^[26]，这两种方法针对复杂背景下的微弱目标探测取得了较理想的效果。此外，TBD 方法还包括基于管道滤波（Pipeline Filter, PF）的方法^[27]，基于多级假设检验（Multistage

Hypothesis Testing, MSHT) 的红外弱小目标检测算法^[28], 基于时域剖面 (Temporal Profile, TP) 的红外弱小目标检测方法^[29], 基于动态规划 (Dynamic Programming, DP) 的方法^[30] 以及基于贝叶斯估计 (Bayes Estimation, BE) 的检测方法^[31] 等。近年来针对 TBD 的研究也有一些新思路, 例如, M. Wan 等 (2016) 提出了一种在复杂云层场景下利用帧间信息检测弱小目标的方法, 利用目标和云层不同的变化特点, 在该特定场景下取得了很好的效果^[32]。重庆大学李正周教授的团队近年来在红外弱小目标检测及跟踪方面取得了一系列成果, 利用红外图像的帧间信息构造字典, 进而实现鲁棒性检测及跟踪^[33-35]。上述方法无一例外都利用了红外序列的时域信息, 这是 TBD 方法与 DBT 方法的最大区别。

除上述算法之外, 值得注意的是, 近年来随着深度学习技术的发展, 越来越多的研究者试图用这一高效的工具来处理红外弱小目标检测问题。尽管利用深度学习进行红外弱小目标检测可以被视为是一种基于特征的方法, 但由于其检测框架是基于深度神经网络的发展而产生的, 因此我们不再将其归类于 DBT 检测方法或者 TBD 检测方法。W.T. Wang 等 (2017) 提出了一种利用卷积神经网络 (Convolutional Neural Network, CNN) 进行红外弱小目标检测的方法, 采用 CNN 获取更好的目标特征描述子^[36]。Z. Fan 等 (2017) 采用 CNN 对红外图像进行增强, 针对低对比度红外图像的特点, 在第一层网络中采用训练出的卷积核进行卷积, 最终实现对红外图像各个部分的增强^[37]。该研究结果对红外弱小目标检测的预处理部分有着很大的参考价值。Q. Liu 等 (2017) 实现了利用 CNN 的红外目标跟踪, 以在可见光图像中预先训练好的网络为初始模型, 针对红外图像进行了一定调整^[38]。值得注意的是, 以上应用虽然不全是直接针对弱小目标检测问题的, 但毫无疑问, 这些思路和研究成果应用于红外搜索与跟踪系统中, 可以提高红外目标检测与跟踪的精度和鲁棒性。

至此我们回顾了现有的红外弱小目标检测算法, 包括传统的 DBT、TBD 算法以及近年来的一些新思路, 例如基于深度学习的算法等。尽管上述思路可以在一定程度上解决弱小目标检测的问题, 但由于实际成像场景变化多样, 同时待检测目标的类型也在不断更新, 很难找到在不同应用中都行之有效的方法。换言之, 红外弱小目标检测问题没有一劳永逸的解决方案。此外, 部分现有的算法需要较强的人工干预, 例如参数的选择等, 其自适应程度相对较低^[39]。同时, 现有的算法也不可避免地存在一些缺陷, 例如, 所处理的场景相对较为单一, 多为天空、海面等, 在这样的背景下, 干扰目标检测的虚警源类型同样比较单一^[40,41]。而随着红外搜索与跟踪系统的应用愈加广泛, 其应用场景势必向着更加多样化的方向发展, 这对现有的技术造成了一定的挑战。此外, 在现有的红外弱小目标检测研究

中，由于其研究的主体是红外弱小目标，背景的成像特性没有得到足够的重视。而在实际中，对背景特性和其对应的成像特点的分析，往往可以帮助我们在目标检测中取得更好的效果。

1.2.2 图像的稀疏反演技术

反演问题，如前文所述，是已知观测信号以及观测-参数映射（模型），从中反求参数集的过程。该问题是数学，物理以及工程学中最重要、也是最值得研究的问题之一。从上世纪 60 年代起，研究者就开始专注于对反问题的病态本质的研究。A.N. Tikhonov（1963）提出了变分正则化方法，该方法至今仍然被广泛应用^[42]。变分正则化方法可以被用来增强反问题求解中的鲁棒性，该工作成为了反演问题研究中的里程碑式的成果。随后，反演问题最早的成功应用出现在地球物理领域，G. Backus 和 F. Gilbert 的先驱性成果第一次将反演问题的数学成果应用于地球物理的研究问题之中^[43,44]。该工作讨论了在地球物理学的应用背景下反问题中解的不适定性以及多解性的评估与选择方法。A. Tarantola 的一系列工作从概率模型的角度出发，给出了解决地球物理中的反演问题中的通用方法^[45]。在此之后，反问题的求解与应用吸引了诸多学科的学者的目光。在图像分析与计算机视觉领域，很多基本的问题都可以被视为反问题，例如，图像去噪可以被视为通过带噪声的观测求解无噪图像的反演问题；图像识别与检测可以被视为通过观测图像求解图像的像素分类的反演问题；超分辨率重建可以被视为依据等距采样来求解密度更高的采样的问题；图像复原可以被视为通过观测被污染的信号，求解原信号的问题。因此，对于反问题求解方法的研究可以促进图像分析和计算机视觉领域的研究和发展。

二十世纪九十年代开始，多个领域的学者们相继发现，如果可以找到一个域，在这个域中，观测信号具有稀疏表示的形式，那么我们可以据此简化该观测信号的反演求解。自然地，研究者们想到，可否有一种方式去寻找这样一个域？在该思路的驱动下，研究者们开始尝试将观测信号转换至稀疏观测域去求解其反演问题，因此，稀疏反演问题成为了一个独立的研究领域。具体到图像反演问题，以图像去噪问题为例，M. Elad 等（2006）提出了一种去除图像中的高斯白噪声的算法，在经过学习的冗余字典中，寻找到了图像的稀疏表示^[46]；K. Dabov（2007）提出了一种图像去噪算法，该算法采用了一种三维协同滤波的思路，并将整个过程放到稀疏域中操作^[47]；M. Protter 等（2009）提出了一种利用冗余字典和稀疏表示的序列图像去噪方法，相较于传统的对每一帧图像重复进行去噪操作，该方法在效率和效果上都有了很大提升^[48]；D. Guo 等（2014）提出了一种检测和去除图像椒盐

噪声的方法^[49]；T. Lu 等（2016）提出了一种基于时空联合稀疏表示的超光谱图像去噪方法，结合的图像序列的多种信息，取得了很好的效果^[50]；A.A. Mohammed（2017）提出了一种基于稀疏表示非负约束下的矩阵分解的图像去噪方法，采用了联合正则化的思路^[51]。在图像超分辨率的研究中，J. Yang 等（2010）提出了一种基于图像块的稀疏表示方法^[52]；稀疏表示的奠基人之一，S. Mallat 等（2010）提出一种利用信号的稀疏表示构造混合估计器的方法，可以用于求解图像反问题，实验证明了其在超分辨率重建中具有很好的效果^[53]；W. Dong 等（2011）提出采用稀疏选择结合自适应正则化的方法，来进行图像去模糊以及超分辨率重建^[54]；此后，在 2016 年，该团队又提出了一种用于超光谱图像的超分辨率重建方法，思路是通过结合非负约束的稀疏表示，以实现该目的^[55]。J. Jiang 等（2017）提出了一种基于稀疏表示的方法，用于对人脸图像进行超分辨率重建，该方法的特点是在噪声环境下具有较高的鲁棒性^[56]。此外，在图像复原领域，J. Mairal 等（2008）提出一种基于稀疏表示方法，用于复原彩色图像，其中的字典是利用 K-SVD 所构造的^[57]；该团队同时提出了另外一种基于非局部稀疏模型的图像复原方法，将以往的基于字典分解和局部均值的方法进行了结合^[58]；B. Yang 等（2010）提出一种基于稀疏表示的多源图像融合和复原的方法，并与传统的金字塔分解和小波分解进行了对比^[59]；W. Dong（2011）提出了一种中心化稀疏表示（Centralized Sparse Representation, SCR）模型用于图像退化问题的求解^[60]；J. Zhang 等（2014）提出了一种基于图像组的稀疏表示方法（Group-based Sparse Representation, GSR），与传统的基于图像块的稀疏表示不同，这里采用组稀疏约束的模式，在图像复原中取得了较好的效果^[61]；W. He 等（2016）提出了一种基于全变差以及低秩约束联合正则化的超光谱图像复原方法，是全变差联合正则化算法的一个代表性成果^[62]；G. Yuan 等（2017）提出了一种基于稀疏范数以及全变差约束的图像复原方法，针对被脉冲噪声污染的图像取得了目前为止最好的效果^[63]。在目标识别与检测应用之中，S. Agarwal（2004）等提出了基于学习和稀疏表示的目标检测方法，将其应用到了静态灰度图像中^[64]。V. Cevher 等（2008）提出了一种利用压缩感知理论来去除背景的方法，将目标检测问题转化为一个稀疏逼近问题来求解^[65]；Y. Chen 等（2011）提出了一种基于稀疏表示的目标检测方法，假设图像的像素处于一个低维子空间，利用 L0 范数优化，在遥感图像中进行目标检测取得了较好的效果^[66]；J. Zhao 等（2011）提出了一种基于二维完备高斯字典稀疏表示的红外小目标检测方法^[67]；H. Zhang 等人（2012）提出了一种目标识别方法，基于联合稀疏表示的思想，实现了多视角 SAR 目标自动识别。通过与传统方法的比较，可以充分证明稀疏表示在处理该类问题中的优越性^[68]；H. Sun 等（2012）提出一种在高分辨率

遥感图像中，基于空间稀疏编码的词袋模型的自动目标检测方法^[69]；J. Zhang 等（2017）提出一种联合稀疏张量表示的目标检测方法，用于检测极化超光谱图像中的目标^[70]；M. Wan 等（2018）提出了一种运动红外目标检测与识别方法，同样采用全变差以及低秩约束的思路^[71]。可以看出，在典型的图像反演问题求解中，稀疏表示及稀疏约束在近年来得到的重视日渐提高，新的方法和思路时有出现，在很多传统计算机视觉问题中取得了很好的效果，并且也还有大量问题需要研究和完善。

综上所述，反演问题以及应运而生的稀疏反演问题、稀疏约束问题已经在图像分析和计算机视觉中产生了重要的影响，同时取得了傲人的成果。因此，对图像稀疏反演问题展开深入的研究，如探索更加简洁和有效的图像建模方法，以及探索更高效的反问题求解方法，会推动反问题求解问题在图像处理中的应用。具体到我们的研究目标和应用场景，开展对反演问题的研究势必会带来复杂背景下弱小目标检测精度和效率的提升。

1.3 主要研究工作及技术路线

本文采用稀疏动态反演的方法实现了包括海面、天空及地面等复杂背景下的红外弱小目标高精度检测，具体来说，本文的主要研究工作包括弱小目标检测反问题构建，背景/目标建模分析以及求解等。同时，我们也研究了基于稀疏表示、模态分解以及视觉显著性的红外弱小目标检测方法，主要完成了以下六个方面的工作：

1. 研究分析了复杂红外背景以及红外弱小目标的成像特征。

为了解决在复杂红外背景下进行弱小目标检测的问题，首先需要对红外图像中背景和目标的特性进行分析。由于实际的红外搜索与跟踪系统中，目标距离成像设备往往较远，图像中的目标往往呈现着复杂多样的外在表现特征，难以使用单一的数学模型去描述红外弱小目标。同时可以观察到在典型的红外目标探测场景中，背景呈现高噪声，低纹理，无固定形状及红外辐射的特征，且复杂场景往往表现为非均匀、非平滑的状态。因此，本文需要针对红外图像的特点和表征形态去提出针对性强的红外图像弱小目标检测方法。

2. 提出了基于联合正则化的红外弱小目标检测方法。

在复杂红外场景下，红外背景的特征并不是单一的，常常需要处理非均匀、非平滑背景，而在这样的场景下，红外弱小目标更容易淹没在背景中。由于红外图像对比度低、成像质量差，使得其某些区域具有低秩性，即图像区块之间有一定重复性。联合正则化可以被认为是多种特征的联合，通过引入全变差正则化项，

可以更加精细地刻画复杂背景中的灰度变化，因而改善弱小目标的检测效果。本文提出了一种基于全变差-主成分追踪的红外弱小目标检测算法，对红外背景施加低秩与全变差联合约束，提高了背景恢复的准确度，相应地提高了弱小目标检测的精度，在复杂场景下测试取得了很好的效果。

3. 提出了基于稳定多子空间学习的红外弱小目标检测方法。

同样针对复杂红外场景，在某些情况下，场景中可能含有不止一个强红外辐射源，不可避免地会对红外弱小目标检测造成很强的干扰。我们从背景入手，构建了多子空间模型，用于描述上述提到的含有多个强辐射源的红外场景。通过从红外数据本身学习、抽取得到对应的多子空间结构，再通过该结构对背景进行表示，进而分离出其中的弱小目标。通过在多个复杂场景下的测试，证明该方法取得了很好的效果。

4. 提出了基于多任务联合稀疏表示的红外弱小目标检测方法。

由于红外弱小目标面积小、特征难以识别等特点，传统的基于稀疏表示的方法往往难以实现对目标区域准确的表示。结合近年提出的基于多特征的多任务联合稀疏表示方法，我们构建了一种多任务联合稀疏表示模型，通过采用包括灰度、边缘以及梯度信息在内的不同特征，全方位地刻画了红外弱小目标的特点，并据此来构建过完备字典。在此字典上进行稀疏表示，可以实现准确度更高、虚警率更低的红外弱小目标检测，同时也是对基于稀疏表示的红外弱小目标检测的一种拓展。

5. 提出了基于非负变分模态分解的红外弱小目标检测方法。

红外弱小目标不仅在空域中具有显著性，同样地，在频域中也有可以利用的特征。红外弱小目标由于其面积小，其所占频带高于背景区域；但与噪声相比，红外弱小目标所占频带又低于噪声。因此，弱小目标往往处在红外图像的中间频带。本文提出一种基于非负约束变分模态分解的红外弱小目标检测算法，利用红外弱小目标的频带信息，实现自适应分解，并加入对目标的非负约束，从而提取红外目标。该方法具有检测速度快、鲁棒性强等特点。

6. 研究了基于视觉显著性的红外弱小目标检测方法。

红外弱小目标往往处于红外图像中视觉显著性较高的区域。本文研究了两种显著性描述策略：空域局部对比度显著性以及时空域运动及亮度显著性。针对空域对比度显著性，本文提出了一种基于部分局部对比度的红外弱小目标检测方法，利用显著性检测的原理，首先结合红外图像的区域相似性以及局部信息熵的分布，粗略地提取目标的潜在区域。随后在该潜在区域中进行多尺度局部对比度计算，对比度高的区域即为目标所在区域。对于时空域显著性，本文提出了一种基于二

值图显著性结合运动信息的红外弱小目标检测方法，将灰度图像以及运动显著性图像作为输入，通过二值图显著性计算，输出目标位置。该研究内容及成果是对目前的基于显著性度量的红外弱小目标检测的一种推进。

图 1-1 为本文的技术路线图。通过分析背景和目标的成像特性，进行稀疏动态反演算法的研究，提出四种不同的基于反问题求解、稀疏约束和稀疏表示的红外弱小目标检测方法；同时研究了基于视觉显著性的检测方法，实现了复杂背景下的红外弱小目标检测。

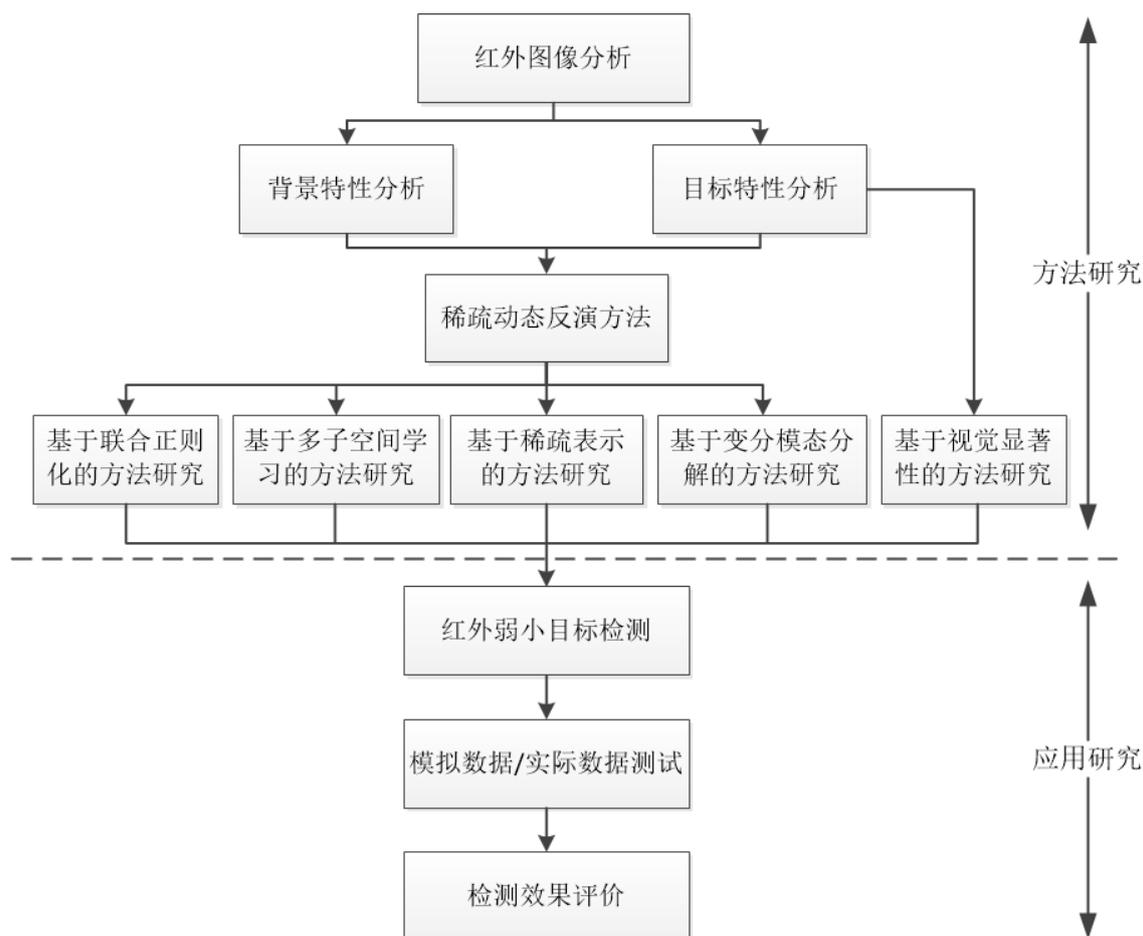


图 1-1 本文技术路线图

1.4 论文结构安排

论文包括八个章节，研究了红外图像稀疏动态反演的理论及方法，并将之应用于红外弱小目标检测。其主要内容依次为：

第一章是绪论。主要介绍了复杂背景下红外弱小目标检测研究的背景和意义，研究新的检测框架的意义，以及红外弱小目标检测以及图像反演理论的国内外研究现状及发展动态。这是为了说明本文的研究紧跟信号处理的发展热点，具有很

大的理论意义及应用价值。

第二章介绍了本文的研究工作的基础和背景。主要分析了不同场景下的红外图像的成像特点，以及红外弱小目标的特点。此外给出了动态反演中涉及的基本数学理论和优化算法的介绍。这一章的内容可以作为后续研究工作的理论基础。

第三章介绍了基于多任务联合稀疏表示的红外弱小目标检测方法。这种方法通过将主成分分析与全变差正则化相结合，在红外背景恢复及弱小目标检测方面都取得了很好的效果。

第四章介绍了基于多子空间学习的红外弱小目标检测方法。首先介绍了子空间学习理论，这是一种常用的数据分析及挖掘方法。随后提出了基于稳定多子空间学习的红外弱小目标检测方法，通过构建多子空间背景模型，可以很好地描述背景中有强辐射源的红外图像，进而实现准确的目标检测。

第五章介绍了基于稀疏表示的红外弱小目标检测方法。首先介绍了图像的稀疏表示理论，随后介绍了其在红外弱小目标检测中的应用，接下来介绍了一种新的多任务联合稀疏表示模型，通过构建多特征红外图像字典，实现了基于多任务联合稀疏表示的红外弱小目标检测。

第六章介绍了基于变分模态分解的红外弱小目标检测方法。首先介绍了模态分解与变分理论，其次提出了一种基于非负约束变分模态分解的红外弱小目标检测方法，并通过实验分析证明了该方法的有效性。

第七章介绍了基于视觉显著性的红外弱小目标检测方法。首先介绍了显著性检测的基本理论，随后分别提出了基于部分局部对比度以及二值图显著性结合运动信息的红外弱小目标检测方法，分别利用了单帧图像以及多帧图像中弱小目标的视觉显著性，得到了较好的检测效果。

第八章对本文的全部研究工作进行了总结，并对后续的研究方向做出了展望。

第二章 红外弱小目标反演及检测

红外弱小目标反演检测的目的是从观测量，即输入的红外图像出发，结合图像模型（包括背景模型、目标模型等），反向求解其中的目标分量。该过程涉及到两个主要问题：一是根据红外目标以及背景的特性，对红外成像系统所获取到的图像进行建模；二是根据相应模型和应用来选取恰当的反问题求解方法。因此，在本章之中，我们首先从红外成像系统的原理和应用场景出发，分别分析了红外图像中弱小目标的成像特征以及相关应用场景中的背景特性。之后，我们介绍了反演问题求解的基础理论与方法，其中包括了向量与矩阵的相关基本概念和测度；以及多种应用于反演问题求解的经典最优化方法。这些理论及方法适用于各类反演问题的构造和求解，所述的方法和理论在后续的章节中均有应用。

2.1 复杂背景红外成像特性

根据第一章中的描述，在红外成像及相关技术领域，整个红外辐射范围通常被分为 4 个波段，分类依据为红外辐射的波长：波长范围在 $0.78\text{-}3\mu\text{m}$ 之间的红外线称为近红外，波长范围在 $3\text{-}5\mu\text{m}$ 之间的红外线称为中红外，波长范围在 $5\text{-}15\mu\text{m}$ 之间的红外线称为远红外，极远红外则指的是波长在 $15\text{-}1000\mu\text{m}$ 之间的红外线。在上世纪六七十年代，伴随着半导体物理技术以及相关工艺的发展，相继研制成功了对应于三个大气窗口的红外探测器，即 $1\text{-}2.5$ 、 $3\text{-}5$ 和 $8\text{-}14\mu\text{m}$ 波长。其中， $3\text{-}5\mu\text{m}$ 的探测器通常用于对距离大于 20km 的目标的探测，该波段也是我们所说的红外探测与跟踪系统中的常用波段。

从应用场景来说，常见的红外弱小目标检测场景包括海面、天空以及地面等。一般来说，背景的成像照度都远高于目标，尤其是在白天的观测环境下，因此，相关场景的平均灰度较高，或至少含有灰度较高的背景物体。此外，不同红外场景的灰度分布、场景复杂度都不尽相同。在同一类红外场景中，也会出现由于成像环境不同而导致的差异。因此，我们首先分析了海面、天空以及地面场景，结合实例分析了各个场景的一般特点以及在目标检测中的难点。其次我们对上述实例进行了定量分析，通过灰度均值、方差、平滑度、图像熵以及图像一致性等指标进一步说明了本文所研究的红外场景的复杂性和目标探测的难度。

在海面船只监测、海洋动物检测以及海面救援等应用场景中，常常需要处理海面背景或海天背景。图 2-1 展示了一组典型的海面/海天红外图像。可以看出，不同环境下的海面场景的红外成像差别非常大。图 2-1 (a) 是一幅由设立在陆面上的

探测器拍摄的海面场景，可以看出，该探测器成像质量较差，过曝区域较多，这是由于高照度的海面带来的曝光度提升，位于图片下方的人造背景目标出现了较为严重的过曝；同时该图像噪声较多，这也是由于水波的变化所带来的红外辐射强度变化所导致的。但整体来说，该背景较为平滑，具有均匀性和一定的各向一致性。图 2-1 (b) 是一幅远距离海天背景红外图像，可以明显在其中看到海天线。海天线将图像分为两部分，海面部分以及天空部分，在该示意图中，每一部分的红外辐射都是均匀而平滑的。但与图 2-1(a) 相比，其平均灰度明显降低，这是由于成像距离较远，红外辐射强度较低造成的。图 2-1 (c) 是一幅近距离探测到的海面/礁石背景图像，可以清晰地看到海面与礁石的分界线。但是由于拍摄距离较近，海水的起伏带来的红外辐射强度的变化会比较准确地被探测器捕捉到，因此形成了如图中所示的剧烈变化的场景。同时，我们可以看到，天气的变化对背景表现，即背景成像带来不小的影响：与图 2-1(a) 和 (b) 相比，该图像包含着较为复杂的、在空域中变化剧烈的云层。这两种不同的干扰都将会给红外弱小目标的探测带来一定难度。图 2-1 (d) 是一幅远距离拍摄的红红外海天图像，与图 2-1 (b) 不同的是，该图的拍摄距离更远，图中包含了低空云层，会对红外目标探测产生较大的干扰。综上所述，海面背景红外图像在不同的应用场景中呈现完全不同的形态，与探测距离关系也较大，该场景可能是均匀和各向同性的，也可能呈现非常复杂的表现状态：如包含了人造物，水波，低空云层或是礁石的各种不同干扰的复杂背景。

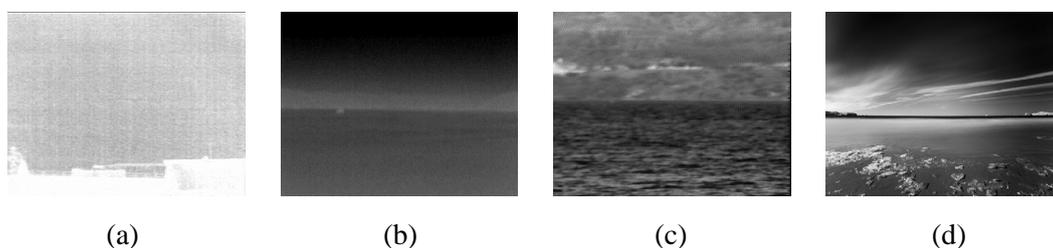


图 2-1 典型红外海面成像示意图。(a) 陆上探测器拍摄的海面红外图像；(b) 远距离海天红外图像；(c) 近距离海面/礁石红外图像；(d) 远距离海天红外图像（含云层）

对于天空场景而言，其中往往包含云层等干扰物，包括卷云、卷积云、卷层云等类型，在应用中会对红外弱小目标检测造成非常大的干扰。图 2-2 展示了一组典型的红外天空-云层场景。可以看出，该类场景具有如下特点：由于云层起着吸收及散射太阳辐射的作用，同时吸收地表辐射，因此在红外图像中属于能量较高的部分，在图 2-2 中表现为灰度值较高的像素区域。同时，由于云层在不同的高度、不同的气象状况下具有不同的形态，使得该类场景具有多样性和复杂性。图 2-2

(a) 是一幅包含积云的场景，可以看出，在图像下半部分有大片连续云层，且云层照度较低，因此全图灰度分布较为一致，可以视为平滑背景；在图像的上半部分，存在碎片状团块，且具有较强流动性，会对红外弱小目标检测造成干扰。图 2-2 (b) 是一幅典型的卷积云红外图像，云的分布呈现团块状，且红外辐射较强，局部云朵团块内可以视为平滑分布，但整体而言属于复杂多变红外背景，弱小目标容易淹没在该类背景中，与图 2-2(a) 相比，在该类图像中进行红外弱小目标检测将会相对较为困难。图 2-2 (c) 是一幅碎积云红外图像，成像距离较远。可以看出，图像中包含大块云层分布，而云层内部以及无云层的背景区域可以被视为是平滑的。但由于成像距离较远，图像下部包含了经由地面辐射的红外能量，因此图像下部的背景的红外辐射要强于图像上部。图 2-2 (d) 是一幅层积云红外图像，其分布与卷积云类似，其非均匀性相对卷积云较低，但依然属于复杂红外背景，检测难度较大。综上所述，云层背景图像由于其辐射强度不均匀、云团变化多样，同时受成像距离影响较大等特点，属于典型的复杂红外场景。并且连续云层面积越大，相对而言更容易出现平滑分布的区域，而碎片状云层极大地增加了场景的非均匀性和复杂程度，给检测带来了极大困难。

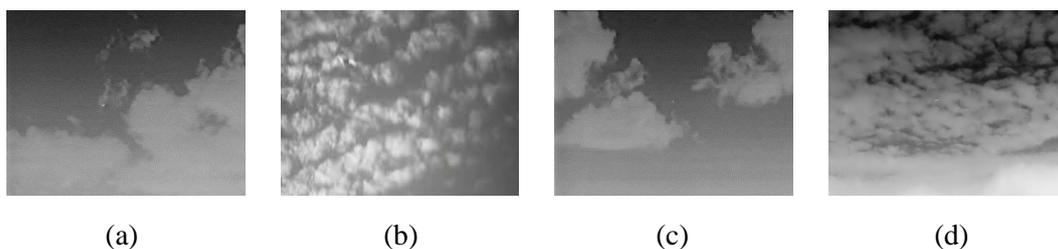


图 2-2 典型红外天空-云层成像示意图。(a) 天空-积云红外成像示意图；(b) 卷积云红外成像示意图；(c) 碎积云红外成像示意图；(d) 层积云红外成像示意图

最后我们分析地面场景的特点。在地面目标探测，森林火灾预警以及地面动植物检测等应用中，我们往往需要在地面场景中检测弱小目标。相比海面及天空等场景，地面是细节最丰富的一种红外成像场景，同时也是检测难度最大的，且地面中待检测目标的形态差异较大。图 2-3 展示了一组典型的红外地面场景示意图，成像距离由远及近。图 2-3 (a) 是一幅由高空红外探测器拍摄的地形图，可以看出其中有山川及河流等自然元素，场景的灰度值起伏较大，且部分地面的红外辐射较大，在该区域中进行红外弱小目标检测存在较大难度；图 2-3 (b) 是一幅在城市上空远距离拍摄的红外图像，可以清晰地看到其中的房屋、街道分布等，且不同建筑物之间红外辐射强度差异较大，是典型的非均匀复杂场景；图 2-3 (c) 是一幅公路场景红外图像，拍摄距离小于前两幅图，且观测角度与图 2-3 (a) 和 (b) 的正

上方观测不同，该图像采用了斜上方的观测角度，因此，图像受地面红外辐射变化影响较大，同时具有较大的噪声，另外图中机动车的红外辐射远高于背景区域；图 2-3 (d) 是一幅近距离拍摄的户外场景示意图，虽然图像整体灰度较低，但也可以看出其细节较丰富，属于非均匀背景。总体而言，地面场景变化多样，场景不确定性高，与海面、天空背景相比属于一种更复杂的红外探测场景。

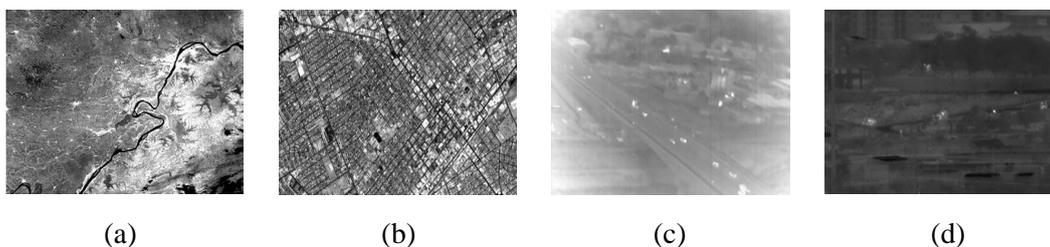


图 2-3 典型红外地面成像示意图。(a) 山川-河流红外成像示意图；(b) 城市房屋红外成像示意图；(c) 公路及车辆红外成像示意图；(d) 近距离户外红外成像示意图

上面我们分析了不同场景下的红外图像的特点。那么对于这些红外场景，依据对图像的观察和分析，综合来说，上述红外图像中呈现的背景物体和杂波具有如下几个方面的特性：

1. 纹理特性

与可见光图像不同，通过分析图 2-1到图 2-3我们可以发现，红外图像几乎无法呈现物体的具体纹理细节，且与成像距离无关。无论远距离成像或者近距离成像，物体表面的细节信息都被模糊掉了，这是由于红外线传输过程中大气的影 响，以及探测器的性能等因素决定的。因此，我们无法通过类似可见光目标检测中的纹理分析来排除背景物体的影响。同样，我们在进行背景建模的时候，无法使用纹理信息进行建模。

2. 边缘特性

可以发现，红外图像中较少出现锐利和清晰的边缘，尤其是在天空和海面图像中，物体之间的分界往往是模糊的。这也同样是由于红外传输过程中的大气影响所导致的。由于大气的吸收、散射和折射作用，使得图像中不同元素之间的温度变化较连续，反映在红外图像中，就表现为边缘模糊。这种模糊的边缘需要我们在检测的过程中进行边缘增强，从而达到更好的弱小目标检测效果，但也要警惕边缘的增强对背景复杂度的提升。

3. 形状特性

在海面场景中，由于海浪的起伏，背景物体呈现不稳定的形态；在天空场景中，同样，云层的形状是不稳定且快速变化的，难以用合适的形状描述子去描述

其分布；在地面场景中，很多元素是固定不变的，具有稳定的形状。但是在某些场景和成像条件下，元素之间的分界是模糊的，因而形状也难以界定。因此，在红外图像中物体的形状特征较难被描述。

我们引入一些统计特性评价指标，用于对本文所处理的红外场景做进一步说明。这里采用灰度均值、方差，图像熵，图像均匀度以及一致性作为评价指标，分别定义如下：

灰度均值，顾名思义，就是图像中各个像素灰度值的平均。假设待分析的红外图像为 $f(x,y) \in \mathbb{R}^{m \times n}$ ，这里 x 和 y 为图像的行/列索引，则灰度均值定义为：

$$\mu = \frac{1}{m \times n} \sum_{i=1}^m \sum_{j=1}^n f(i,j) \quad (2-1)$$

一般来说，灰度均值 μ 越大，代表背景的整体灰度值越高，存在强辐射干扰源的可能性就越大，对红外目标检测容易造成一定干扰。

有了灰度均值，我们可以进一步定义图像的灰度方差，即：

$$\sigma^2 = \frac{1}{m \times n} \sum_{i=1}^m \sum_{j=1}^n [f(i,j) - \mu]^2 \quad (2-2)$$

图像方差表示了图像中灰度分布的分散程度，在我们的问题中，如果背景方差越大，意味着背景中所包含的不同灰度级越多，可能对目标检测造成更大的干扰。

图像平滑度定义为^[72]：

$$R = 1 - \frac{1}{1 + \sigma^2} \quad (2-3)$$

这里 σ^2 即为上文定义的方差。可以看出，图像平滑度 $R \in [0, 1]$ ，并且 R 越大，代表图像越不平滑， R 越小，代表该图像较为平滑，更有利于目标检测。

图像熵是一个整体的概念，反映了图像内部灰度分布的均匀程度。熵值越大，代表了像素值分布相对杂乱，意味着图像中包含更多的信息量，对应到红外图像中，意味着背景信息越丰富，对目标检测可能造成负面影响；熵值越小，则出现平滑背景的可能性就越大，对目标检测是有利的。图像熵定义为^[73]：

$$E = - \sum_{i=0}^{L-1} p(x_i) \log_2 p(x_i) \quad (2-4)$$

这里 L 为图像的灰度级别数， x_i 为每个级别中的灰度值， $p(x_i)$ 为对应的灰度级在图像中出现的概率。

同样地，采用灰度分级的思想，我们可以定义图像一致性，即^[74]：

$$U = \sum_{i=0}^{L-1} p(x_i)^2 \quad (2-5)$$

这里 L 同样是待评价图像的灰度级别的数量， x_i 表示第 i 个灰度级别对应的值， $p(x_i)$ 为对应的灰度级出现的概率。对于理想的均匀图像，其一致性为 1；而对于其他图像，其一致性越低，代表图像越不均匀。

采用上述介绍的图像统计特性评价指标，我们对上文中展示的海面、天空以及地面场景的红外图像进行进一步分析。对于图 2-1 中的海面背景红外图像，分别计算其灰度均值、方差、平滑度、图像熵以及一致性，结果如表 2-1 所示，表中的图片序号与图 2-1 相对应。

表 2-1 图 2-1 中的海面场景的统计特性评价结果

图片序号	μ	σ^2	$R (\times 10^{-2})$	E	U
(a)	34.90	690.51	99.86	2.03	0.30
(b)	53.04	988.70	99.90	2.51	0.20
(c)	86.99	1052.95	99.91	6.95	0.01
(d)	79.81	3404.94	99.97	7.55	0.01

可以看出，从图 2-1 中的图像 (a) 到 (d)，其灰度均值整体呈现上升趋势，尽管图 2-1(c) 的灰度均值超过了图 (d)；从方差上来说，从图 2-1(a) 到 (d)，图像灰度方差逐渐增大，特别是图 2-1(d) 的方差远远大于其他图片，这也与上文中我们对场景复杂度的分析相吻合。对于图像平滑度而言，这四幅图片的平滑度 R 都较大，说明它们都不属于均匀平滑场景，对于目标检测而言，难度较大，属于红外复杂场景。从图像熵和一致性的分析中我们也可以得到相同的结论，图 2-1 中所展示的场景复杂度逐渐增加，均属于复杂红外成像背景。

对于图 2-2 中所展示的天空及云层场景，我们统一对其进行统计特性分析，结果如表 2-2 所示，表中的图片序号对应于图 2-2 中的序号。

表 2-2 图 2-2 中的天空场景的统计特性评价结果

图片序号	μ	σ^2	$R (\times 10^{-2})$	E	U
(a)	80.21	1483.00	99.93	3.02	0.14
(b)	136.58	1286.52	99.92	7.11	0.01
(c)	79.13	1158.61	99.91	2.78	0.17
(d)	109.24	3154.78	99.97	3.61	0.09

从表 2-2中我们可以看出, 图 2-2(b) 以及 (d) 所对应的卷积云和层积云场景复杂度最高, 在图像熵以及一致性方面表现地尤为明显, 且层积云场景的方差非常大; 图 2-2(c) 中的碎积云由于其云层面积较大, 分布相对平滑, 因此是这四幅场景中复杂度最低的, 一致性达到 0.17, 图像熵也较低; 简单积云场景的复杂度介于卷积云/层积云和碎积云之间。但对比表 2-1我们可以发现, 整体而言, 天空-云层场景的复杂度是高于海面场景的, 在图像平滑度以及一致性上该差异表现地较为明显。

同样地, 我们对图 2-3中所展示的四幅图像做同样的统计特性分析, 结果如表 2-3所示。

表 2-3 图 2-3中的地面场景的统计特性评价结果

图片序号	μ	σ^2	$R(\times 10^{-2})$	E	U
(a)	45.62	6944.45	99.99	4.70	0.07
(b)	115.31	1905.64	99.95	7.43	0.01
(c)	77.60	1057.10	99.91	2.73	0.18
(d)	24.71	407.14	99.95	1.67	0.37

可以看出, 图 2-3(a) 中所展示的红外卫星成像场景复杂度很高, 尽管整体亮度较低, 但其方差极大, 且平滑程度很低, 考虑成像距离及分辨率的因素, 在这样的场景中检测红外弱小目标难度很高。图 2-3(b) 也是一个十分复杂的场景, 其图像熵非常大, 代表其中包含了大量的信息, 这也与我们的直观感受相吻合。图 2-3(d) 是一种相对较简单的场景, 这是由于成像距离及探测器分辨率所决定的, 其中包含的信息量较少。但与海面、云层等场景相比, 依然属于复杂背景, 给弱小目标的检测带来了一定的难度。总体而言, 地面场景复杂度较高, 且较为多变, 是一类难以处理的红外成像场景。

综合上述实例以及分析, 在常见的红外场景中, 背景往往复杂多变, 且可见光图像中的常用特征在这里往往不再有效, 因此, 需要研究针对性的红外图像背景描述及背景分离方法。

2.2 红外弱小目标成像特性

由于成像距离长、红外探测器精度有限等原因, 在红外精确制导、反导、天基碎片探测等领域, 所处理的目标大多是红外弱小目标。由第一章可以知道, 红外弱小目标的主要特点为目标面积小, 往往不大于 9×9 个像素, 且信噪比低, 容易被复杂背景所淹没^[12]。

图 2-4 展示了一组红外弱小目标图像，其中目标位置均采用黄色方框标注。在图 2-4 (a) 中，目标面积为 2×3 ，呈现点状。且由于其只含有 6 个像素，目标内的像素值可以被视为是一致的，但在目标与背景的交界处，红外辐射的强度发生了一定变化，该目标可以被认为是在一个很小的范围内平滑分布的，且局部对比度较高。在图 2-4 (b) 中，目标面积稍大，其分布也不再是点状，呈现中间亮度稍高，边缘处亮度逐渐下降的特点，其局部对比度较高。但由于其高亮度区域的分布是不规则的，难以采用相应的扩散函数去描述。图 2-4 (c) 展示了一幅典型的弱目标图像，整幅图像受到噪声干扰较严重，目标可见度非常低，局部对比度很低，且灰度分布不均匀，不具有形状信息，同时受到严重的噪声干扰，难以用准确的数学模型描述。在图 2-4 (d) 中，背景中存在干扰性杂波，但目标本身呈点状且较为明亮，直观观察认为其可以采用点扩散函数进行描述。随着目标的运动，可能会被背景中的干扰物所影响，探测器接收到的辐射特性也很容易受到影响，目标的遮蔽度会发生变化。

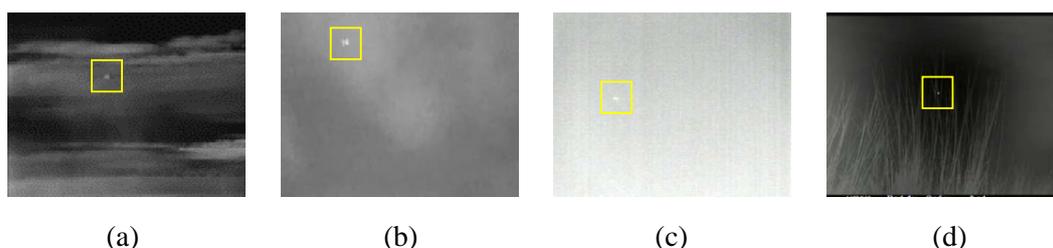


图 2-4 红外弱小目标示意图。(a) 层云背景下的红外弱小目标示意图；(b) 积云背景下的红外弱小目标示意图；(c) 低信噪比天空场景下的红外弱小目标示意图；(d) 低空背景下的红外弱小目标示意图

综合上述分析可以看出，红外弱小目标由于其面积小、总辐射能量相对背景较低等特点，在图像中的灰度分布是多变的，难以采用固定的数学模型去描述（如高斯函数、点扩散函数等）。对于某些目标，或许可以构建合适的数学模型，但由于实际场景的多样性，背景杂波种类丰富，会对目标造成不同的干扰，预先设定的数学模型往往会在红外弱小目标检测中失效。因此，需要研究并提出更稳定的红外弱小目标描述方法，用以实现准确的目标检测及定位，并进一步实现目标识别及实际应用。

2.3 动态反演方法

动态反演的本质是采用最优化理论及方法，从观测量中反向求解模型参数的过程，其中涉及到向量和矩阵理论、优化算法等多方面内容。本节作为背景知识，

介绍了相应的基本数学知识和理论基础，方便后续章节的研究描述。其中涵盖了向量测度以及矩阵的相关概念，以及常用的最优化方法等。

2.3.1 预备知识

首先我们给出本文中常用的几种范数的定义，首先是向量范数。

1. L_0 范数

假设向量 $x \in \mathbb{R}^n$ ，其 L_0 范数定义为 x 中非零元素的个数。

2. L_1 范数

假设向量 $x \in \mathbb{R}^n$ ，其 L_1 范数定义为：

$$\|x\|_1 := \sum_{i=1}^n |x_i| \quad (2-6)$$

可以看出，对向量中所有元素的绝对值求和，即为向量的 L_1 范数。

3. L_2 范数

假设向量 $x \in \mathbb{R}^n$ ，其 L_2 范数定义为：

$$\|x\|_2 := \sqrt{\sum_{i=1}^n x_i^2} \quad (2-7)$$

L_2 范数描述的是一个向量的欧几里得长度，即对向量中各个元素求平方和再开方。

4. L_p 范数

假设向量 $x \in \mathbb{R}^n$ ，我们定义其 p 范数为：

$$\|x\|_p = \left(\sum_{i=1}^n |x_i|^p \right)^{1/p}, \quad 1 \leq p \leq \infty \quad (2-8)$$

可以看出， L_1 范数和 L_2 范数即为 L_p 范数在 $p = 1$ 和 $p = 2$ 时的情况。 L_0 范数即为 L_p 范数在 $\lim_{p \rightarrow 0}$ 时候的特殊情况。有了上述 L_p 范数的定义，我们可以更灵活地定义向量范数。

接下来我们给出本文中常用的几种矩阵范数的定义。

1. L_0 范数

假设矩阵 $M \in \mathbb{R}^{m \times n}$ ，其 L_0 范数定义为 M 中非零元素的个数。

2. L_1 范数

假设矩阵 $M \in \mathbb{R}^{m \times n}$ ，其 L_1 范数定义为：

$$\|M\|_1 := \sum_{i=1}^m \sum_{j=1}^n |M_{ij}| \quad (2-9)$$

这里 i, j 表示矩阵的行列坐标。 L_1 范数即为矩阵中各个元素的绝对值之和。

3. Frobenius 范数

假设矩阵 $M \in \mathbb{R}^{m \times n}$ ，其 Frobenius 范数定义为：

$$\|M\|_F := \sqrt{\sum_{i=1}^m \sum_{j=1}^n M_{ij}^2} \quad (2-10)$$

即对矩阵中各个元素求取平方和再开方，可以视为向量的 L_2 范数在矩阵上的扩展。

4. 核范数

假设矩阵 $M \in \mathbb{R}^{m \times n}$ ，其奇异值分解（Singular Value Decomposition, SVD）定义为 $M = U\Sigma V^*$ ，这里 $\Sigma = \text{diag}(\{\sigma_i\}_{1 \leq i \leq r})$ 表示 M 的奇异值。 M 的核范数（Nuclear Norm）定义为其奇异值之和，即：

$$\|M\|_* := \sum_i \sigma_i(M) \quad (2-11)$$

可以看出，核范数与矩阵的奇异值以及矩阵的秩有关。

5. 行/列 L_0 范数

假设矩阵 $M \in \mathbb{R}^{m \times n}$ ，其行 L_0 范数表示其非零行的个数，记为 $\|M\|_{\text{row-}0}$ 。类似地，列 L_0 范数记为 $\|M\|_{\text{column-}0}$ ，表示其中非零列的个数。

6. $l_{1,2}$ 及 $l_{2,1}$ 范数

$l_{1,2}$ 范数是一种矩阵混合范数，其含义为矩阵中的每一个列向量的向量 L_2 范数之和。假设矩阵 $M \in \mathbb{R}^{m \times n} = \{M_1, M_2, \dots, M_n\}$ ，其中 $M_j, j = 1, \dots, n$ 为 M 中的各个列，则其 $l_{1,2}$ 范数定义为：

$$\|M\|_{1,2} = \sum_{j=1}^n \|M_j\|_2 \quad (2-12)$$

在某些应用中， $l_{1,2}$ 范数又被称为列 L_1 范数，记为 $\|M\|_{\text{column-}1}$ 。

同样地，我们也可以定义 $l_{2,1}$ 范数，这同样也是一种针对矩阵的混合范数，其含义为矩阵中每一个行向量的向量 L_2 范数之和，其定义如下：

$$\|M\|_{2,1} = \sum_{i=1}^m \|M_i\|_2 \quad (2-13)$$

这里 $M_i, i = 1, \dots, m$ 表示矩阵 M 中的每一行。 $l_{2,1}$ 又被称为行 L_1 范数，记为 $\|M\|_{\text{row-}1}$ 。 $l_{1,2}$ 以及 $l_{2,1}$ 混合范数在稀疏表示中有着重要的用途。

上述这些范数的定义给出了向量和矩阵的不同“长度”的定义。下面我们给出本文中常用的两个关于矩阵性质的描述，涉及到线性代数以及矩阵理论相关的基础知识，同时将其与上文中描述的红外图像联系起来。这些概念对于后文的算

法及应用研究非常重要。

1. 矩阵的秩

在线性代数中，矩阵的秩定义为矩阵的列向量张成的空间的维度，或者说，是其中相互线性独立的列的最大个数。而低秩矩阵，顾名思义，表示该矩阵中大部分的列可以由其中极少数的列线性表出，或者近似线性表出。其数学表示可以写为：

$$\text{rank}(M) \ll \max(m, n) \quad (2-14)$$

其中 $M \in \mathbb{R}^{m \times n}$ ， rank 表示计算矩阵的秩的算子。具体到红外图像，我们将其视为一个二维矩阵，由第2.1节我们可以知道，对于天空背景来说，无云层的部分往往重复性较高，在不考虑噪声及其他干扰的情况下，部分红外背景区块可以被视为是低秩矩阵；而对于有云层的部分，根据云层的种类不同，其秩的性质有很大区别。海面背景与天空背景类似，当海面波纹变化较少、拍摄距离较远且不具有其它干扰时，容易形成低秩场景或局部低秩场景，而在其它情况下，背景矩阵不能简单地被一组低维的基底线性表出。对于地面背景，其往往不容易形成低秩性。

2. 稀疏矩阵

矩阵的稀疏性用以表示矩阵中非零元素的个数。由上文中对常用矩阵范数的定义可以知道，该性质可以用矩阵的 L_0 范数来描述。如果一个矩阵是稀疏的，则意味着其 L_0 范数的值较小，即：

$$\frac{\|M\|_0}{m \times n} < \delta \quad (2-15)$$

其中 $M \in \mathbb{R}^{m \times n}$ ，这里 δ 是一个很小的值，表征着该矩阵的稀疏程度。具体到红外图像，由于弱小目标的面积在整幅图像中所占比例很小，可以将其视为一个稀疏矩阵，仅仅在目标区域有非零值，其余区域数值为零，而红外弱小目标检测的目的就是求解该稀疏矩阵中非零值的位置，以实现弱小目标定位。

2.3.2 反演方法

在反演中，涉及到目标函数构建以及反演求解等内容，本节我们介绍几种常用的优化求解方法。由于反演以及优化求解是一个很广泛的研究课题，涉及到众多的思路和方法，并且还不断地有新的发展，我们在这里仅仅介绍一些基本思路及后文中常用的优化算法。

2.3.2.1 增广拉格朗日方法

增广拉格朗日方法（Augmented Lagrangian Method, ALM）是一类用于解决等式约束的优化问题的方法。ALM 最初被称为乘子法（the Method of Multipliers），

由 M. Hestenes 以及 M. Powell 分别进行了研究讨论^[75,76]。其基本思路与经典的拉格朗日乘子法 (Lagrangian Multiplier Method) 类似, 即通过某种方式, 将有约束的问题转化为一系列无约束问题, 同时, 在目标函数中引入惩罚项。但是与惩罚方法 (Penalty Methods) 不同, 除了惩罚项, ALM 还会在目标函数中加入拉格朗日乘子项 (Lagrangian Multiplier), 这也使得 ALM 方法与传统的拉格朗日乘子法有些许区别。ALM 被广泛地应用于全变差求解、压缩感知问题求解等。此外, ALM 还有一些变化形式, 例如著名的交叠方向乘子法 (Alternative Directional Multiplier Method, ADMM) 等^[77]。

下面我们介绍 ALM 的典型应用场景。假设我们的目标是求解这样一个有约束问题:

$$\min f(x), \quad \text{s.t. } c_i(x) = 0, \forall i \quad (2-16)$$

该问题可以通过求解一系列无约束问题而实现。ALM 将其转化为如下所示的无约束问题:

$$\min \Phi_k(x) = f(x) + \frac{\mu_k}{2} \sum_i c_i(x)^2 - \sum_i \lambda_i c_i(x) \quad (2-17)$$

这里 μ_k 可以理解为罚因子, λ_i 是拉格朗日因子。可以看到, ALM 方法相比传统的朴素拉格朗日乘子法, 在约束条件中加入了一个惩罚项 $\frac{\mu_k}{2} \sum_i c_i(x)^2$ 。该惩罚项的引入, 相较朴素拉格朗日乘子法, 可以使得转化后的问题更易求解, 同时解的鲁棒性更高。在每次迭代过程中, μ_k 逐步增大, 同时依据下式更新 λ_i :

$$\lambda_i \leftarrow \lambda_i - \mu_k c_i(x_k) \quad (2-18)$$

这里 x_k 表示第 k 次迭代中所求得解, 即:

$$x_k = \arg \min \Phi_k(x) \quad (2-19)$$

在每次迭代中, λ 可以理解为是对拉格朗日乘子的近似, 随着迭代次数的增加, 近似的精度也逐渐增加。ALM 方法的主要优势在于, 在求解过程中不需要满足 $\mu \rightarrow \infty$, 这一点与惩罚法不同。由于采用了拉格朗日乘子, μ 可以采用一个较小的值, 避免因 μ 值过大而造成无法求解的情况。

2.3.2.2 交叠方向乘子法

ADMM 是 ALM 方法的一种变化形式, 对于含有多个待优化部分的对偶问题, 在每次迭代中采用部分更新的方式进行求解; 可以将其理解为 ALM 方法针对含有

多个项的目标函数的推广。假设待求问题可以被写为如下形式：

$$\min_x f(x) + g(x) \quad (2-20)$$

则该问题等价于：

$$\min_{x,y} f(x) + g(y), \quad \text{s.t. } x = y \quad (2-21)$$

经过转化后，该问题变成了有约束优化问题，且具有两个变量 x 和 y 。该问题现在可以采用有约束优化算法求解，例如 ALM。

ADMM 的主要思路是将上述问题进行分步部分求解，首先求解关于 x 的优化问题，此时将 y 视为一个固定值；接下来固定 x ，求解关于 y 的优化问题。每一次计算中都对 x 和 y 的数值分别进行求解及更新，接着重复该过程。尽管这样的优化求解并不是在每一次迭代中都同时找到了针对多个变量的最优解，但是实验证明，该过程可以最终收敛到 x 和 y 的最优解。也正是由于其求解过程中包含固定某些变量，只优化另一个变量的过程，使得 ADMM 与经典的 ALM 方法在求解过程上不尽相同。

ADMM 过程可以视为是道格拉斯-拉什福德分裂方法的一种应用^[77]，目前也有一些成熟的工具箱中包含了该算法，可以很方便地求解如公式(2-20)所示的优化问题^[78,79]。

2.3.2.3 加速近端梯度法

传统的梯度下降法（Gradient Descent）一般用于求解无约束优化问题，但其要求目标函数在迭代中可微。在被优化函数不可微的情况下，我们便无法使用简单的梯度下降法对目标函数进行优化求解。近端梯度法（Proximal Gradient）提供了解决不可微函数的最优化问题的一种方法。当目标函数具有以下形式时：

$$\min_x f(x) + g(x) \quad (2-22)$$

其中 $f(x)$ 是可微的，且具有 Lipschitz 连续梯度；同时 $g(x)$ 不可微，则该问题可以使用加速近端法求解。在该方法中，可微部分 $f(x)$ 可以使用二阶近似来逼近：

$$f(x) = f(x') + \nabla f(x')(x - x') + \frac{L_f}{2} \|x - x'\|_2^2 \quad (2-23)$$

其中 L_f 为 ∇f 的 Lipschitz 常数，是固定不变的。在该逼近下，原问题可以被转化为如下的优化问题。

$$\min_x f(x') + \nabla f(x')(x - x') + \frac{L_f}{2} \|x - x'\|_2^2 + \lambda g(x), \quad (2-24)$$

其中前三项为函数 $f(x)$ 的二次逼近。对该问题的求解，可以定义一近端算子：

$$p(x) = \arg \min_{x'} \frac{L_f}{2} \|x - x'\|_2^2 + \lambda g(x'). \quad (2-25)$$

这便是原问题的一个逼近。在此基础上，原问题的解可以使用如下迭代来给出：

$$x^k = p_k(x^{k-1} - t \nabla f(x^{k-1})) \quad (2-26)$$

其中 t 为迭代步长。更进一步地，我们可以将上式进行如下变换：

$$x^k = x^{k-1} - t_k \cdot G_k(x^{k-1}) \quad (2-27)$$

其中

$$G_k(x) = \frac{x^{k-1} - p(x^{k-1} - t \nabla f(x^{k-1}))}{t} \quad (2-28)$$

这里 t 为迭代步长。由上式我们可以看到，函数 $G_k(x)$ 为原不可微函数的梯度的一个近似。重复这个迭代过程，则原问题会逐步收敛至最优解附近。

近端梯度算法使用了近端算子来近似原问题，该近端算子具有解析解。同时，该函数与可微部分 $f(x)$ 无关，仅与不可微部分有关，这可以大大简化问题的计算；同时该问题可以处理复杂的可微部分 $f(x)$ ，因为我们仅仅需要计算其梯度。正是因为这些优秀的性质，近端梯度算法广泛应用于不同的优化求解问题上：例如处理不可微的含有 L_1 范数正则化项的优化问题。

但近端梯度法具有收敛速度较慢的问题，为了解决该问题，研究者们提出了加速近端梯度算法（Accelerated Proximal Gradient, APG）。该算法源自于传统的近端梯度算法，其区别为仅仅在迭代过程中加入了额外的一项，用于加速计算过程，该算法的迭代过程如下：

$$v_{k-1} = x^{k-1} + \frac{k-2}{k+1} (x^{k-1} - x^{k-2}) \quad (2-29)$$

$$x^k = p_k(v_{k-1} - t \nabla f(v_{k-1})) \quad (2-30)$$

可以看到，该方法相较传统的近端梯度算法，在迭代中加入了加速项 $\frac{k-2}{k+1}(x^{k-1} - x^{k-2})$ ，这一项一般被称为“动量项”。该动量项的加入旨在解决梯度下降相关算法中的各次迭代方向差异较大的问题。该动量项包含了前一次迭代的迭代方向，将前一次的迭代方向引入新的迭代之中，可以补偿梯度下降相关算法中由于各次迭代相互独立而导致的搜索方向差异极大的问题。同时，其还具有传统近端梯度算法的一切优点。因此，在反演问题的求解中，常常使用 APG 算法。

2.4 本章小结

本章回顾了该论文所进行的研究工作的基础，从反演问题出发，结合具体实例，详细分析了包括海面、天空及地面场景在内的红外成像场景的特点，并讨论了其图像特性，包括纹理、边缘以及形状等。随后分析了红外弱小目标的特点，为后续章节的算法研究打下了基础。此外，本章介绍了动态反演算法中的基础数学知识，包括向量及矩阵范数，以及常用的几种优化求解算法等，涉及到有约束及无约束优化问题的求解算法，同样是后续工作的基础。

第三章 联合正则化红外弱小目标检测

3.1 联合正则化理论

在数学、统计学以及计算机科学中，特别是针对机器学习以及反问题，正则化（Regularization）是用来求解病态问题（Ill-posed Problem）的，即，通过在求解过程中引入额外信息，用以避免难解和多解性的手段。此外，正则化还被用于避免过拟合（Overfitting）现象的发生。一般来说，正则化是针对病态优化问题中的目标函数的^[80]。一个简单的例子是，在分类器的训练过程中，我们常常在损失函数（Loss Function）中加入额外的约束，并引入权重因子用于二者之间的平衡。通常来说，在机器学习或最优化中，正则化可以用于训练更简单的模型，获得更稀疏的模型，或者引入组结构信息（Group Structure）等。一般来讲，经典的正则化项包括了 L_1 正则化与 L_2 正则化两种。考虑一个机器学习和最优化理论中常见的最小二乘问题：

$$\min_x \|f(x)\|^2 \quad (3-1)$$

其 L_1 正则化可以被表示为：

$$\min_x \|f(x)\|^2 + \alpha \|x\|_1 \quad (3-2)$$

其 L_2 正则化可以被表示为：

$$\min_x \|f(x)\|^2 + \alpha \|x\|_2 \quad (3-3)$$

其中 α 为权重因子。 L_1 和 L_2 正则化对于优化问题的影响可以直观地解释为： L_2 正则化项将解本身的“长度”加入最优化，可以避免解中有较大的参数出现，因此可以降低数据质量低所带来的过拟合问题。 L_1 正则化将会增强优化问题解的稀疏性。这是由于 L_1 正则化项在解空间中呈现临界非凸的形态，因此，加入正则化项后的解大概率落在坐标轴上，因此可以增强解的稀疏性。更进一步地，我们甚至可以使用 L_p 范数正则化项所具有的非凸性质来进一步增强解的稀疏性。

联合正则化（Joint Regularization），顾名思义，即在优化问题中采用多个正则化项，使其同时发挥作用。不同的正则项可以定义在不同的特征空间中，描述不同维度的信息。如果说单一正则化项只通过某一个方面的约束信息来折射出待恢复数据的特点，那么联合正则化则可以被认为是一种立体的手段，从各个角度更加完整地刻画了我们的目标。因此，其优点是显而易见的：通过联合正则化可以

从病态问题中求解获得更接近真实情况的数据结构。因此，联合正则化被广泛地应用于信号处理的多个领域，例如数字图像处理^[81]，地震信号处理^[82]，雷达信号处理^[83]以及语音信号处理^[84]等。采用联合正则化方法已经成为了近年来构造反问题的一种趋势。

联合正则化问题固然有其突出的优点，但是在实际问题中，需要谨慎地考虑和研究，确定如何选择正则项因子。由于多个正则项相互影响，会使得被正则项因子影响的优化行为变得难以预测。同时，额外增加的正则化项将会大大增加求解的难度。这些都是联合正则化应用中潜在的问题和难点。在本文的研究中，我们将红外弱小目标检测视为一个稀疏动态反演过程，采用反问题求解的方式从原始图像中提取红外弱小目标。如果能找到合适的联合正则化项以及求解方法，则会大大提高目标检测的准确性和鲁棒性，这也是弱小目标检测的一种新的思路。

3.2 基于全变差-主成分追踪的红外弱小目标检测

3.2.1 全变差理论

全变差 (Total Variation, TV) 是由 Camille Jordan 于 1881 年提出的，最初是为了证明某一类非连续周期函数的傅里叶级数的收敛性^[85]。随后很久，该概念才由单一变量推广到多变量。L. Rudin, S. Osher 以及 E. Fatemi 等于 1992 年提出了全变差的重要应用——基于全变差的图像去噪算法^[86]，该研究证明，在数字图像处理中，相比起常用的最小二乘恢复算法，基于 TV 的恢复算法可以获得更好的视觉及数值结果。此后，全变差也广泛地应用于图像去模糊，图像复原等方面^[87,88]。在此过程中，全变差被证明是一种有效的图像正则化算子，可以用于保持重要的边缘以及部分角点等结构，因此在图像的非连续区域的恢复中起着重要作用^[89]。换言之，TV 可以被视为图像平滑度的一种重要表征。此外，TV 也被用于图像分解之中，可以将一幅图像分解为包含很多随机模式的部分以及由重要的边缘和分段平滑区域组成的部分^[90]。通过最小化一幅图像的全变差，可以得到其中平滑的部分，并保留显著的边缘^[91]。除图像处理之外，TV 还可以被用于其他类型的信号去噪中，如地震信号处理等^[92]。

目前比较常用的二维离散全变差的定义包括基于 L_2 范数的各向同性全变差 (Isotropic TV) 以及基于 L_1 范数的各向异性全变差 (Aisotropic TV)^[93]。假设

$X \in \mathbb{R}^{m \times n}$ 表示一幅二维图像，各向同性全变差定义如下：

$$\begin{aligned} TV_l(X) &= \sum_{i=1}^{m-1} \sum_{j=1}^{n-1} \sqrt{(x_{i,j} - x_{i+1,j})^2 + (x_{i,j} - x_{i,j+1})^2} \\ &\quad + \sum_{i=1}^{m-1} |x_{i,n} - x_{i+1,n}| + \sum_{j=1}^{n-1} |x_{m,j} - x_{m,j+1}| \end{aligned} \quad (3-4)$$

可以看出，各向同性全变差定义为两个方向的图像差分的 L_2 范数（不考虑边缘情况）。各向异性全变差的定义如下：

$$\begin{aligned} TV_{l_1}(X) &= \sum_{i=1}^{m-1} \sum_{j=1}^{n-1} \left\{ |x_{i,j} - x_{i+1,j}| + |x_{i,j} - x_{i,j+1}| \right\} \\ &\quad + \sum_{i=1}^{m-1} |x_{i,n} - x_{i+1,n}| + \sum_{j=1}^{n-1} |x_{m,j} - x_{m,j+1}| \end{aligned} \quad (3-5)$$

其可以视为两个方向图像差分的 L_1 范数。在本章的下述讨论中，我们采用各项同性 TV，为了书写简化，将其表示为 $TV(X)$ 。进一步地，如果将一幅图像向量化， X 表示向量化后的图像，我们采用 $D_i X \in \mathbb{R}^2$ 表示 X 在 i 处的离散梯度，这里 D_i 是对应的梯度算子，则某一矩阵的各项同性全变差可以表示为

$$TV(X) = \sum_i \|D_i X\|_2 \quad (3-6)$$

3.2.2 主成分追踪理论

主成分追踪（Principal Component Pursuit, PCP）算法，又称为鲁棒主成分分析（Robust Principal Component Analysis, RPCA）算法，是由 E. J. Candès 等人（2011）提出的一种低秩-稀疏矩阵分解方法^[94]。现代信号处理越来越倾向于密集数据驱动的处理方式，在视频、多媒体以及生物医学图像等领域，其数据往往具有以下两个特点：1）数据量大，待处理数据往往出现数千甚至更高的维度；2）数据的内在本征维度往往较低，即数据中包含大量重复性的、可以互为表征的信息，可以对其进行降维而不会显著地损失信息量。例如，有研究表明自然数据可以被认为是处于一些低维子空间之中^[95]；或者其在某一组基底上是稀疏的^[96]。如果可以从杂乱的高维数据中恢复其本征信息，将大大提高数据分析的效率和精度。主成分分析（Principal Component Analysis, PCA）即是在这种背景下提出的，其可以从幅值较小、且近似高斯分布的噪声中恢复出信号的“主成分”。然而，当输入数据被极其尖锐、随机分布的噪声所干扰时，PCA 的结果会显著下降。简单来说，如果待处理数据中有一个点的幅值远高于其他点，那么 PCA 的结果也将会远远偏离其真实值，这是由于奇异值对噪声的敏感性所决定的。换言之，PCA 对于稀疏噪声鲁

棒性很低。因此，研究者提出了 PCP 算法，以解决这个问题。

PCP 问题可以描述为，假设有一个矩阵 $M \in \mathbb{R}^{m \times n}$ ，并且已知其可以被分解为如下形式：

$$M = L + S \quad (3-7)$$

其中 L 是一个低秩矩阵，换言之，其可以被视为很多重复的行/列元素的组合； S 是一个稀疏矩阵，且 L 和 S 具有任意幅值。这里假设我们不知道低秩矩阵 L 所对应的低维空间信息，同样地，我们也不知道 S 中非零元素位置以及个数的信息。在这个前提下，PCP 旨在从 M 中快速而准确地恢复出 L 和 S 。

可以证明，在一个相对较弱的约束条件下，PCP 问题可以通过求解下述表达式来解决：

$$\min \|L\|_* + \lambda \|S\|_1, \quad \text{s.t. } L + S = M \quad (3-8)$$

通过最小化对应的核范数和 L_1 范数，该过程可以很好地恢复低秩矩阵 L 以及稀疏矩阵 S 。理论分析指出，哪怕在极端情况下，例如 L 的秩随着矩阵的维度而线性增加，公式(3-8)都成功恢复出低秩及稀疏矩阵。又或者当 S 的数值与 M 相关时，即数据受到了与其本身大小成比例的噪声污染，PCP 依然可以成功恢复出信号的主要成分，并且其计算效率不低于传统 PCA^[94]。因此，由于其出色的数据提取、分析能力以及较高的计算效率，PCP 被广泛地应用于张量恢复、子空间分析、运动目标提取等方面^[97-99]。

3.2.3 全变差-主成分追踪红外弱小目标检测算法

3.2.3.1 红外图像分析

通常来说，包含红外弱小目标的图像由三个部分组成：背景区域、目标和噪声。假设图像 $f_I \in \mathbb{R}^{m \times n}$ ，这三个部分可以由一个加性模型来表示：

$$f_I(x, y) = f_T(x, y) + f_B(x, y) + f_N(x, y) \quad (3-9)$$

这里 $f_I(x, y)$ 表示图像 I 在像素点 (x, y) 处的灰度值， $f_T(x, y)$ 以及 $f_B(x, y)$ 分别表示目标区域与背景区域在该点处的像素值， $f_N(x, y)$ 表示噪声分布。弱小目标检测的目的就是将这三个部分准确地区分开来，因此，需要找到合适的特征来描述每一个区域的特点。

研究表明，红外背景图像中，如果其具有一定的均匀性，哪怕是物理距离相距较远的区块，也可以被视为具有一定相似性，例如远距离天空背景、深空背景、

远距离海面背景等，这是由特殊应用场景下红外背景的性质所决定的。因此这些区块可以构成一个低秩矩阵。与此同时，红外弱小目标由于其面积小的特点，可以被视为一个稀疏矩阵。特别地，当场景中存在复杂多变的云层、海浪以及其他干扰时，我们也需要考虑这些虚警元素对于弱小目标检测的干扰。因此，我们可以通过考虑这些背景均匀性和其带来的矩阵稀疏性对含有目标的红外图像进行建模以及求解，用以检测红外图像中的弱小目标。

3.2.3.2 模型构建

基于上述分析，我们采用红外块图像（Infrared Patch Image, IPI）模型对输入数据进行重新排布，以增强图像中各个部分的性质，以进行后续处理。IPI 模型是由 C.Q. Gao 等人（2013）所提出的一种红外图像低秩-稀疏构建方法^[16]。考虑到红外背景图像的非局部自相关性质，可以采用将部分重叠的图像块相互叠加的方式来增强红外背景图像的低秩性，IPI 模型就是基于这种思想提出的。图 3-1 展示了 IPI 模型的构建过程，左边是一幅原始红外图像 I ，这里假设 $I \in \mathbb{R}^{p \times q}$ ，右边是所构建的块图像（Patch image），表示为 I_p ，且 $I_p \in \mathbb{R}^{m \times n}$ 。首先，采用滑窗的方式，将预先设定大小的窗口在图像中从左到右、从上到下移动，可以得到一系列局部图像块。其次，将这些图像块分别向量化，使之成为列向量，随后将这些列向量按照取出的顺序，组合成为一个新的矩阵，即为块图像。块图像的大小不仅取决于原始图像的大小，也取决于滑窗的大小以及水平和垂直方向的滑动步长。特别地，如果滑窗的大小与原始图像相同，那么所得到的块图像也与原始图像相同。从这个意义上来说，基于原始图像的处理也可以看作是一种特殊的块图像模型^[16]。

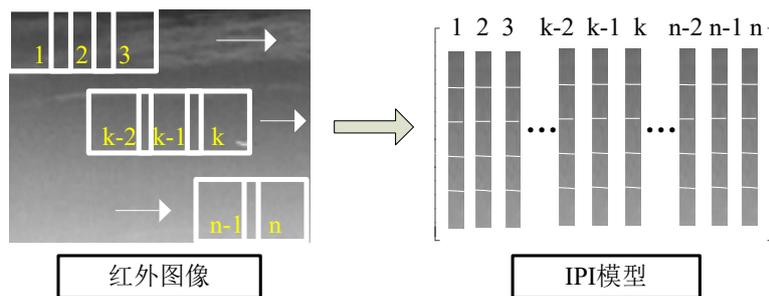


图 3-1 IPI 模型构建示意图

另一个问题是如何从块图像中恢复出原始图像。由于在滑动过程中，图像块是相互重叠的，在恢复时，就会出现块图像中几个不同位置的数值对应于原图同一个像素点的情况。为了解决这个问题，C.Q. Gao 等人提出采用池化（Pooling）的方式，例如均值池化，中值池化，最大值池化等。

与公式(3-9)相对应，红外图像的块图像模型可以表示为

$$I_p = T + B + N \quad (3-10)$$

这里 T , B , N 分别表示目标区域、背景区域以及噪声所对应的块图像模型。根据第 3.2.3.1 节中的分析，如果只考虑背景的低秩性和目标的稀疏性，基于 IPI 模型的红外弱小目标检测模型构建方式如下^[16]：

$$\min_{B,T} \|B\|_* + \lambda \|T\|_1, \quad \text{s.t.} \|I_p - B - T\|_F \leq \delta \quad (3-11)$$

这里 λ 为正则化因子，是一个正数； δ 表征了图像受到噪声污染的程度。该模型在处理低秩背景和稀疏目标的同时，考虑了噪声的干扰，具有一定抗噪性。很显然，该问题可以采用 PCP 方式求解。

我们发现，公式(3-11)仅仅考虑了低秩背景的情况。也就是说，该模型的效果很大程度上依赖于平滑、均匀的红外背景。当处理非平滑、非均匀场景时，上述低秩假设从理论上讲是不合适的，会导致恢复出的背景变得模糊。背景中一些重要的细节，例如云层的变化，海浪的波动等，将会无法恢复，因此导致错误的背景分类结果。我们知道，优化问题是一个动态平衡的过程，某一项假设的错误会导致其他项求解结果相应地下降。例如，某些云层的边缘可能被误认为是“稀疏”的，因此云层边缘有可能被误判为弱小目标，进而提高虚警率，影响弱小目标的检测。

为了实现更加准确的红外弱小目标检测，我们将 TV 约束引入 PCP 模型中，用以保持背景图像中重要的边缘及部分角点信息，称为 TV-PCP 模型^[100]。TV-PCP 模型构建如下：

$$\min_{B,T} \|B\|_* + \lambda_1 TV(B) + \lambda_2 \|T\|_1, \quad \text{s.t.} I_p = T + B + N, \quad \|N\|_F \leq \delta \quad (3-12)$$

这里 λ_1 和 λ_2 是正的常数，用以平衡上述三项待优化项，即正则化因子。 δ 表征了噪声的大小。将前文所述的矩阵全变差，即公式(3-6)，代入到公式(3-12)中，可以得到如下的范数形式的模型：

$$\min_{B,T} \|B\|_* + \lambda_1 \sum_i \|D_i B\|_2 + \lambda_2 \|T\|_1, \quad \text{s.t.} I_p = T + B + N, \quad \|N\|_F \leq \delta \quad (3-13)$$

这里 D_i 表示梯度算子。

可以看出，除了过去所采用的核范数之外，全变差模型也同时被用于对背景块图像 B 的约束。这样做可以避免核范数约束对背景区域造成的过度模糊，因此可以将背景区域的边缘与角点的清晰度提升，从而获得更加精确的背景估计结果。在此基础之上，这种更加精确的背景估计结果反过来可以减少检测结果中的干扰。

通过求解公式(3-12)，我们可以得到红外弱小目标所对应的块图像 T ，该过程可被视为一个动态反演过程，即，从输入的原始图像中反演求解得到其不同图像块的分类，包括背景图像块和目标图像块。在初步得到目标和背景分离结果之后，再通过块图像重构以及简单的后处理步骤，我们可以得到较为精确红外弱小目标检测结果。图 3-2展示了 TV-PCP 方法的流程图。

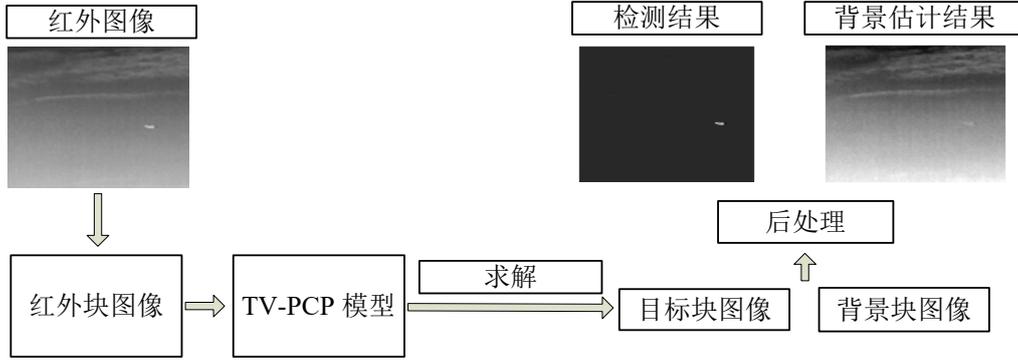


图 3-2 TV-PCP 算法流程图

3.2.3.3 优化求解方法

为了求解上述提出的 TV-PCP 模型，我们将其分解为几个便于求解的子问题。首先，将公式(3-13)进行等价变换，去掉各个变量之间的耦合关系：

$$\begin{aligned}
 & \min_{Z_1, Z_2, Z_3} \|Z_1\| + \lambda_1 \sum_i \|z_i\|_2 + \lambda_2 \|Z_3\|_1 \\
 & \text{s.t. } Z_1 = B \\
 & \quad Z_2 = [z_1; z_2; \dots; z_{mn}] \\
 & \quad Z_3 = T \\
 & \quad I_p = T + B + N, \quad \|N\|_F \leq \delta
 \end{aligned} \tag{3-14}$$

公式(3-14)的增广拉格朗日方程可以表示为

$$\begin{aligned}
 L_A = & \|Z_1\|_* + \lambda_1 \sum_i \|z_i\|_2 + \lambda_2 \|Z_3\|_1 + \langle Y_1, Z_1 - B \rangle + \frac{\beta}{2} \|Z_1 - B\|_F^2 \\
 & + \sum_i \left(\langle y_i, z_i - D_i B \rangle + \frac{\beta}{2} \|z_i - D_i B\|_F^2 \right) + \langle Y_3, Z_3 - T \rangle + \frac{\beta}{2} \|Z_3 - T\|_F^2 \\
 & + \langle Y_4, I_p - T - B - N \rangle + \frac{\beta}{2} \|I_p - T - B - N\|_F^2
 \end{aligned} \tag{3-15}$$

这里 $\langle \cdot \rangle$ 表示矩阵的内积， β 可以视为惩罚因子， Y_i , $i = 1, 2, 3, 4$ 代表拉格朗日乘

子, 且有如下形式:

$$\begin{aligned} Y_i &\in \mathbb{R}^{mn \times 1}, \quad i = 1, 3, 4 \\ Y_i &= [y_1, y_2, \dots, y_{mn}] \in \mathbb{R}^{2 \times mn} \end{aligned} \quad (3-16)$$

为了计算方便, 对公式(3-15)中的 Z_1, Z_3, T, B, N 进行列向量化。根据第二章中的介绍, 该问题可以采用交叠方向乘子方法 (Alternating Direction Multiplier Method, ADMM) 进行求解。我们知道, ADMM 是一种迭代的计算方法。在每次迭代中, 我们首先求解关于 $Z_i, i = 1, 2, 3$ 的子问题。接下来求解关于 N, B 和 T 的子问题。最后更新拉格朗日乘子。特别地, 在迭代过程中, 当我们求解某一个变量的子问题时, 其他变量都是固定不变的。

在第 $k+1$ 次迭代中, 对于 Z_1 子问题, 其可以被转化为:

$$\begin{aligned} Z_1^{k+1} &\leftarrow \arg \min_{Z_1} L_A \left(Z_1, Z_2^k, Z_3^k, B^k, T^k, N^k \right) \\ &= \arg \min_{Z_1} \|Z_1\|_* + \langle Y_1^k, Z_1 - B^k \rangle + \frac{\beta}{2} \|Z_1 - B^k\|_F^2 \\ &= \arg \min_{Z_1} \|Z_1\|_* + \frac{\beta}{2} \left\| Z_1 - \left(B^k - \frac{Y_1^k}{\beta} \right) \right\|_F^2 \end{aligned} \quad (3-17)$$

该问题可以采用奇异值阈值方法求解^[101]:

$$Z_1^{k+1} = SVT_{\frac{\beta}{2}} \left(B^k - \frac{Y_1^k}{\beta} \right) \quad (3-18)$$

这里 $SVT_{\mu}(\cdot)$ 是奇异值阈值算子, 其定义如下:

$$\begin{aligned} SVT_{\mu}(Y) &= U \text{diag}[(\sigma - \mu)_+] V^T \\ (\sigma - \mu)_+ &= \begin{cases} \sigma - \mu & \sigma > \mu \\ 0 & \text{otherwise} \end{cases} \end{aligned} \quad (3-19)$$

类似地, 在第 $k+1$ 次迭代中, 对于 Z_2 子问题, 其可以被转化为:

$$\begin{aligned} Z_2^{k+1} &\leftarrow \arg \min_{Z_2} L_A \left(Z_1^k, Z_2, Z_3^k, B^k, T^k, N^k \right) \\ &= \arg \min_{Z_2} \sum_i \left(\|z_i\|_2 + \langle Y_i^k, z_i - D_i B^k \rangle + \frac{\beta}{2} \left\| z_i - D_i B^k \right\|_F^2 \right) \end{aligned} \quad (3-20)$$

可以看出, 这是一个典型的有约束 L_2 范数优化问题, 它的求解可以通过如下的二

维收缩算子来实现:

$$z_i = \max \left\{ \left| \left| D_i B - \frac{y_i}{\beta} \right| - \frac{1}{\beta}, 0 \right\} \cdot \frac{(D_i B - \frac{y_i}{\beta})}{\|D_i B - \frac{y_i}{\beta}\|_2} \quad (3-21)$$

关于该算子的更多内容可以参考文献 [102]。

对于 Z_3 子问题, 我们的目标是求解下式:

$$\begin{aligned} Z_3^{k+1} &\leftarrow \arg \min_{Z_3} L_A \left(Z_1^k, Z_2^k, B^k, T^k, N^k \right) \\ &= \arg \min_{Z_3} \lambda_2 \|Z_3\|_1 + \langle Y_3^k, Z_3 - T^k \rangle + \frac{\beta}{2} \|Z_3 - T^k\|_F^2 \\ &= \arg \min_{Z_3} \lambda_2 \|Z_3\|_1 + \frac{\beta}{2} \left\| Z_3 - \left(T^k - \frac{Y_3^k}{\beta} \right) \right\|_F^2 \end{aligned} \quad (3-22)$$

上式可由如下算子求解:

$$Z_3^{k+1} = Th_{\frac{\lambda_2}{\beta}} \left(T - \frac{Y_3^k}{\beta} \right) \quad (3-23)$$

$$Th_\varepsilon(W) = \begin{cases} w - \varepsilon & w > \varepsilon \\ w + \varepsilon & w < -\varepsilon \\ 0 & \text{otherwise} \end{cases} \quad (3-24)$$

这里 $Th_\varepsilon(\cdot)$ 被称为阈值算子^[103]。至此, 整个求解过程的第一步就结束了。

在第二步中, 我们求解 N, B, T 子问题。对于 N 子问题, 其可以被转化为如下形式:

$$\begin{aligned} N^{k+1} &\leftarrow \arg \min_N \langle Y_4^k, I_p - T^k - B^k - N \rangle + \frac{\beta}{2} \|I_p - T^k - B^k - N\|_F^2 \\ &= \left\| N - \left(I_p - T^k - B^k + \frac{Y_4^k}{\beta} \right) \right\|_F^2, \quad \text{s.t. } \|N\|_F \leq \delta \end{aligned} \quad (3-25)$$

上式的解可以由如下的投影算子给出:

$$N^{k+1} = P_\Omega \left(I_p - T^k - B^k + \frac{Y_4^k}{\beta} \right) \quad (3-26)$$

Ω 代表了 $\|\cdot\|_F \leq \delta$ 所对应的三维空间中的球 (等值球面)。 P_Ω 表示了在这个球面上的投影。

对于 B 的子问题，它具有如下形式的解：

$$B^{k+1} \leftarrow \frac{\partial L_A}{\partial B} = 0 \quad (3-27)$$

上式是一个线性方程，求解过程为：

$$\begin{aligned} -\frac{\partial L_A}{\partial B} &= Y_1^k + \beta(Z_1^{k+1} - B) \\ &+ \sum_i [D_i^T y_i + \beta_i D_i^T (z_i - D_i B)] + Y_4^k + \beta(I_p - T^k - N^{k+1}) \end{aligned} \quad (3-28)$$

$$\begin{aligned} B^{k+1} &= (2\beta + \sum_i \beta_i D_i^T D_i)^{-1} \\ &[Y_1^k + Y_4^k + \sum_i (D_i^T y_i + \beta_i D_i^T z_i) + \beta(Z_1^{k+1} + I_p - T^k - N^{k+1})] \end{aligned} \quad (3-29)$$

类似地， T 的求解可以写为：

$$T^{k+1} \leftarrow \frac{\partial L_A}{\partial T} = 0 \quad (3-30)$$

$$T^{k+1} = \frac{Y_3 + \beta Z_3^{k+1} + Y_4 + \beta(I_p - B^{k+1} - N^{k+1})}{2\beta} \quad (3-31)$$

在第三步，我们更新拉格朗日乘子：

$$\begin{aligned} Y_1^{k+1} &\leftarrow Y_1^k + \gamma\beta(Z_1^{k+1} - B^{k+1}) \\ Y_2^{k+1} &\leftarrow Y_2^k + \gamma\beta(Z_2^{k+1} - DB^{k+1}) \\ Y_3^{k+1} &\leftarrow Y_3^k + \gamma\beta(Z_3^{k+1} - T^{k+1}) \\ Y_4^{k+1} &\leftarrow Y_4^k + \gamma\beta(I_p - T^{k+1} - B^{k+1} - N^{k+1}) \end{aligned} \quad (3-32)$$

这里 $\gamma > 0$ 是一个预设的搜索步长。至此，我们提出了完整的 TV-PCP 算法模型以及求解方法，算法流程如表 3-1 所示。

3.3 实验与结果分析

3.3.1 算法参数设置

上述提出的 TV-PCP 算法中包含有几个重要的参数，本节给出了这些参数的设置方式。

首先， $\lambda_i > 0$ ， $i = 1, 2$ 是正则化参数，用于在低秩项、稀疏项以及全变差项之间进行平衡。实际操作中， λ_1 是一个经验值，一般取 0.01 左右。在我们的实验中，

表 3-1 TV-PCP 模型求解算法

输入: 红外块图像模型 $I_p \in \mathbb{R}^{m \times n}$, β , λ_1 , λ_2 , δ
输出: B , T
1. 初始化: $B^k = \text{zeros}(m, n)$, $T^k = \text{zeros}(m, n)$, $N^k = \text{zeros}(m, n)$, $Z_1 = Z_3 = Z_4 = \text{zeros}(m, n)$, $Y_1 = Y_3 = Y_4 = \text{zeros}(m, n)$ 在下述迭代中, 上述矩阵均进行列向量化。 $Z_2 = \text{zeros}(mn, 2)$, $Y_2 = \text{zeros}(2, mn)$
2. while not converged do
3. $Z_1^{k+1} = D_{\frac{1}{\beta}}(B^k - \frac{Y_1^k}{\beta})$
4. 由公式(3-20)求解 Z_2^{k+1}
5. $Z_3^{k+1} = Th_{\frac{\lambda_2}{\beta}}\left(T - \frac{Y_3^k}{\beta}\right)$
6. $N^{k+1} = P_{\Omega}\left(I_p - T^k - B^k + \frac{Y_4^k}{\beta}\right)$
7. 由公式(3-29)求解 B^{k+1}
8. 由公式(3-31)求解 T^{k+1}
9. 由公式(3-32)更新拉格朗日乘子
10. $k = k + 1$
11. end while

$\lambda_1 = 0.005$ 。对于 λ_2 , 它起着平衡核范数和 L_1 范数的作用, 同时也需要考虑到 TV 项的影响, 这里我们将其设置为 $\lambda_2 = 1/\sqrt{\min(m, n)}$, 这里 m 和 n 是输入的块图像的大小。 β 是拉格朗日方程中的惩罚因子, 这里设置 $\beta = 0.025$ 。此外, $\gamma = 1.5$ 是一个经验参数。在 TV-PCP 的迭代求解中, 我们定义误差容许因子, 其作用是控制所恢复出的背景图像、目标图像之和与原图像的误差, 保证反演结果不脱离原图, 使得反演结果稳定可靠。其定义表示为:

$$\text{tol} = \frac{\|I_p - T^k - B^k - N^k\|_F}{\|I\|_F} \quad (3-33)$$

这里 k 是迭代次数。当 $\text{tol} < 10^{-5}$ 时, 算法被认为是收敛的。或者, 当达到最大迭代次数 $\text{MaxIter} = 500$ 时, 迭代停止。

3.3.2 评价指标

本节中我们介绍一些红外弱小目标检测常用的评价指标。这些指标将不仅仅被用于 TV-PCP 算法的评价, 同时也会用于本文所介绍的其他算法的评价之中。

信杂比 (Signal-to-Clutter Ratio, SCR) 是一种用于评价红外弱小目标显著程度

的指标。其定义如下：

$$\text{SCR} = \frac{|\mu_t - \mu_b|}{\sigma_b} \quad (3-34)$$

这里， μ_t 和 μ_b 是目标区域和目标区域周围一个背景邻域的平均像素值； σ_b 是该背景邻域的标准差^[15]。目标区域和局部邻域示意图见图 3-3。在我们的实验中，设置 $d = 20$ 。随后我们引入 SCR 增益，定义如下：

$$G_{\text{SCR}} = \frac{\text{SCR}_{out}}{\text{SCR}_{in}} \quad (3-35)$$

这里 SCR_{in} 以及 SCR_{out} 分别是输入红外图像以及处理后的图像的信杂比。可以看出，信杂比增益表示了目标增强效果的好坏。其定义为输出图像信杂比与输入图像信杂比的比例，因此该指标不存在量纲。

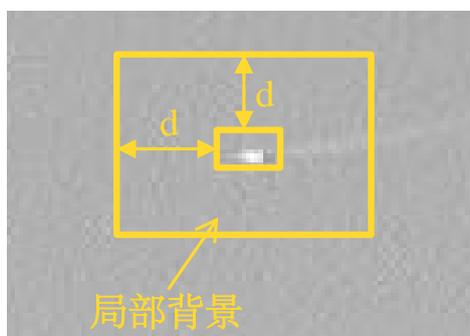


图 3-3 红外弱小目标及局部背景邻域示意图

另一个常用的评价指标是背景抑制因子（Background Suppression Factor, BSF），定义如下：

$$\text{BSF} = \frac{C_{in}}{C_{out}} \quad (3-36)$$

其中， C_{in} 和 C_{out} 分别代表原始红外图像和处理后的红外图像的背景区域标准差。注意与公式(3-35)不同，这里的背景不是局部背景，而是图像中除目标区域以外的全局背景。同样地，BSF 表征处理前后图像区域标准差的比例，该指标无量纲。

此外，为了给出某种算法在某个测试场景中的全局效果的评价，我们引入两个重要的指标：检测率（Probability of Detection, P_d ）以及虚警率（False Alarm Rate, F_a ）。检测率定义如下：

$$P_d = \frac{TD}{AT} \quad (3-37)$$

这里 TD 表示实际检测到的目标数量， AT 表示测试序列中真实存在的目标数量。

虚警率定义为:

$$F_a = \frac{FD}{NP} \quad (3-38)$$

这里 FD 以及 NP 分别表示虚警区域中的像素个数以及测试序列中的总像素个数。

有了上述定义, 我们可以引入被测试者操作特征 (Receiver Operation Characteristic, ROC) 曲线, 同样用于评价红外弱小目标检测的效果。ROC 曲线描述了在不同的虚警率 F_a 下, 检测率 P_d 的变化趋势。另外, 可以计算曲线下面积 (Area Under Curve, AUC), 作为 ROC 曲线的辅助定量评价指标。一般来说, AUC 越大, 则该 ROC 曲线代表了越好的检测效果。

3.3.3 检测结果与分析

我们选取 6 组测试序列对 TV-PCP 方法进行测试。这 6 组测试序列包括了天空、云层、海面 and 地面场景, 详细信息见表 3-2。其中, 序列 5 为公开的红外测试数据集, 其余数据由部分合作单位提供。序列 1 是典型的天空/云层场景, 背景亮度在一个较大的范围内变化, 目标是动态的, 且出现了闪烁, 即红外辐射强度不稳定, 且对比度较低; 序列 2 是一幅明亮的天空场景, 在某些区域中有丰富的细节, 干扰较为严重, 目标的形状不规则, 且带有旋转; 序列 3 是一幅海面场景, 在近处有人工建筑物干扰, 目标是长条状的船只; 序列 4 是一幅天空背景, 云层随时间变化, 目标的形态也随着时间而变化; 序列 5 是典型的非均匀云层场景, 目标呈点状, 随运动过程其大小有变化; 序列 6 是一幅复杂地面场景, 其中有明亮的干扰, 目标是一个行人, 在场景中移动。本节中所涉及的实验测试环境为 Matlab R2014b, 采用了配置有 8GB 内存以及 4G Hz 英特尔 i5 处理器的计算机。

表 3-2 测试场景描述

序号	帧数 (frames)	分辨率 (pixels)	背景描述	干扰物描述	目标个数	运动状态
1	40	128 × 128	天空	云层	1	动态闪烁
2	100	240 × 320	天空	云层	1	动态
3	50	240 × 320	海面/陆地	人工建筑物	1	动态
4	50	208 × 264	天空	云层	1	动态
5	30	200 × 256	天空	云层	1	动态
6	30	240 × 320	地面	明亮的地面干扰	1	动态

与此同时, 为了充分验证算法的有效性, 我们选取四种检测方法作为基线

(baseline), 与 TV-PCP 方法进行比较。这四种方法是: Top-hat 滤波算法, 最大均值算法, 最大中值算法以及基于 IPI 模型的检测方法^[16]。其中, 最大均值算法以及最大中值算法的滤波器大小均为 15×15 。IPI 方法的参数与文献 [16] 中相同。对于每组测试序列, 我们选取其中有代表性的一帧直观展示其检测结果, 如图 3-4 所示。

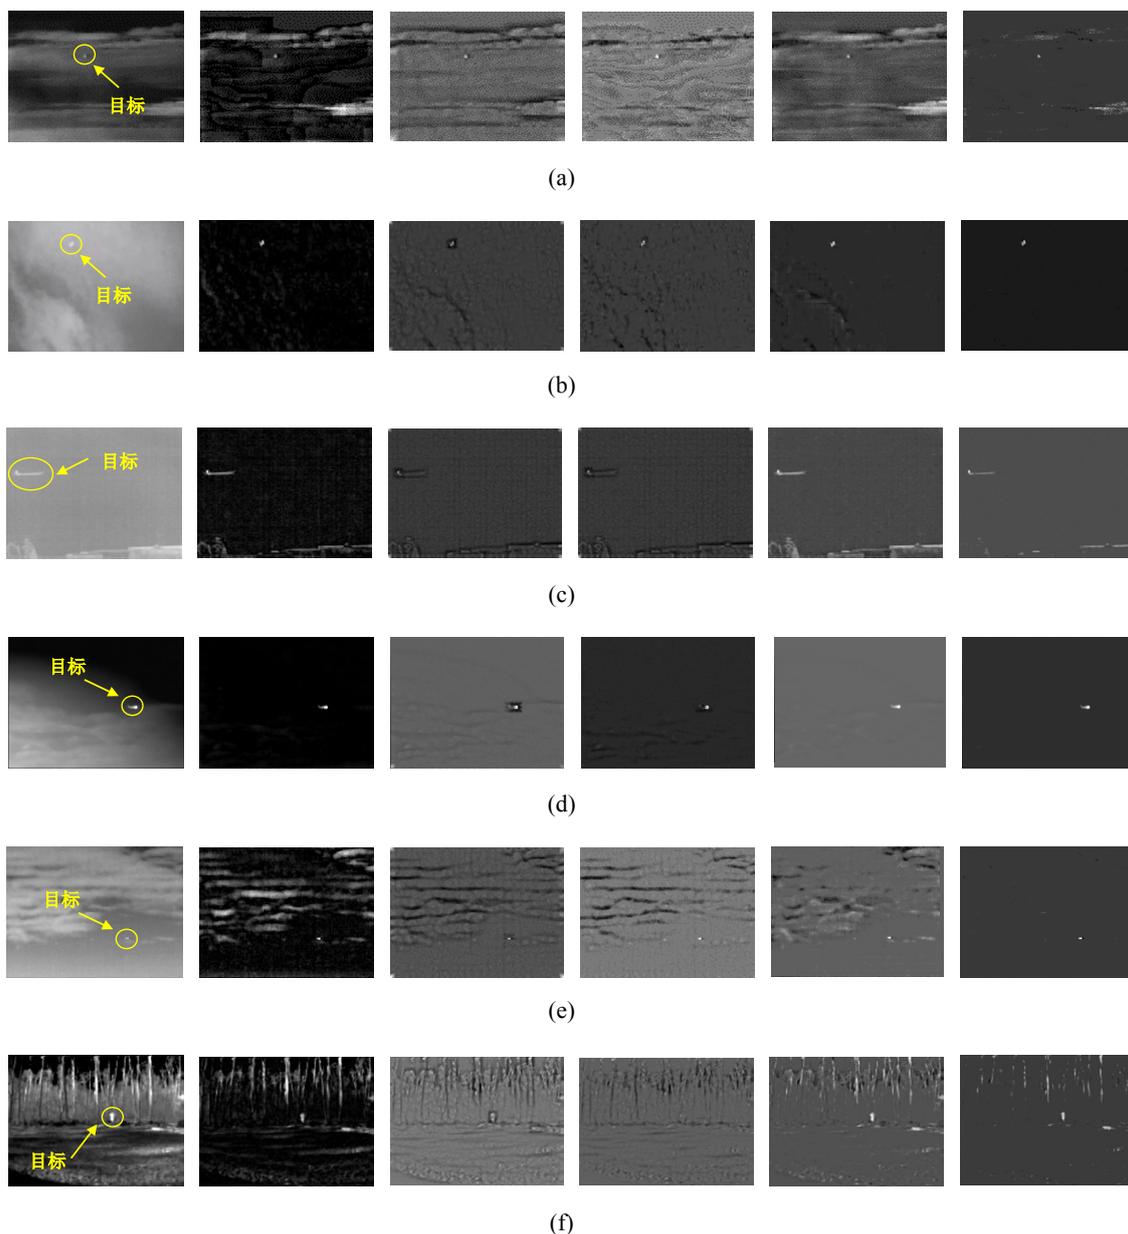


图 3-4 红外弱小目标检测结果, 从左到右依次为: 原图, Top-hat 检测结果, 最大均值算法, 最大中值算法, IPI 方法以及本章提出的 TV-PCP 算法。(a) 序列 1 检测结果; (b) 序列 2 检测结果; (c) 序列 3 检测结果; (d) 序列 4 检测结果; (e) 序列 5 检测结果; (f) 序列 6 检测结果

可以看出，总体来说，在 TV-PCP 算法的检测结果中，目标更加突出，背景杂波更少；Top-hat 等滤波类的算法容易受到复杂背景影响，出现较多虚警。IPI 模型更易受到细节丰富且亮度较高的背景影响，这是由其稀疏-低秩模型所决定的。特别是在序列 1, 3 和 4 中，背景是非均匀且复杂的，基线方法的检测结果均具有一定的虚警，而 TV-PCP 模型一定程度上避免了这个问题。

表 3-3 6 组测试序列的平均信杂比增益

	Top-hat	Maxmean	Maxmedian	IPI method	TV-PCP
序列 1	0.9075	0.7825	1.6628	0.7924	3.8708
序列 2	5.2639	0.6108	2.8017	12.2334	18.2471
序列 3	1.0107	0.5703	1.4931	1.0723	1.6735
序列 4	43.3366	1.9113	21.6923	21.6567	63.2282
序列 5	2.5561	1.1106	3.6981	5.8849	77.0683
序列 6	1.3781	0.2679	0.1983	2.3603	3.5340

表 3-4 6 组测试序列的平均背景抑制因子

	Top-hat	Maxmean	Maxmedian	IPI method	TV-PCP
序列 1	1.1287	3.0769	3.3240	2.5291	14.5979
序列 2	3.2335	8.6952	16.0503	23.3861	122.2180
序列 3	0.8044	2.5080	3.8095	2.1022	5.9564
序列 4	13.7273	14.4389	34.8797	9.3511	49.2204
序列 5	0.6660	3.5018	3.7469	5.3105	67.8014
序列 6	1.4532	2.5119	2.9462	3.0878	5.8583

表 3-3 以及表 3-4 分别展示了上述方法在 6 组测试序列中的检测结果所对应的平均信杂比增益和平均背景抑制因子，对于每个测试序列，其最大的数值用粗体标出。可以看出，TV-PCP 方法不仅在目标增强方面具有良好的效果，同时可以抑制背景杂波。其次，IPI 方法在大部分测试序列中表现仅次于 TV-PCP 模型。其余方法在不同测试序列中的表现差异很大，说明了传统方法在复杂场景中的不稳定性。

为了更直观地展示 TV-PCP 算法的目标增强和背景抑制效果，我们选取序列 2 和序列 3 为代表，图 3-5 展示了其中的代表性图像经 TV-PCP 算法处理前后的三维图对比。之所以选取这两组测试序列，是因为序列 2 中大部分海面背景相对平滑，可以作为局部均匀场景的代表，而序列 3 是典型的云层干扰下的天空场景，是复杂场景的代表。可以看出，对于本身背景不是非常复杂的测试序列，如序列 2，

TV-PCP 几乎可以完全抑制背景杂波，目标显得突出而清晰；在本身背景复杂的测试序列中，例如序列 3，TV-PCP 算法可以很好地抑制绝大多数背景，并突出目标。该结果与表 3-3 中的结果相一致。

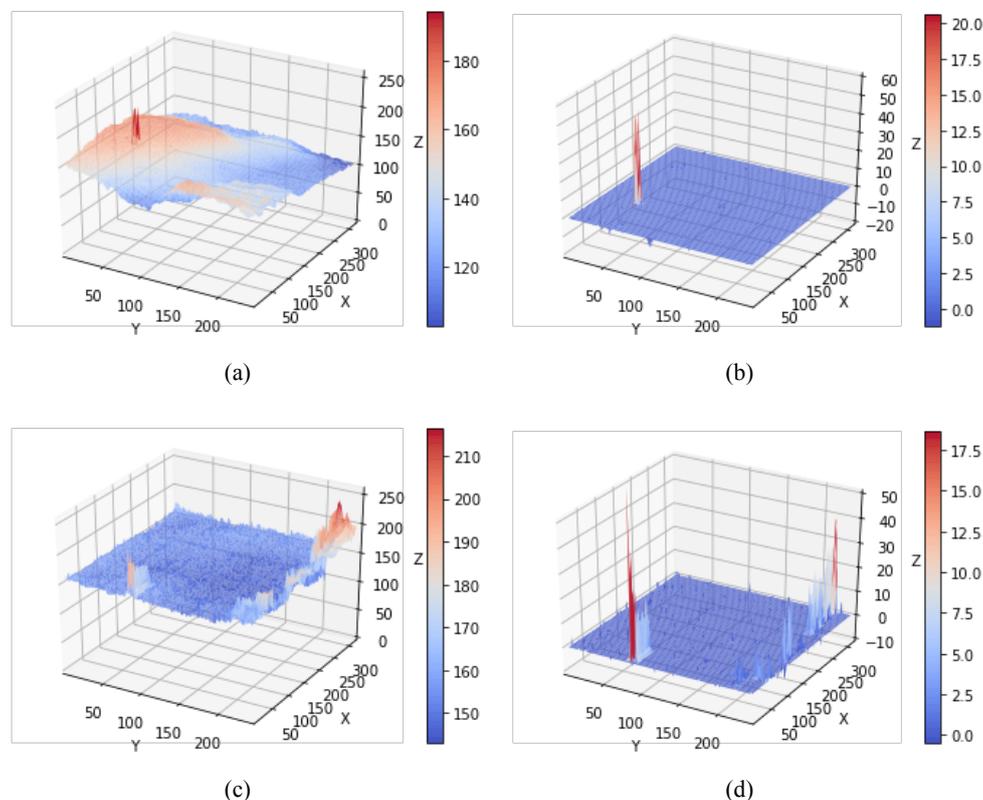


图 3-5 TV-PCP 算法处理前后的三维图像对比。(a) 序列 2 原图的三维投影图；(b) 序列 2 经 TV-PCP 算法处理后的三维投影图；(c) 序列 3 原图的三维投影图；(d) 序列 3 经 TV-PCP 算法处理后的三维投影图

除了可以获得很好的目标检测效果之外，TV-PCP 算法的另一个优点是其突出的背景恢复效果。由于 TV-PCP 算法可以视为 IPI 方法的一种改进，且该改进集中在对背景数据的处理，通过引入全变差项从而更精确地刻画背景。因此，我们展示了这两种算法在 6 组测试序列中对于背景恢复的效果，结果见图 3-6。可以看出，IPI 算法由于采用了低秩约束，尽管可以保留大部分背景，但对于边缘和细节的恢复不尽如人意。对于本章提出的 TV-PCP 算法，通过加入额外的背景约束，成功恢复出了大量背景细节，效果远好于单一低秩约束，该结果与表 3-4 中的结果相一致。但同时也要注意，部分目标的残影出现在了背景中，在序列 3 和序列 6 的测试结果中尤为明显，这是由于全变差项以及其他约束项的权重所导致的。这也印证了本章的一个主要观点：在联合正则化问题中，多重约束项之间的平衡往往会带来不一样的效果，而如何自适应地根据场景确定这些权重的值，也可以作为

今后的一个研究方向。

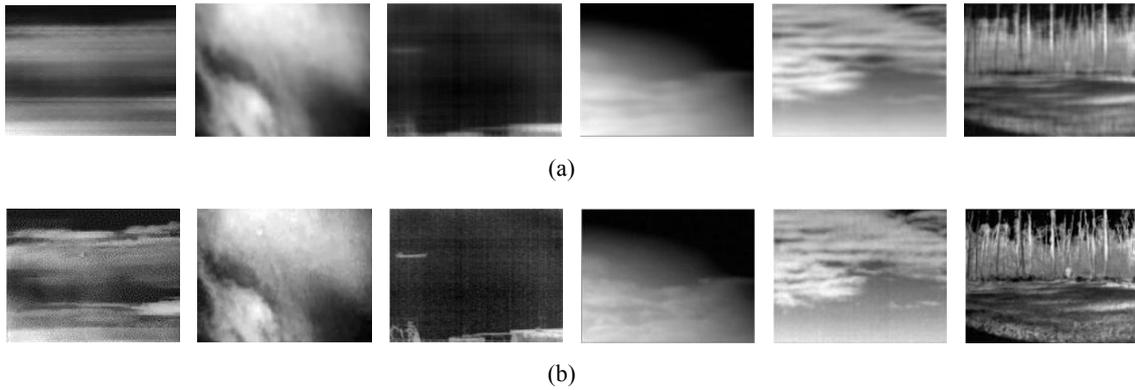
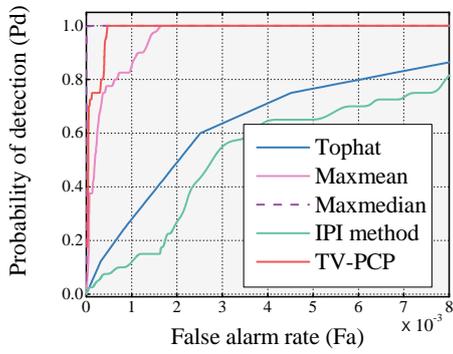


图 3-6 背景恢复结果图，从左到右依次为测试序列 1 到 6 的结果。(a)IPI 方法的背景恢复结果；(b)TV-PCP 方法的背景恢复结果

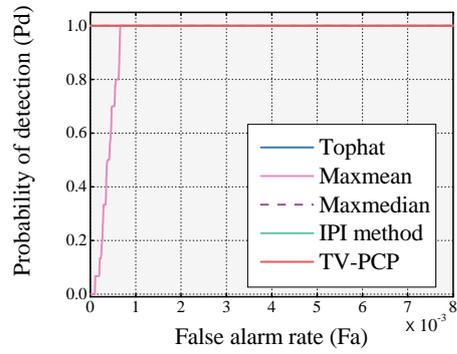
进一步地，我们引入 ROC 曲线，对不同的算法在不同序列中的检测效果做整体评估，其结果见图 3-7。从中可以看出，在序列 1 的检测结果的 ROC 曲线中，TV-PCP 算法的结果优于 Top-hat 方法，Maxmean 以及 IPI 方法，仅仅在左上角处略逊于 Maxmedian 方法。作为 IPI 方法的一种改进，TV-PCP 方法体现了其优越性，在虚警率和检测率的综合评判体系中表现超过了 IPI 方法。在序列 2 中，Maxmean 方法表现不佳，其余方法都取得了很好的效果，序列 3 同样如此。在序列 4 中，各个方法整体而言都取得了很好的效果，ROC 曲线难以断言各个方法的优劣。在序列 5 中，TV-PCP 方法的效果超过了 Top-hat 方法以及 Maxmean 方法。在序列 6 中，各个方法之间的差异较为明显。在虚警率极低时 ($F_a < 10^{-3}$)，TV-PCP 算法取得了最高的检测率；而 IPI 方法最为靠近左上角；在其余序列中表现一般的 Maxmean 方法在序列 6 中的表现有很大提升。上述分析表明，对于不同的检测方法，其往往受到测试场景、目标类型等因素的影响，单一的方法很难在不同测试序列中都取得很好的效果。但 TV-PCP 模型依然表现出了很强的鲁棒性。

综上所述，我们可以得出如下结论：每一种红外弱小目标检测方法都存在其固有的优势和劣势，表现在检测结果中，即为不同的场景适应性。因此，判断一个方法的效果需要采用多个评价指标，同时考虑其局部目标增强效果、全局背景抑制效果以及在某一测试序列中的整体表现。TV-PCP 算法在上述指标下都取得了令人满意的表现。对于某一个具体的测试序列以及某一个具体的指标，它或许不是最优的，但是整体而言，TV-PCP 具有最好的场景适应性，可以很好地突出目标并抑制背景，是一种鲁棒的红外弱小目标检测方法。该方法旨在处理背景中有明显灰度变化的场景，通过引入全变差正则化去除背景干扰，从而清晰地提取出弱

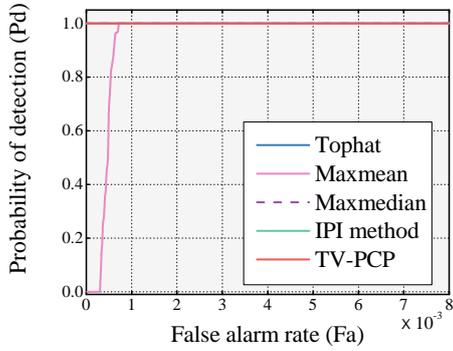
小目标。



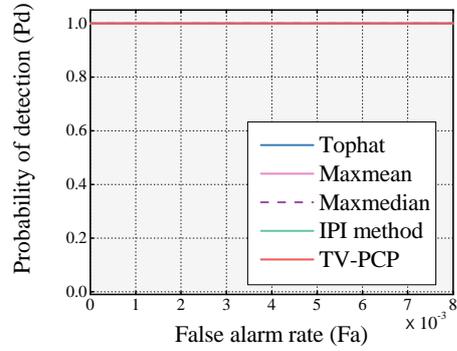
(a)



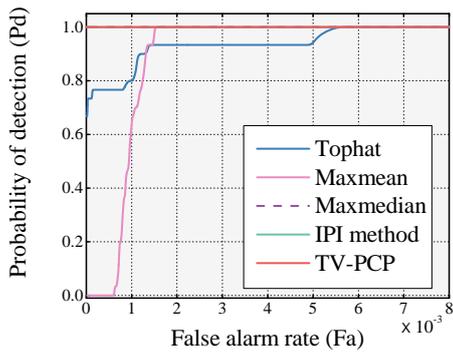
(b)



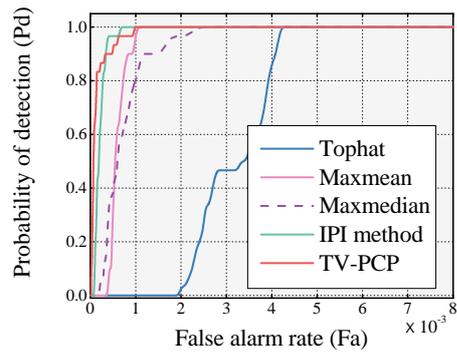
(c)



(d)



(e)



(f)

图 3-7 6 组测试序列的 ROC 曲线图。(a) 序列 1；(b) 序列 2；(c) 序列 3；(d) 序列 4；
(e) 序列 5；(f) 序列 6

3.4 本章小结

本章首先介绍了联合正则化理论，说明了其在反问题求解中的重要作用和研究难点。其次提出了一种基于全变差-主成分追踪的红外弱小目标检测方法，通过考虑红外背景的非局部自相关性质以及复杂背景中细节和边缘信息丰富的特点，构建了低秩-全变差联合正则化目标函数，用于描述红外背景，同时用稀疏正则项来约束目标。随即我们推导了基于 ADMM 算法的求解方法，通过将原问题划分为数个子问题，准确地求解了该联合正则化目标函数，且具有一定的抗噪性。最终我们给出了在 6 组测试序列上的结果，证明了所提出的 TV-PCP 算法的有效性。

第四章 基于子空间学习的红外弱小目标检测

4.1 子空间学习理论

在模式识别、机器学习及信号处理中，数据的结构可以用作数据智能处理和分类的依据，而子空间是其中常用的一种数据表示方法。线性子空间（Linear Subspace），或称子空间（Subspace），在数学上定义为某给定的向量空间的子集，同时也是该向量空间的加法子群。子空间学习这个概念在计算机视觉方面多有应用，同时也可用于机器学习等应用中，其背后的思想是，尽管我们处理的实际数据往往是高维的，但很多情况下，我们可以认为其分布在一个低维的子空间上^[104-106]。在低维子空间上处理问题可以帮助我们更好地发掘数据特征，寻求更精简的表示和数据处理方法。计算机视觉中的多种重要目标，例如运动、人脸以及纹理都可以被子空间很好地描述^[107-109]。而如何学习最优的子空间则是子空间学习理论需要解决的首要问题。

常用的子空间学习方法包括主成分分析（Principal Component Analysis, PCA）^[110]，支持向量机（Support Vector Machine, SVM）^[111]，主成分追踪（Principal Component Pursuit, PCP）^[94]以及一些线性正则化模型等^[112]。其中，数据降维和分类是其最主要的应用，这类方法广泛应用于人脸识别，图像索引与搜索，以及语音-语义识别等等。

在以上应用中，以 PCA 方法为例，该方法假设数据来自于一个低秩子空间，PCP 方法同样采用了该假设。然而，在实际中，数据往往很难用一个单一子空间去描述。更加合理的做法是采用数个子空间，即认为数据来源于多个低秩子空间的集合。图 4-1 是一组来源于多个子空间的数据示意图。可以看出，这里包括了一个 2 维子空间（图中的平面）以及两个一维子空间（线条）。而如何从实际数据中学习出其真正的子空间结构，是一个有挑战性的问题。在下一节中我们将介绍一种多子空间聚类方法，以及在此基础上提出的红外弱小目标检测方法。

4.2 基于稳定多子空间学习的红外弱小目标检测

4.2.1 低秩表示与子空间聚类

由上文可以知道，自然数据往往具有多子空间的性质，同时，由于自然数据的低秩性，这些数据可以被认为是分布在不同的低秩子空间中。子空间聚类（Subspace Clustering, SC），又称子空间分组（Subspace Grouping, SG），其目的就是

将数据同时归类到不同的子空间中，并且需要考虑噪声干扰的影响。

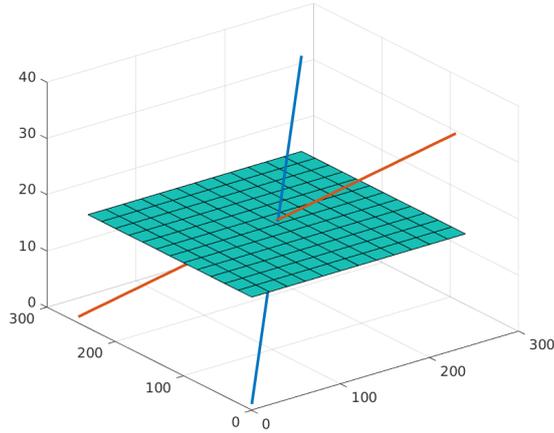


图 4-1 多子空间数据示意图

Liu 等 (2013) 提出了一种多子空间恢复方法, 称为低秩表示 (Low-rank Representation, LRR), 旨在寻找分布在不同子空间中的数据的最低秩的表示^[113]。这里我们仅考虑干扰项为稀疏矩阵的情况, 类似公式(3-7), 假设观测数据 $M \in \mathbb{R}^{m \times n}$, 其可以被表示为一个低秩矩阵 L 和一个稀疏矩阵 S 的和, 即满足下式:

$$\begin{aligned} M &= L + S \\ \text{rank}(L) &\ll \min \{m, n\}, \quad \|S\|_0 \ll mn \end{aligned} \quad (4-1)$$

这里 L 中的数据分布在 k 个子空间的集合 $\{U_i\}_{i=1}^k$ 上, 这里 k 是未知的。在 LRR 中, 问题可以被构建为如下形式:

$$\min_{L, S} \text{rank}(L) + \lambda \|S\|_0, \quad \text{s.t. } M = L + S \quad (4-2)$$

这里 $\lambda > 0$ 是正则化因子。对比公式 (3-8) 中所描述的 PCP 问题, 其不同之处在于 PCP 采取了最小化 L 的核范数的策略。这两者的区别是, PCP 所采取的核范数优化潜在地认为 L 是分布在一个单一子空间 $U = \sum_{i=1}^k U_i$ 上的。而实际上, 根据我们的假设, L 分布在子空间 U_1, \dots, U_k 上, 即 $U' = \cup_{i=1}^k U_i$ 。由于子空间 $U_i, i = 1, \dots, k$ 之间往往不可避免地存在交集, 因此, $U = \sum_{i=1}^k U_i$ 往往比 $U' = \cup_{i=1}^k U_i$ 大得多, 这就意味着采用核范数优化所得到的低秩子空间结构是不够准确的^[113]。

因此, 为了更好地描述数据的多子空间性质, LRR 方法中采取了以下策略:

$$\min_{\alpha, S} \text{rank}(\alpha) + \lambda \|S\|_0, \quad \text{s.t. } M = D\alpha + S \quad (4-3)$$

这里 D 可以视为一个字典, 该字典线性张成了数据所在的向量空间。我们将使得

上式取最小值的最优的 α 以及相应的字典 D 称为待恢复的数据 L 的最低秩 (the Lowest Rank Representation) 表示。得到最优化的 α 以及 D 之后, 就可以从中恢复出 L , 即 $L = D\alpha$ 。LRR 可以被视为广义的 PCP 问题, 在 PCP 问题中, 数据 L 是在其标准基上展开的。通过选择合适的字典 D , LRR 可以更加准确地恢复多子空间低秩结构信息。在实际应用中, 往往采用数据本身 L 作为 LRR 问题中的字典^[113]。

4.2.2 基于稳定多子空间学习的红外弱小目标检测

上节介绍了 LRR 的基本思想, 旨在恢复多子空间下的低秩数据结构。本节将介绍一种基于稳定多子空间学习的红外弱小目标检测算法, 通过构建多子空间背景模型, 并从数据中学习合适的字典, 实现复杂场景下的红外弱小目标检测^[114]。

4.2.2.1 复杂红外背景分析

根据第 2.1 节所描述的红外成像系统模型, 可以看出, 常见的应用场景包括深空背景, 天空背景, 海面背景以及地面背景。其中, 对于深空背景, 一般不存在或者只存在很少的背景杂波干扰, 因此可以被视为是均匀的, 且具有一定的自相关性。对于天空背景, 往往存在卷云、条带状云层以及絮状云层。这些不同的部分有着不同的红外辐射性质。在海面背景中, 海浪的快速变化会带来变化的红外辐射, 在该场景下红外图像的背景是不均匀的。在地面场景中, 众多因素都会引起红外成像的非均匀性, 例如建筑物, 树木, 地面等。此外, 场景中的人造目标往往会对目标检测问题造成非常大的干扰。综合上述分析, 天空背景、复杂海面背景以及地面背景往往都包含有不同的红外辐射源, 可以被视为复杂的、多源的 (Heterogeneous) 红外场景。图 4-2 展示了一组红外均匀背景以及一组红外非均匀背景的对比图, 包括均匀的天空和海面场景, 以及复杂云层场景, 包含人造建筑物的天空、海面场景以及地面场景。

与自然图像相比, 红外图像不具有颜色及纹理信息, 很多时候成像质量也较低。在弱小目标检测任务中, 这样的性质会带来更多的困难。由于其缺乏颜色及纹理信息, 我们在检测中可以利用的特征就更少; 由于成像质量低, 红外图像中不同部分的边界往往是模糊的, 难以准确区分。此外, 在复杂多源红外场景中, 往往有不止一个强红外辐射源。同时, 由于红外弱小目标所占面积小, 这些强辐射源会对目标检测造成强烈的干扰。因此, 在复杂多源红外场景中, 传统的红外弱小目标检测方法效果往往较差。因此, 我们希望能从红外场景的数据结构本身出发, 寻找一种新的表示方式, 用于描述复杂多源红外场景, 并进一步将其用于红外弱小目标检测。

现有的基于数据结构分析和表示的红外弱小目标检测方法主要包括两类: 第

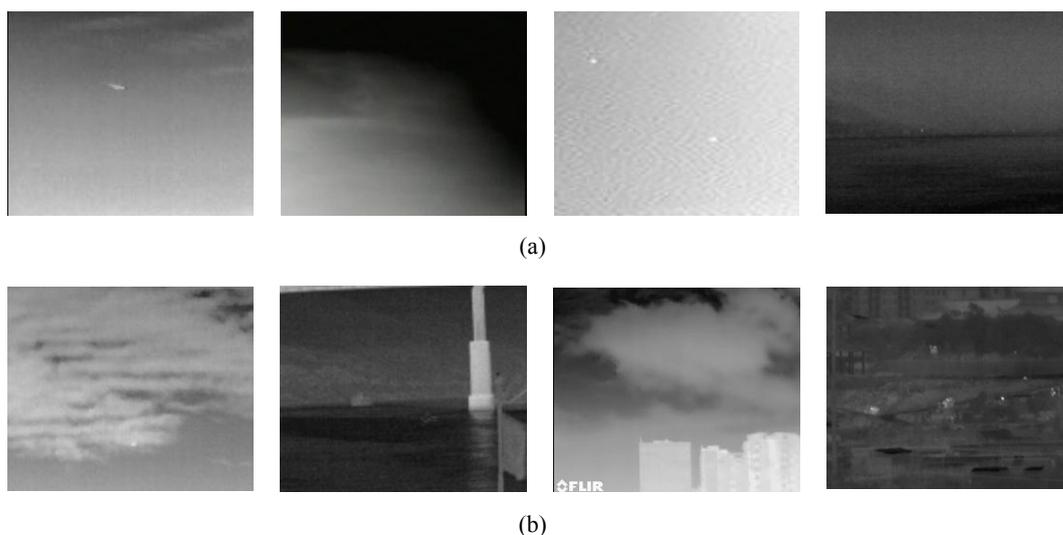


图 4-2 典型均匀、平滑红外场景与复杂红外场景对比图。(a) 均匀、平滑红外场景示意图；(b) 复杂、多源红外场景示意图

一类是基于过完备字典表示的方法，在过完备字典中寻找一组合适的基底，用以表示红外背景的结构。第二类是基于低秩表示的方法，即寻找一个低维子空间用以表示红外背景数据。对于第一类方法，Y. He 等（2015）提出了一种基于稀疏表示的方法，构建了过完备字典以实现目标检测^[115]。此外，时空联合字典构建以及其他字典学习方式也被用于红外弱小目标检测中^[34, 116]。而对于第二类方法，典型的基于低秩表示的算法包括第三章中提到的 IPI 模型，通过寻找红外背景图像的低秩结构以及目标的稀疏结构，实现了目标和背景的分离^[16]。同样地，该过程也可以在压缩域（Compressive Domain）中实现^[117]。

这里重点讨论红外弱小目标检测的 IPI 模型。我们知道，在红外搜索与跟踪系统中，由于成像距离长、成像质量不高等特点，其图像往往具有一定的非局部自相关性，图像不同区块之间的差异可能并不明显，甚至在一些情况下，相距很远的图像块之间可以互相表示。根据本文第三章中所阐述的模型，红外背景图像可以被认为是低秩的，即满足：

$$\text{rank } f_B(x, y) \ll \min\{m, n\} \quad (4-4)$$

这里 $f_B(x, y) \in \mathbb{R}^{m \times n}$ 表示背景图像， x 和 y 分别表示图像的行/列索引。在 IPI 模型中，根据公式(3-11)，通过最小化背景成分的核范数，可以对该低秩成分进行恢复。该方法在变化缓慢的均匀背景中取得了很好的效果。结合第 4.2.1 节的分析，从子空间的角度来说，可以看作是将背景成分在其主成分子空间（Principal Subspace）上的表示。但核范数约束将背景图像的表达限制在其主成分子空间上，实际中，当

图像的不同部分来源于不同的子空间时，单一子空间模型的基础假设将不再适用，其目标检测效果也会下降。因此，引入多子空间假设将会使得该问题的求解更加精确^[16]。此外，核范数优化还存在计算效率低的问题，其计算量随着图像大小的增加会出现显著增长^[118]。

4.2.2.2 基于稳定多子空间学习的红外弱小目标检测

根据上述分析，为了描述复杂多源红外场景，我们提出一种多子空间红外背景模型。对于具有多个强红外辐射源的背景，通过描述其多子空间结构可以区分各个不同的区域，减小其对目标检测的干扰；而对于平滑均匀的红外背景，需要采用单一子空间模型，这是多子空间模型在子空间数为 1 时的特殊情况。

与第三章类似，我们考虑如下的加性红外图像模型：

$$f_I(x, y) = f_B(x, y) + f_T(x, y) + f_N(x, y) \quad (4-5)$$

这里 $f_I(x, y)$ 表示图像 I 在像素点 (x, y) 处的灰度值， $f_T(x, y)$ 以及 $f_B(x, y)$ 分别表示目标区域与背景区域在该点处的像素值， $f_N(x, y)$ 表示噪声。首先，为了增强多源背景的低秩性，我们采用 IPI 模型对输入图像进行预处理，构建块图像模型 $I \in \mathbb{R}^{m \times n}$ ，即^[16]：

$$I = B + T + N \quad (4-6)$$

这里 B 表示背景数据， T 为目标， N 表示噪声，分别对应公式 (4-5) 中的三项。

接下来我们分别 B 、 T 以及 N 进行建模。对与 LRR 类似， B 的低秩恢复可以通过下式实现：

$$\min_{\alpha} \text{rank}(\alpha), \quad \text{s.t. } B = D\alpha \quad (4-7)$$

这里 $D = [D_1, \dots, D_k] \in \mathbb{R}^{m \times k}$ 表示一个字典，其中的所有列张成了背景数据空间， k 是子空间维度； $\alpha = [\alpha_1; \alpha_2; \dots; \alpha_k] \in \mathbb{R}^{k \times n}$ 为表示系数。公式 (4-7) 可以视为一个子空间学习问题，通过选择合适的字典 D ，可以很好地恢复 B 的多子空间结构^[113]。

公式(4-7)所表示矩阵的秩是离散函数，因而为该问题的求解带来了一定难度。受到组稀疏约束思想的启发，表示系数 α 的秩小于等于其非零行的个数，即：

$$\text{rank}(B) \leq \text{rank}(\alpha) \leq \|\alpha\|_{\text{row-0}} \quad (4-8)$$

因此最小化 α 的秩的过程可以通过最小化 $\|\alpha\|_{\text{row-0}}$ 来实现。同时，参考

第 2.3.1 节的定义, $\|\alpha\|_{\text{row-0}}$ 可以凸松弛为 $\|\alpha\|_{\text{row-1}}$ 。则上述公式 (4-8) 可以转化为:

$$\min_{\alpha} \|\alpha\|_{\text{row-1}}, \quad \text{s.t. } B = D\alpha \quad (4-9)$$

受到近年提出的鲁棒正交子空间算法的启发^[119], 这里我们不采用预先设定的字典作为 D , 相反地, 我们从背景数据 B 本身的结构出发, 去寻找自适应的子空间结构, 用以描述背景数据中各个区块的低秩性。在公式 (4-9) 的优化中, 为了避免 α 中出现太多的非零行或者数值极小的类非零行, 需要对字典 D 进行一定约束, 例如将其限制在单位球形区域内。同时, 为了使得表示系数 α 可以更好地表征 L 的秩, 我们需要降低 D 中各个列的相关性, 可以通过构造正交矩阵来实现, 即转化为^[119]:

$$\min_{D, \alpha} \|\alpha\|_{\text{row-1}}, \quad \text{s.t. } B = D\alpha, D^T D = I_j, \forall i \quad (4-10)$$

这里 D 的各列张成了一个正交子空间。在上述假设下, D 的各个列之间关联性很弱, 这使得 $\|\alpha\|_{\text{row-1}}$ 可以很好地表示多个低秩子空间的结构。此外, 上述子空间学习过程避免了循环求解 SVD 问题, 因此具有较高的计算效率。

对于目标成分 $f_T(x, y)$, 它表示的是红外弱小目标成分。从成像角度来说, 该部分与背景图像相关性很小, 并且面积也很小, 可以被视为干扰项。同时, 正是因为弱小目标面积很小, 根据第 2.2 节中的分析, 其可以被视为稀疏矩阵, 该矩阵中非零元素的位置即表示弱小目标的位置。我们考虑其所对应的块图像 T , 与 $f_T(x, y)$ 相同, T 具有稀疏支撑集, 可以由 L_0 范数进行约束。经过凸松弛, 可以采用 L_1 范数进行优化。此外, 考虑噪声项, 我们可以认为噪声是随机的, 且满足独立同分布形式。因此, 红外弱小目标检测问题可以被建模为如下形式:

$$\begin{aligned} & \min_{D, \alpha, T} \|\alpha\|_{\text{row-1}} + \lambda \|T\|_1 \\ & \text{s.t. } \|I - D\alpha - T\|_F \leq \delta, D^T D = I_j, \forall i \end{aligned} \quad (4-11)$$

这里 $\lambda > 0$ 是正则化因子, $\delta > 0$ 是一个与噪声相关的参数, 因此该模型对噪声鲁棒。通过求解上述凸优化问题, 可以自适应地得到对复杂红外背景的多子空间表示, 同时分离出弱小目标。我们将该算法称为稳定多子空间学习 (Stable Multi-subspace Learning, SMSL) 算法, 图 4-3 展示了 SMSL 算法检测红外弱小目标的流程图。

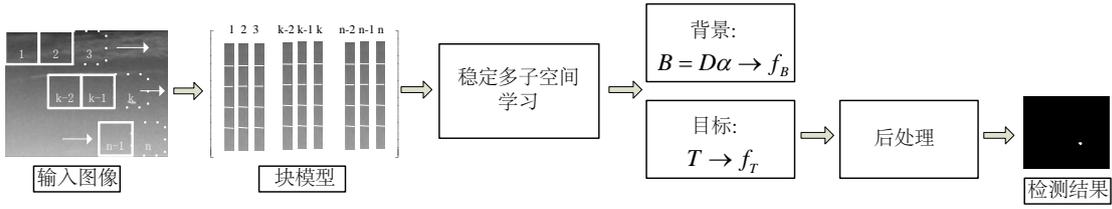


图 4-3 SMSL算法检测红外弱小目标流程图

4.2.2.3 求解方法

公式 (4-11)展示了基于SMSL的红外弱小目标检测算法要解决的问题，本节则提出一种有效的求解方法。在公式 (4-11)中，噪声是通过一个不等式来约束的，我们将其转化为等式，即：

$$\begin{aligned} \min_{D, \alpha, T} & \|\alpha\|_{\text{row}-1} + \lambda \|T\|_1 + \frac{1}{2\mu} \|I - D\alpha - T\|_F^2 \\ \text{s.t.} & D^T D = I_j, \forall i \end{aligned} \quad (4-12)$$

这里 $\mu(\delta)$ 是正则化因子。有理论研究表明，对于合适的 μ 值，公式 (4-12)和 (4-11)等价，且 $D\alpha$ 和 T 的恢复精度与噪声程度 δ 成反比^[120]。实际中， $f_N(x, y)$ 的幅值往往不大，因此背景和目標恢复误差很小。

公式 (4-12)中的前两项是凸的，因此可以采用 APG 算法求解，参考第2.3.2节中的描述^[121]。详细算法流程见表 4-1，这里 k 是子空间的初始化维度， $S_\varepsilon[X] = \max\{(X) - \varepsilon, 0\} \cdot \text{sgn}(X)$ 是软阈值算子^[103]。在步骤 5 中，我们采用了块坐标下降 (Block Coordinate Descent, BCD) 方法来求解 (D_i, α_i) ^[122, 123]。BCD 的详细算法流程见表 4-2。

SMSL算法求解的关键步骤是进行子空间系数和基底的收缩，从而在新的字典上通过 LRR 得到背景数据的多子空间低秩结构。研究表明，行 L_1 范数具有闭式表达。如表 4-1中的步骤 5 所示，当我们通过中间变量 G_k^B 计算得到 α_k 以及 D_k 后， α_{k+1} 可以通过对 α_k 中各个行的 L_2 范数进行软阈值分割得到。通过这种方式，我们实现了对最小化 $\|\alpha\|_{\text{row}-1}$ 的求解，也就实现了对 α 的降秩处理。同时，通过删除 α_{k+1} 中的零行以及 D_{k+1} 中的对应列，可以提高计算效率，且这些列不会再次出现在未来的计算中。将 APG 与行 L_1 范数软阈值相结合的方式是在该问题中首次提出的^[114]。

上述求解方法中，如何选择合适的 μ 是一个关键的问题。从公式 (4-12)中可以看出，当 μ 增加时，显然， $1/2\mu$ 也会相应增加，则 $\|I - D\alpha - T\|_F^2$ 在优化问题中起的作用会增加。因此， μ 应该足够大，以去除SMSL问题中噪声的影响；同时如果

表 4-1 SMSL求解算法

输入: 红外图像块模型 $I \in \mathbb{R}^{m \times n}$, k , λ
输出: $D = D_j$, $\alpha = \alpha_j$, $T = T_j$
1. 初始化: $D^0 = D^{-1} = \text{zeros}(m, k)$, $\alpha^0 = \alpha^{-1} = \text{rank}(k, n)$, $T^0 = T^{-1} = \text{zeros}(m, n)$, $t^0 = t^{-1} = 1$; $\mu_0 > 0$, $\bar{\mu} > 0$, $\eta < 1$
2. while not converge do
3. $Y_j^{B=D\alpha} = B_j + \frac{t_{j-1}-1}{t_j}[B_j - B_{j-1}]$, $Y_j^T = T_j + \frac{t_{j-1}-1}{t_j}(T_j - T_{j-1})$
4. $G_j^B = Y_j^B - \frac{1}{2}(Y_j^B + Y_j^T - I)$
5. 采用 BCD 方法求解 D_{j+1} 以及 α_{j+1}
6. $B_{j+1} = D_{j+1}\alpha_{j+1}$
7. 更新 k , 新的子空间维数等于 D_{j+1} 的列数
8. $G_j^T = Y_j^T - \frac{1}{2}(Y_j^B + Y_j^T - I)$
10. $t_{j+1} = \frac{1 + \sqrt{4t_j^2 + 1}}{2}$
11. $\mu_{j+1} = \max(\eta\mu_j, \bar{\mu})$
12. $j = j + 1$
13. end while

μ 太大, 则会影响 $D\alpha$ 以及 T 的优化, 使之过度收缩。从表 4-1中可以看出, μ 在整个求解过程中是变化的, 从初始值 μ_0 逐步下降到其最小值 $\bar{\mu}$ 。

4.2.2.4 计算复杂度分析

在红外搜索与跟踪系统中, 对于计算效率有较高的要求。本节将简单讨论SMSL方法的计算复杂度。从图 4-3可以看出, 其计算量主要集中在稳定多子空间学习的处理过程中。对于表 4-1所示的SMSL过程, 其计算量主要由步骤 5 的BCD 计算过程和步骤 9 的软阈值计算过程所决定。

对于 BCD 算法, 其计算复杂度由子空间维度和待分解的图像块模型的大小决定, 即 $O(kmn)$, 这里 m 和 n 是块图像模型 I 的大小, k 是子空间维度。对于软阈值计算过程, 其计算复杂度为 $O(mn)$ 。假设表 4-1中的循环次数为 N , 则本章所提出的SMSL算法的总体计算复杂度为 $O(Nkmn)$ 。

4.3 实验与结果分析

为了展示本章所提出的基于SMSL的红外弱小目标检测的效果, 我们分别在模拟数据和实际数据上进行了测试, 并对该方法的计算效率进行了评价。本章所采用的评价指标与第 3.3.2中所介绍的相同, 包括 SCR, G_{SCR} , BSF、检测率 P_d 以及

表 4-2 BCD 算法流程

输入: G_j^B, μ_j, k
输出: D_{j+1}, α_{j+1}
1. for $i = 1 : k$ do
2. $R_j^i = G_j^B - \sum_{p < i} D_{j+1}^p \alpha_{j+1}^p - \sum_{p > i} D_j^p \alpha_j^p, R_j^i = R_j^i - \sum_{p=1}^{i-1} D_{j+1}^p (D_{j+1}^p)^T R_j^i$
3. $D_{j+1}^i = R_j^i \alpha_j^{iT}$
4. $D_{j+1}^i = D_{j+1}^i / (\ D_{j+1}^i\ _2)$
5. $\alpha_{j+1}^i = S_{\frac{\mu_j}{2}} \left[\left\ \begin{matrix} D_{j+1}^i \\ R_j^i \end{matrix} \right\ _2 \right]$
6. end for
7. 删除 α_{j+1} 中的零行, 以及 D_{j+1} 中对应的列

虚警率 F_a 等。

4.3.1 参数设置

由上节可以知道, 基于SMSL的红外弱小目标检测算法中包含一些参数, 本节给出了这些参数的数值。假设输入的红外图像 $f(x, y) \in \mathbb{R}^{p \times q}$, 其对应的块模型为 $I \in \mathbb{R}^{m \times n}$ 。在块图像构建过程中, 我们选取的图像块的大小为 $\sqrt{p} \times \sqrt{q}$, 它可以自适应地根据输入图像的大小来调整。此外, 在求解公式 (4-12) 所示的问题时, 我们将其中的参数设置为 $\lambda = (1/(\min(m, n))^{1/2}) * 3$ 。对于 μ , 其在整个求解过程中从 μ_0 变化到 $\bar{\mu}$, 其含义参见第 4.2.2.3 节。这里我们设置 $\mu_0 = 0.5 \times s_4$, $\bar{\mu} = 0.05 \times s_5$, 这里 s 是 I 的奇异值, 按照下标顺序, 数值从大到小排列。这里 μ_0 和 $\bar{\mu}$ 的取值参考了文献 [16], 且根据SMSL算法的实际情况进行了调整。值得注意的是, 这些只是我们在测试中所采用的通用性的经验数值, 对于某个特定场景, 适当对参数进行一定调整有可能取得更好的效果。

4.3.2 仿真数据测试

为了测试本章所提出的SMSL方法在不同背景下针对不同类型目标的检测效果, 我们合成了五组不同的含有红外弱小目标的模拟序列。这些模拟序列都是通过真实的红外背景与模拟目标叠合而成, 该过程称为数据正演^[124]。我们采用泊松融合^[125]的方法, 在红外背景中通过给定弱小目标的运动轨迹, 将合成的目标融合入背景图像中的对应位置, 从而得到模拟数据。五组测试数据的背景图片均为合作单位提供。这五组模拟数据的具体信息如下: 模拟场景 1 包含了海面与礁石所构成的背景, 同时背景中包含有明显的人造干扰物, 在该场景中包含有两个红外弱小目标, 其一为一个人工合成的红外弱小目标, 形状符合高斯分布, 在运动过

程中它的大小从 2×2 像素改变至 5×6 像素，其二为一静态红外目标，它的位置分布在人造干扰物的下方，大小为 9×6 像素；模拟场景 2 表现了在天空及云层背景下的两个红外弱小目标，其一为人工模拟的运动目标，大小为 6×3 像素，其二为缓慢运动的目标，大小为 6×4 像素；模拟场景 3 表现了包含着明亮的人造干扰物的天空场景，其上有一个人工模拟的红外弱小目标，大小在运动过程中从 2×3 像素变化到 6×6 像素；模拟场景 4 表现了类似于模拟场景 1 的海面和礁石场景，但人造干扰物的红外辐射更加强烈，同时在该场景中还包含静态的杂波和动态的水波干扰，在该场景中有 1 个人工合成的红外目标，该目标从场景的左下角运动至右上角；模拟场景 5 表现了海空场景下的两个红外弱小目标，在场景中包含了明亮的礁石背景以及一艘船只。由于该船只的大小不属于弱小目标的范畴，因此在该应用中，这艘船只将被视为杂波，该场景中的一个目标为高斯模型生成的动态目标，其大小在运动过程中由 3×3 像素变化至 4×4 像素，另一个目标为静态目标，大小为 8×7 像素。表 4-3 给出了 5 组模拟数据的具体信息，包括背景信息以及目标信息等；图 4-4 展示了每一组模拟数据中有代表性的图片，包括其目标位置、形态分布以及个数，其中在模拟场景 1, 2 和 5 中，包含有不止一个弱小目标，其余序列只包含一个目标。可以看出，在这些合成数据之中，包含了复杂的海空以及天空背景；同时包含了各种不同大小，不同类型的红外弱小目标，因此适用于验证基于 SMSL 方法的红外弱小目标检测的有效性。此外，有 3 组模拟数据中含有噪声，可以测试算法在噪声环境下的稳定性。

表 4-3 五组模拟数据的基本信息

序号	帧数 (frames)	背景 描述	干扰物描述	目标 个数	运动状态	目标大小	噪声水平 (dB)
1	73	海面	人造	2	动态/静态	可变	40
2	31	天空	云层	2	动态	$6 \times 3/6 \times 4$	40
3	31	天空	人造	1	动态	可变	40
4	67	海面	人造/水波	1	动态	可变	0
5	67	海空	人造/礁石	2	动态/静态	可变	0

为了验证基于 SMSL 的方法在不同类型以及不同信杂比的场景中的检测效果，我们做了如下两组实验：1) 将 5 组模拟数据中的图像帧按照不同 SCR 来分类，将其分成新的 5 个组，每组数据对应着不同的信杂比。如果将信杂比理解为从该场景中检测出目标的“难度”，则这组实验正是为了验证我们所提出的基于 SMSL 的检测方法在低难度以及高难度场景中的检测效果。表 4-4 展示了分组的详细信息，

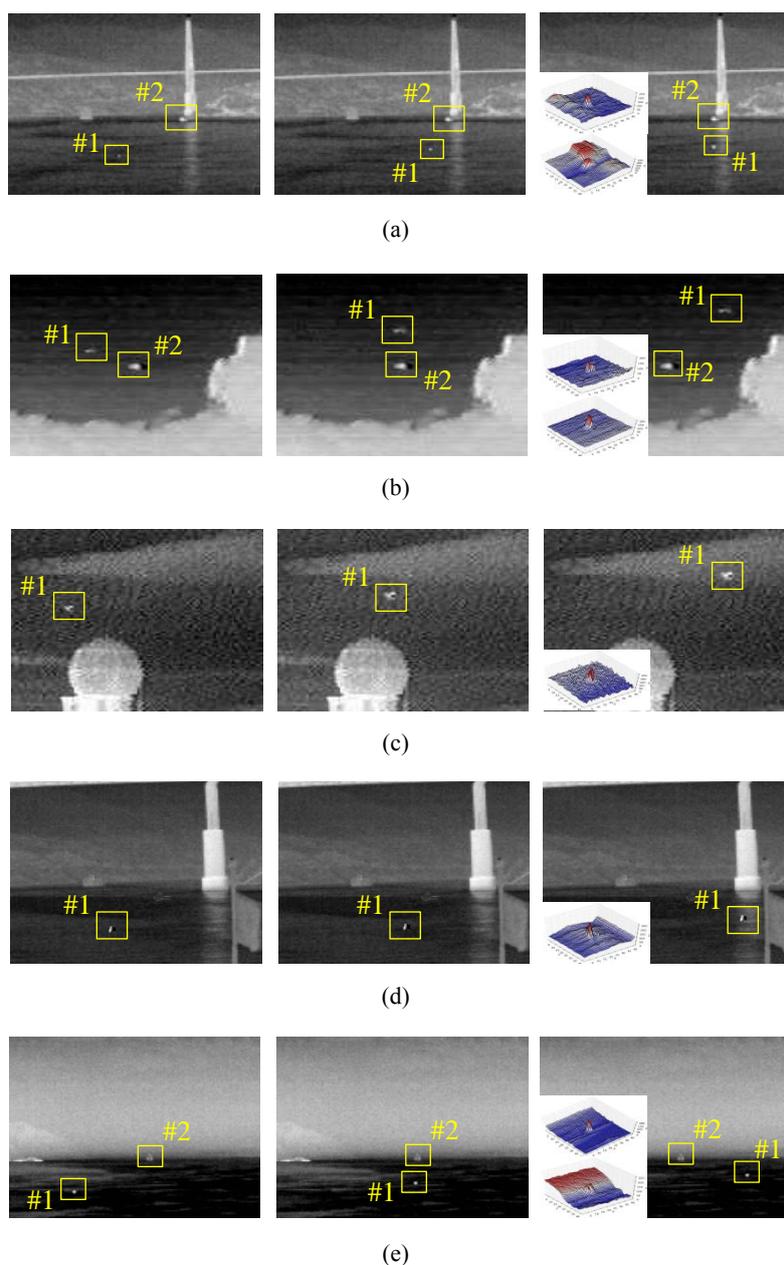


图 4-4 模拟数据场景展示，以及其中目标的三维分布示意图。其中黄色方框代表目标的位置，数字代表该场景中目标的编号。对于包含不止一个目标的场景，其三维图是按照序号从小到大的顺序排列的。(a) 模拟数据 1；(b) 模拟数据 2；(c) 模拟数据 3；(d) 模拟数据 4；(e) 模拟数据 5

其中 \overline{SCR} 和 \overline{size} 分别表示该组中的平均 SCR 以及平均目标大小。2) 直接在 5 组模拟数据上进行检测，这是为了验证基于 SMSL 的算法在不同场景中，检测不同类型和数量的目标的效果。下面我们逐一进行讨论。

在针对不同 SCR 图像的测试中，我们可以从表 4-4 中看出，从第 1 组到第 5

表 4-4 具有不同 SCR 的 5 组图像的细节信息

	第 1 组	第 2 组	第 3 组	第 4 组	第 5 组
目标数量	37	70	56	29	69
SCR 范围	$0 < \text{SCR} \leq 2$	$2 < \text{SCR} \leq 3$	$3 < \text{SCR} \leq 4$	$4 < \text{SCR} \leq 5$	$5 < \text{SCR}$
$\overline{\text{SCR}}$	1.55	2.43	3.46	4.51	6.76
$\overline{\text{size}}$	16.41	21.29	16.79	17.76	29.52

组，每组图像的 SCR 逐渐增加，因此，从第 1 组到第 5 组，检测难度逐渐降低。同时，对于具有同样 SCR 的一组数据， P_d 越大，说明算法的检测效果越好。

我们采用三种基线方法：Top-hat 滤波，最大中值（Maxmedian）以及最大均值（Maxmean）方法作为对比方法。同时，近年提出的两种新方法也被纳入比较，分别是基于核方法的非参数回归（Kernel-based Nonparametric Regression）方法，记为 KR-CFAR [12]，以及块图像模型方法，记为 IPI 方法 [16]。在最大中值以及最大均值滤波算法中，滤波器的大小取 15×15 。在 KR-CFAR 中，我们采用高斯核，其余参数选择与文献 [12] 中相同。IPI 模型的参数与文献 [16] 中相同。表 4-5 展示了对比的结果。其中，为了使得不同算法的检测率具有可比性，这里将虚警率设置为 $F_a = 0.05\%$ ，考虑到每幅图像的分辨率不同，很难完全精确到该固定的虚警率，因此允许实际虚警率在这个值附近很小的范围内上下浮动。

表 4-5 5 组不同 SCR 数据中的检测率对比

评价指标	检测方法	第 1 组	第 2 组	第 3 组	第 4 组	第 5 组
P_d	Tophat	0.38	0.73	0.80	0.9655	1
	Maxmedian	0.9730	0.9143	0.8393	0.9655	1
	Maxmean	0.7027	0.9143	0.8393	0.9655	1
	KR-CFAR	0.7297	0.8571	0.8929	1	1
	IPI Model	0.32	0.71	0.84	0.9655	1
	Proposed method	0.89	0.9429	0.9286	1	1

从表 4-5 中可以看出，本章所提出的 SMSL 方法在第 2 组和第 3 组测试数据中取得了最高的检测率。在第 4 组和第 5 组数据中，SMSL 方法的检测率达到了 100%。以上结果表明，在复杂背景下，通过采用多子空间方法描述背景的多样性，可以取得很好的效果。在第 1 组数据中，最大中值方法达到了最高的检测率，其原因是第 1 组测试数据中，所对应的目标信杂比最低，这样的目标面积更小，往往表现为点目标的形状。而最大中值方法和最大均值方法就是为点目标检测而设计的。当目标的形态不再是点状时，尽管目标的信杂比在提高，但最大中值和最大

均值方法的检测效果并没有提高，如第 2 到第 4 组数据的检测结果所示，这也充分说明了这两种方法的局限性。在第 1 组数据的检测结果中，除了最大中值方法之外，我们所提出的 SMSL 方法取得了最好的效果，实现了检测率 $P_d = 0.89$ ，远高于 Top-hat 滤波方法以及 IPI 方法。随着信杂比的增高，在第 4 组测试数据中，SMSL 方法和 KR-CFAR 方法率先实现了检测率 $P_d = 1$ 。在第 5 组测试数据中，由于信杂比已经增加到了 $SCR = 1$ ，所有的方法都达到了很高的检测率。值得注意的是，这里的 5 组测试数据是通过信杂比来分组的，而非测试场景。也就是说，在每一组测试数据中，都包含了不同的场景、目标以及噪声。

上述讨论表明了本章所提出的方法对于不同信杂比的目标的鲁棒性，下面我们展示不同的方法在 5 种不同场景中的表现，这里采用平均信杂比增益 \overline{G}_{SCR} 以及平均背景抑制因子 \overline{BSF} 进行评价，结果见表 4-6 以及表 4-7。可以看出，本章提出的 SMSL 方法在 5 组模拟数据测试中都达到了最好的效果，尤其是在背景抑制方面，表现非常突出。这也进一步说明，通过采用多子空间模型可以很好地刻画复杂背景，因此可以达到很高的信杂比增益以及背景抑制效果。除了 SMSL 方法之外，IPI 方法表现出了很好的目标增强效果，而最大中值方法以及 KR-CFAR 方法效果近似。最大中值方法和 KR-CFAR 方法都是通过估计背景来实现目标检测的，在 5 组模拟数据中，由于背景较复杂，两种方法都受到了一定的干扰。也正是由于其检测机制着重于背景估计，这两种方法都不能很好地实现目标增强，表现在数据中，即为信杂比增益较低。相比之下 IPI 方法取得了更好的目标增强效果，但是其背景模型采用单一子空间低秩模型，因此在刻画复杂背景方面效果逊色于 SMSL。

表 4-6 5 组模拟数据的平均信杂比增益

	Top-hat	Maxmedian	Maxmean	KR-CFAR	IPI method	SMSL
模拟数据 1	1.85	1.85	0.84	0.85	4.57	8.65
模拟数据 2	2.27	1.92	0.88	0.63	2.21	2.31
模拟数据 3	1.39	1.44	1.21	1.30	1.53	2.00
模拟数据 4	1.97	1.28	0.08	0.73	2.84	3.67
模拟数据 5	2.03	2.74	1.15	0.62	3.22	7.93

图 4-5 展示了 SMSL 方法以及作为比较的其余 5 种方法在模拟数据集上的 ROC 曲线结果，其曲线下面积 (Area Under Curve, AUC) 见表 4-8。可以看出，在第 1 组模拟数据中，SMSL 方法的效果显著地好于其它方法；同时最大中值方法和最大均值方法效果好于 KR-CFAR，IPI 方法以及 Top-hat 滤波方法。在第 2 组模拟数据中，SMSL 方法在虚警率极小的情况下可以达到 80% 以上的检测率，相比其他方法，这是一个非常巨大的优势，与此同时，其 AUC 的值是最大的。IPI 方法在第 2

表 4-7 5 组模拟数据的平均背景抑制因子

	Top-hat	Maxmedian	Maxmean	KR-CFAR	IPI method	SMSL
模拟数据 1	1.58	5.04	4.07	5.71	4.35	8.85
模拟数据 2	5.76	10.09	6.31	7.06	2.90	17.62
模拟数据 3	2.12	3.23	2.74	3.41	1.83	5.59
模拟数据 4	1.82	7.84	4.41	6.92	2.79	12.82
模拟数据 5	5.81	12.05	9.77	10.60	12.14	26.23

组模拟数据中表现不佳，主要是由于该序列中的背景有很强的多子空间性质，而 IPI 方法的原理决定了它不具有处理该类场景的能力。同时我们注意到，第 1 组及第 2 组模拟数据中都含有噪声，可以说明 SMSL 方法在面对含噪场景时具有很强的鲁棒性。在第 3 和第 4 组模拟数据中，我们所测试的 6 种方法都有很好的效果，在这里 ROC 曲线无法说明这些方法的差异性。在第 5 组模拟数据中，基于滤波的方法表现更好，原因是第 5 组模拟数据中的目标呈点状，非常适合于 Top-hat 滤波、最大中值以及最大均值滤波方法。此外我们注意到，在 5 组模拟数据中，SMSL 的方法表现最稳定，而其他方法的表现或多或少都具有一定的起伏，这也说明了 SMSL 方法的稳定性，在各种类型的场景和噪声程度下，面对不同类型的目标，都可以实现令人满意的检测效果。

表 4-8 模拟数据 ROC 曲线的曲线下面积 ($\times 10^{-3}$)

	Top-hat	Maxmedian	Maxmean	KR-CFAR	IPI method	SMSL
模拟数据 1	994.0147	999.9755	999.8902	999.2132	997.8854	999.9904
模拟数据 2	999.4608	999.4268	999.1925	999.6011	986.1873	999.6589
模拟数据 3	999.9975	999.9998	999.9998	999.9836	999.9996	999.9996
模拟数据 4	1000.0000	1000.0000	1000.0000	1000.0000	1000.0000	1000.0000
模拟数据 5	1000.0000	1000.0000	1000.0000	999.9404	999.9981	999.9875

4.3.3 实际场景数据测试

我们在 3 组实际数据上测试了本章所提出的 SMSL 方法的检测效果，每组序列的代表性图片展示在图 4-6 中，其详细信息见表 4-9。其中第 3 组测试图片为公开的红外弱小目标检测数据，其余数据为合作单位提供。可以看出，3 组数据包括了天空场景以及地面场景，值得注意的是，在第 2 组实际数据中，包含了 3 个明亮的目标：其中一个是在图 4-6 中所标注出的红外目标，其强度随着时间而改变；另外两个是手持目标，分布在标注出的目标的左右两侧。由于这两个手持目标非常不

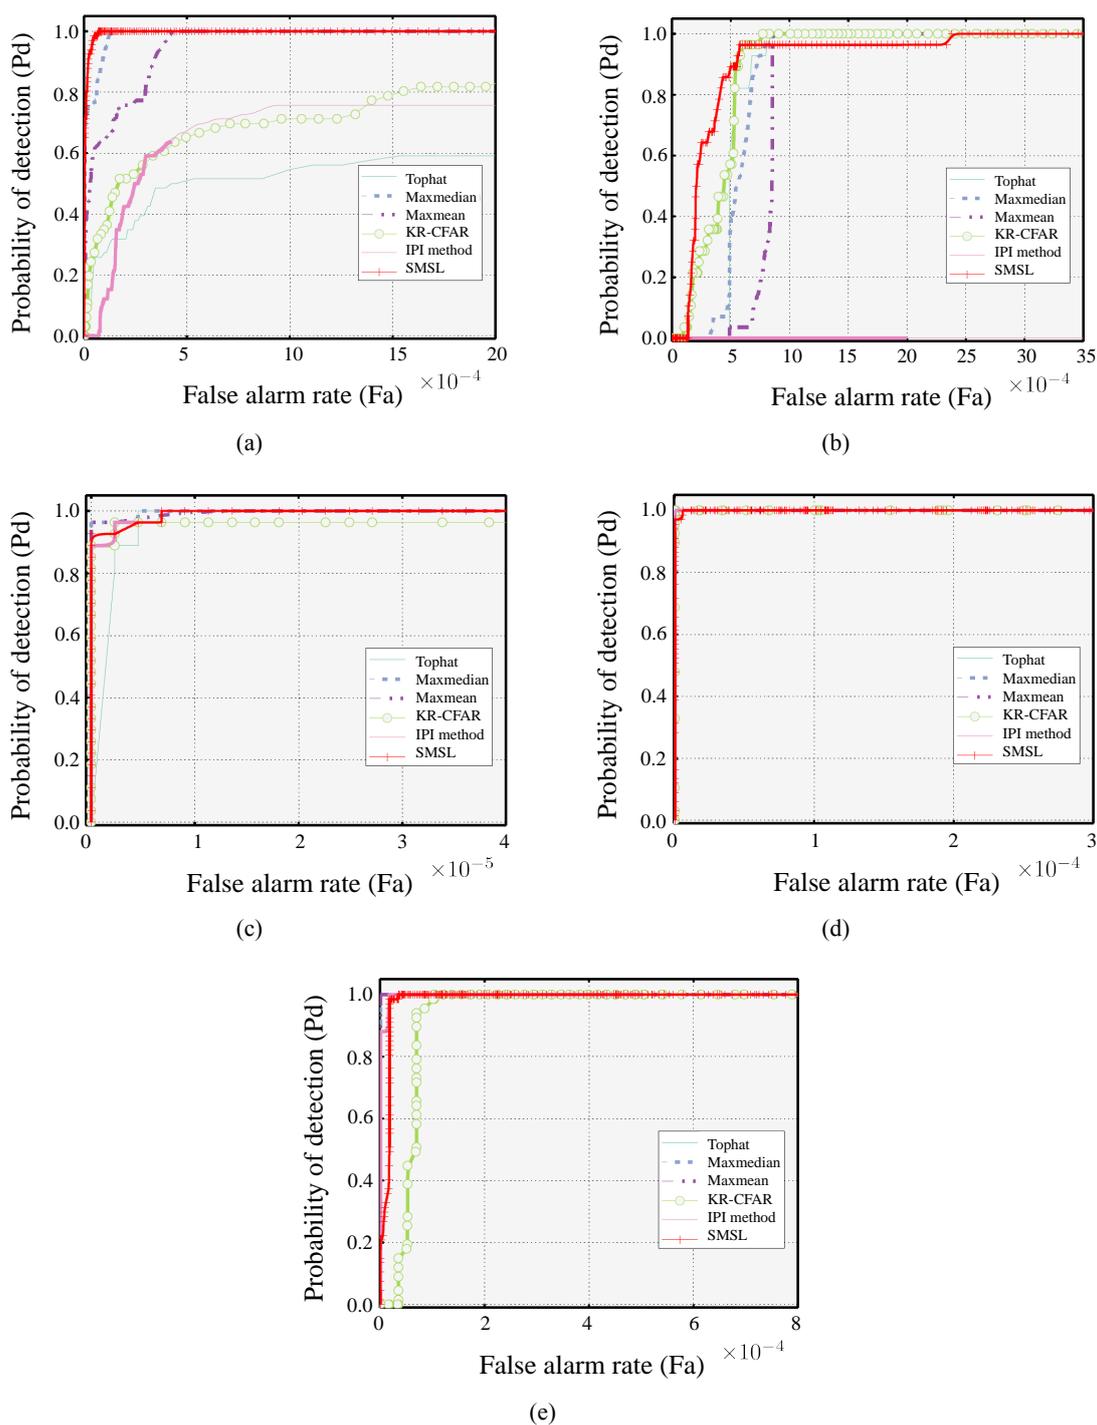


图 4-5 5 组模拟数据的 ROC 曲线图。(a) 模拟数据 1；(b) 模拟数据 2；(c) 模拟数据 3；
(d) 模拟数据 4；(e) 模拟数据 5

稳定，因此不具有讨论价值。我们在下文中仅仅讨论图 4-6 中所标注出的红外目标。

同样地，我们将 SMSL 方法与 5 种其他方法做对比，分别是 Top-hat 滤波方法，最大中值滤波方法，最大均值滤波方法，KR-CFAR 方法以及 IPI 方法。采用简单

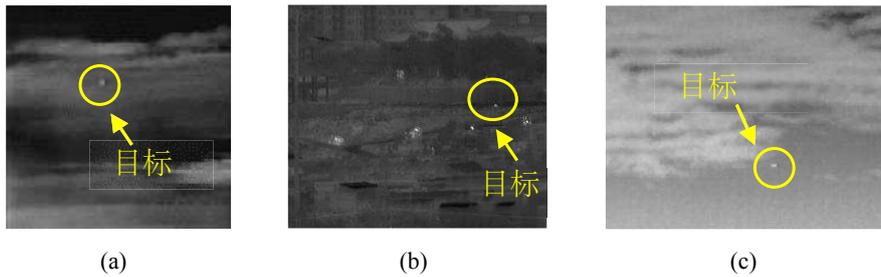


图 4-6 3 组实际测试数据场景示意图

表 4-9 3 组实际数据的基本信息

序号	分辨率 (pixel)	背景描述	干扰物描述	目标个数	运动状态
1	128 × 128	天空	云层	1	动态闪烁
2	227 × 260	地面	建筑物及行人等	3	动态
3	200 × 256	天空	云层	1	动态

阈值分割作为后处理方法，我们可以得到每一组测试序列的目标检测结果以及虚警的情况。

表 4-10 以及表 4-11 展示了我们所采用的测试方法在真实红外数据中的平均信杂比增益以及背景抑制因子。可以看出，SMSL 方法具有最高的信杂比增益以及最高的背景抑制因子结果，这再一次证明了多子空间模型在处理复杂背景时的优势。准确的背景模型不仅可以取得良好的背景恢复效果，同时也会对目标检测有很大的帮助。除此之外，IPI 模型取得了次好的目标增强效果，同时 KR-CFAR 方法取得了次好的背景抑制效果。其余三种方法的表现不尽如人意。总体来说，传统的方法仅仅适用于处理一些特定的简单情况，而 SMSL 方法在不同场景下都可以有很好的效果。

表 4-10 3 组真实数据的平均信杂比增益

	Top-hat	Maxmedian	Maxmean	KR-CFAR	IPI method	SMSL
序列 1	1.04	1.65	0.82	1.06	0.73	2.95
序列 2	1.24	1.45	0.87	0.67	1.86	3.92
序列 3	2.52	3.09	2.23	1.53	5.10	10.78

图 4-7 展示了 6 种方法在 3 组真实数据中测试得到的 ROC 曲线图，对应的 AUC 见表 4-12。在第 1 组结果中，SMSL 方法取得了最好的效果，在 F_a 很低时，达到了很高的 P_d ，并且率先达到了 $P_d = 1$ 。对比 KR-CFAR 方法和 IPI 方法，SMSL 方法极大地提高了复杂背景下红外弱小目标的检测效果。在第 2 组结果中，SMSL 方

表 4-11 3 组真实数据的平均背景抑制因子

	Top-hat	Maxmedian	Maxmean	KR-CFAR	IPI method	SMSL
序列 1	0.90	3.32	3.08	4.06	2.31	7.20
序列 2	1.28	2.24	2.04	3.48	1.83	4.49
序列 3	0.66	3.75	3.50	8.22	4.10	20.19

法依旧取得了最好的效果，同时具有最高的 AUC 值。在第 3 组结果中，SMSL 方法和 IPI 方法都取得了效果很好的 ROC 曲线，但是如同第 1 组中一样，SMSL 方法率先实现了 $P_d = 1$ 。

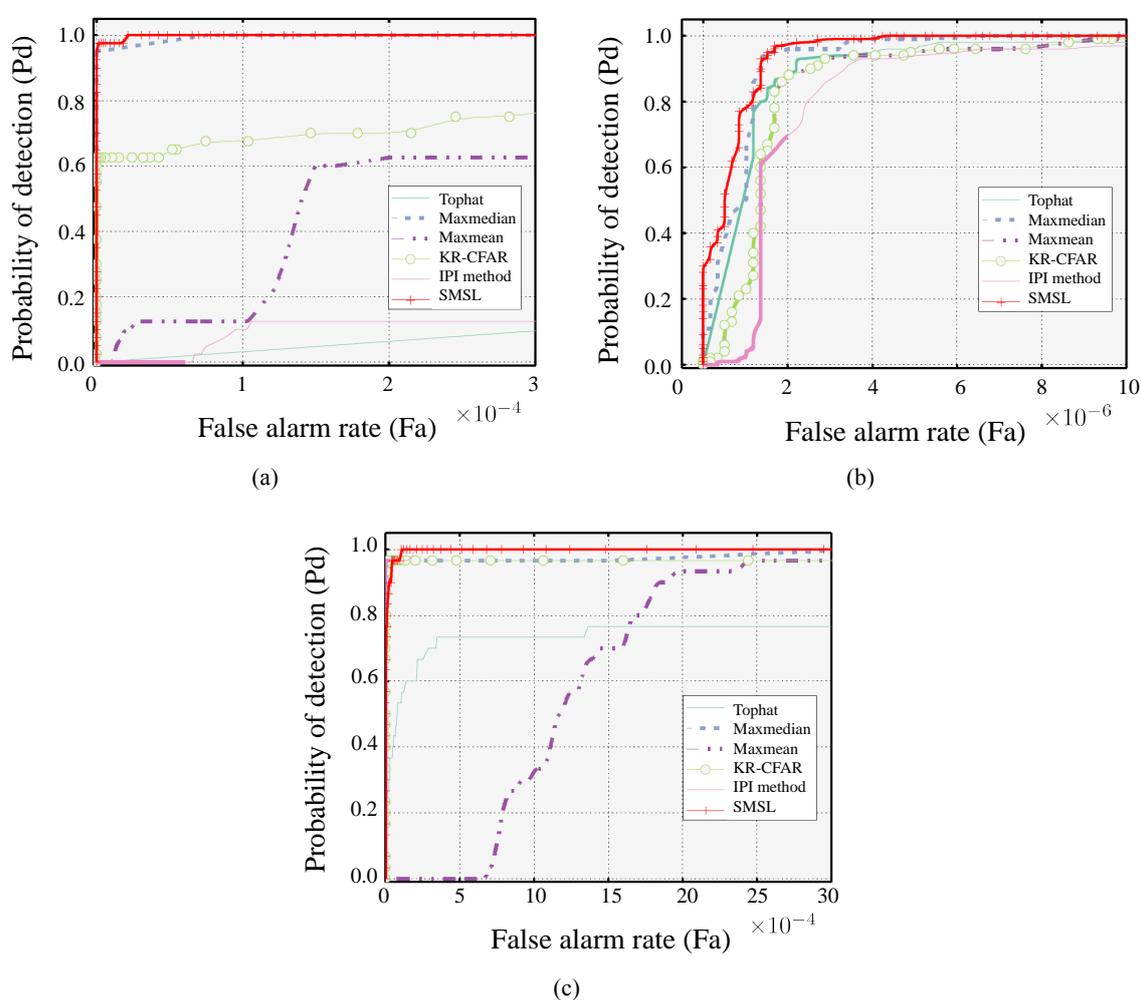


图 4-7 3 组实际数据的 ROC 曲线图。(a) 实际数据 1；(b) 实际数据 2；(c) 实际数据 3

综合上述实验及分析可以看出，与其他 5 种方法相比，本章提出的 SMSL 方法具有最好的检测效果。同时，其检测不依赖于特定的场景、目标类型抑或噪声程度。换言之，该方法非常适合于在多源复杂红外场景下进行目标检测。

表 4-12 实际数据 ROC 曲线的曲线下面积 ($\times 10^{-3}$)

	Top-hat	Maxmedian	Maxmean	KR-CFAR	IPI method	SMSL
序列 1	995.6596	999.9981	999.5033	999.7880	993.1990	999.9995
序列 2	999.9982	999.9991	999.9983	999.9875	999.9977	999.9994
序列 3	996.8214	999.9210	998.6675	997.6527	999.9939	999.9910

表 4-13 计算效率对比 (单位: s)

	Top-hat	Maxmedian	Maxmean	KR-CFAR	IPI method	SMSL
序列 1	0.03226	0.30701	0.36842	0.1987	8.08770	0.35780
序列 2	0.03400	1.10212	1.30563	0.6158	51.58740	0.70730
序列 3	0.03320	0.95656	1.12623	1.0272	33.30190	0.69500

4.3.4 计算效率测试

本节我们分析所提出方法的计算速度，并与其他方法进行对比。我们对比了上述进行测试的 6 种方法在 3 组实际数据中的计算效率，测试环境为 Matlab R2014b，采用了 8GB 内存以及 4G Hz 英特尔 i5 处理器。其结果见表 4-13。

从表 4-13中可以看出，Top-hat 滤波方法是计算效率最高的，但从上文的实验分析我们知道，该方法的检测效果不佳。IPI 方法耗时过多，且在多源复杂场景中表现不佳。本章所提出的SMSL方法的耗时与最大中值滤波，最大均值滤波以及 KR-CFAR 近似。在测试场景 1 中，SMSL方法的耗时介于最大中值滤波方法和最大均值方法之间；在测试场景 2 中，其测试数据的分辨率大于场景 1（见表 4-9），但SMSL方法的速度反而比最大中值以及最大均值滤波都快，但略微慢于 KR-CFAR。在测试场景 3 中，SMSL方法的计算效率高于上述三种算法。可以看出，SMSL方法的计算效率受测试图像的大小影响有限。

与近年提出的 IPI 方法相比，SMSL方法不仅采用了更加准确的多子空间模型，同时计算效率也显著提高。原因之一是在SMSL算法中，由于不采用核范数优化，因此避开了迭代计算 SVD 的过程；原因之二是在SMSL的数据建模过程中，数据块之间没有重叠，因此可以视为是对输入图像的像素的重排，并没有增大计算量。而在 IPI 模型中，需要数据块之间进行大量的重复，以保证背景图像的低秩性得到增强。

尽管在我们的实验中，所有的测试都是在单帧图像上进行的，但是由于我们得到了准确的背景估计，因此在场景变化不大的情况下，当前帧的背景可以被用作对下一帧背景的估计，这样可以减少下一帧的计算量。经过一定帧的运算之后，

再重启背景估计过程，可以得到稳定而快速的红外弱小目标检测。该方法旨在处理背景中包含一个甚至多个强辐射源的红外场景，在低空、近海面等极易受到人造物及其他强辐射源干扰的场景中可以取得很好的效果。

4.4 本章小结

本章首先介绍了子空间学习理论，讨论了基于子空间学习及聚类的低秩数据分析方法，接着提出了一种基于稳定多子空间学习的红外弱小目标检测方法。通过分析复杂红外背景，我们发现，很多情况下，红外背景中同样包含着强辐射源，会对弱小目标检测造成干扰。因此，我们采用多子空间学习的思路，准确分离出复杂多源红外背景，实现了快速而准确的红外弱小目标检测。实验结果表明，本章所提出的SMSL方法不依赖于特定的场景以及目标类型，具有良好的适应性，同时在检测效果以及计算效率之间达到了很好的平衡。

第五章 基于稀疏表示的红外弱小目标检测

5.1 红外图像稀疏表示理论

5.1.1 稀疏表示理论

信号的稀疏性 (Sparsity) 一直是信号处理的重要研究内容之一。在过去的数十年中, 稀疏表示 (Sparse Representation, SR) 在信号处理、图像处理、计算机视觉以及模式识别等领域中都起到了重要的作用^[126]。稀疏表示, 从起源上来讲, 与压缩感知 (Compressed Sensing, CS) 有着直接的关联。Donoho (2006) 首先提出了压缩感知的概念: 如果一个信号在某个域上可以被视为是稀疏的 (可压缩的), 就可以采用很少量的观测值来恢复该信号^[127]。随后 Candès 等 (2006) 从数学上证明了 CS 理论的合理性^[128]。上述这些理论共同奠定了压缩感知研究的基础, 此后大量相关的研究成果随之出现。一般来说, CS 理论包含三个基本的内容: 稀疏表示, 编码测量以及重构算法。而稀疏表示作为其中重要的一环, 渐渐脱颖而出, 得到了颇为广泛的关注和应用^[129-132]。但需要注意的是, 这并不是稀疏表示思想的起源, 仅仅是其得到广泛关注的时间点。

下面我们给出稀疏表示中所涉及到的基本数学理论。假设每一个样本 (向量) 的长度为 d , n 个这样的样本构成一个矩阵 $D \in \mathbb{R}^{d \times n}$ 。如果 D 中的样本可以用于将任何长度为 d 的向量进行线性表示, 且满足 $n > d$, 那么 D 就可以被称为一个过完备字典 (Over-complete Dictionary), 这之中的每一个样本则被称为原子 (Atom)。另一个重要概念是关于稀疏, 或者称为稀疏度 (Sparsity), 它所指的是向量或矩阵中非零元素占有所有元素的比例。如果非零元素所占的比例较高, 相应地, 该向量 (矩阵) 就可以被认为是稀疏的。稀疏表示问题的基本思想是: 对于给定的图像 (样本), 可以认为字典中存在一组原子, 使得输入的样本可以由该组原子进行线性组合而表示出来, 其中每个原子的表示系数就可以被用作重构信息。而这一组原子在所有原子中只占很少的比例, 因此待重构样本在字典上的表示系数可以被认为是稀疏的。假设待表示的样本为 $y \in \mathbb{R}^d$, 其可以被字典 D 中的原子线性表出, 即:

$$y = D\alpha \quad (5-1)$$

其中 $D = [d_1, d_2, \dots, d_n]$, $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_n]^T$ 为表示系数。由于 D 是一个过完备字典

典，若想得到稀疏的表示系数 $\hat{\alpha}$ ，则需要对其施加下述约束：

$$\hat{\alpha} = \arg \min \|\alpha\|_0, \text{ s.t. } y = D\alpha \quad (5-2)$$

这里采用 L_0 范数对系数进行稀疏约束，希望得到稀疏度高的表示。由于真实数据往往含有一定的噪声，即

$$y = D\alpha + s \quad (5-3)$$

这里 $s \in \mathbb{R}^d$ 表示噪声项，且其幅值满足 $\|s\|_2 \leq \varepsilon$ 。考虑到噪声影响，公式(5-2)可以转化为

$$\hat{\alpha} = \arg \min \|\alpha\|_0, \text{ s.t. } \|y - D\alpha\|_2^2 \leq \varepsilon \quad (5-4)$$

进一步地，根据拉格朗日乘子理论，一个合适的乘子 λ 可以用于平衡稀疏项和噪声约束，即

$$\hat{\alpha} = \arg \min L(\alpha, \lambda) = \arg \min \frac{1}{2} \|y - D\alpha\|_2^2 + \lambda \|\alpha\|_0 \quad (5-5)$$

这里 $\lambda > 0$ 。公式(5-5)所示的问题是一个典型的 NP 难解问题，是由于 L_0 范数具有的非凸的特性所导致的。相关研究表明，为了解决这个问题，可以用 L_1 范数代替 L_0 范数，进行凸松弛 (Convex Relaxation)，这样不仅可以方便求解，在一定程度上来说，也不会影响解的稀疏度^[133, 134]。即求解如下问题：

$$\hat{\alpha} = \arg \min L(\alpha, \lambda) = \arg \min \frac{1}{2} \|y - D\alpha\|_2^2 + \lambda \|\alpha\|_1 \quad (5-6)$$

至此，我们就给出了稀疏表示问题的一般构建方式。公式(5-6)所表示的问题是凸的，且有很多高效的求解工具箱可以对其进行直接求解，例如 NESTA^[135]。

5.1.2 稀疏表示在红外目标检测中的应用

稀疏表示自提出以来，在其基础上逐步发展出了很多重要的应用，其中包括图像分类问题。图像分类，简单来说，就是把一幅测试图像分类到预先设定好的类别 (Class) 中。神经科学的相关研究已经证明，对于自然图像而言，其在人类视觉系统中的成像就可以被视为一个稀疏表示的过程^[136]。在基于稀疏表示的分类 (Sparse Representation based Classification, SRC) 算法中，假设对于某一类别的图像，如果我们有足够数量的样本，就可以用它们去表示同一类别的测试图像^[137]。此外，SRC 方法在处理有干扰图像的分类问题时表现出了很强的鲁棒性。

我们考虑一个共有 J 个类别的分类问题。与 5.1.1 节中相同，假设字典 $D \in \mathbb{R}^{d \times n}$,

定义其子字典 $D_j \in \mathbb{R}^{d \times n_j}$ 为第 j 类样本所对应的列，这里 $j \in \{1, \dots, J\}$ ，且满足 $\sum_{j=1}^J n_j = n$ 。给定测试图像 $y \in \mathbb{R}^d$ ，其稀疏表示模型如公式(5-6)所示，求解得到稀疏表示系数 $\hat{\alpha}$ 。换言之，对于样本 y ，其类别标签可以通过下式确定：

$$\hat{j} = \arg \min_{j \in \{1, \dots, J\}} \|y - D_j \hat{\alpha}_j\|_F \quad (5-7)$$

即在每一个类别所对应的原子上进行重构，重构误差最小的那一类就是测试样本 y 的类别。

由于 SRC 方法具有抗噪性强、鲁棒性高的优异特性，它非常适合于对红外图像进行稀疏表示。直观地来看，红外目标检测可以被视为一个二分类问题：目标区域及非目标区域，因此可以采用 SRC 方法进行目标检测。J. Zhao 等（2011）提出了一种以稀疏表示思想为基础的红外弱小目标检测方法，构造过完备字典，同时评价指标采用了稀疏表示系数的集中度，判断出实际的目标区域^[138]。重庆大学李正周等（2014）提出了另一种基于在线字典学习的红外弱小目标检测方法，通过在线更新目标字典以及非目标字典，得到了较好的检测效果^[33]。

5.2 基于多任务联合稀疏表示的红外弱小目标检测

5.2.1 多任务联合稀疏表示理论

在诸多机器学习和计算机视觉问题中，待求解的问题往往分布在不止一个特征空间中。而在解决问题的过程中，将这种多特征的特性引入问题的求解可以带来较大优势，以及效果的提升。此外，不同的分类识别问题之间也可能共享一些特征。举例来说，当训练样本数量较少时，其他问题中所训练得到的结果可以被迁移到当前问题上来，从而达到多个问题共同优化的目的。这种新的训练方式及其思路直接催生了多任务学习（Multi-task Learning, MTL）问题的研究。

多任务联合稀疏表示及分类（Multi-Task Joint Sparse Representation and Classification, MTJSRC）是由 Yuan 等（2012）提出的一种多特征联合分类方法^[139]。这里的“多任务”指的是在合适的正则化参数约束下，同时估计多个线性表达式。例如，在目标识别中，如果我们采用 K 个不同的特征，如颜色、形状、纹理等，每一个特征都指向一个不同的线性表示问题。结合第 5.1.1 节中提到的稀疏表示理论，对于属于同一个分类标签的数据（在这里即为某一类图像），在有足够样本的情况下，测试图像可以被表示为同一类别内的样本的线性组合^[137]。MTJSRC 的主要思想是，找到不同特征所构成的样本库中所共享的信息，并用它们去表示同一个待分类的样本。由于不同的特征所得到的稀疏表示系数往往是不同的，也就是说，通过对不同的分类任务施加联合稀疏约束，可以获得单一任务所不具有的信息。

因此，这样的联合稀疏表示可以提高分类器的泛化性能，增加分类结果的鲁棒性。下面我们分别从多模态表示、联合稀疏正则化、分类准则以及求解方法四个方面来介绍 MTJSRC 理论。

5.2.1.1 多模态表示

首先考虑一般性的多模态表示问题。假设我们的训练集中有 J 类不同的样本，对于每个样本，其具有 K 个不同的特征模态，例如颜色、形状、纹理等。对于每个模态 k ， $D^k \in \mathbb{R}^{d_k \times n}$ 表示其对应的子字典， $D_j^k \in \mathbb{R}^{d_k \times n_j}$ 表示子字典 D^k 中的第 n_j 列，对应第 j 个类别。同时，我们假设测试样本可以表示为 $y = \{y^{kl} \in \mathbb{R}^{d_k}, k = 1, \dots, K, l = 1, \dots, L\}$ ，其中包含 L 个不同的实例。例如，对于人脸识别任务，每一个实例可以是不同视角下的人脸图像，它们都可以被训练样本中的 K 个模态所表示。考虑如下所示的 $K \times L$ 线性表示问题：

$$y^{kl} = D^k W^{kl} + \varepsilon^{kl}, \quad k = 1, \dots, K, \quad l = 1, \dots, L \quad (5-8)$$

这里 $W^{kl} \in \mathbb{R}^n$ 是 y^{kl} 的表示系数， $\varepsilon^{kl} \in \mathbb{R}^{d_k}$ 是残差项，可以被认为是独立同分布的高斯噪声。则表示系数 W^{kl} 可以通过如下的最小二乘模型来估计：

$$\min_W \left\{ f(W) := \frac{1}{2} \sum_{k=1}^K \sum_{l=1}^L \|y^{kl} - D^k W^{kl}\|^2 \right\} \quad (5-9)$$

这里 $W \in \mathbb{R}^{n \times KL}$ 是由 $K \times L$ 列系数向量 W^{kl} 构成的。从多任务学习的角度考虑，公式(5-9)可以被视为是由 $K \times L$ 个独立的最小二乘问题所构成的多任务回归模型，这也是多模态表示问题的基本结构。

5.2.1.2 联合稀疏正则化

上一节中给出了多任务回归模型的结构，但值得注意的是，公式(5-9)实际上是一组相互独立的最小二乘表示，即对于每一个实例的每一个模态，都去构建一个单独的字典表示问题，从而得到一组解，并未考虑实例与实例之间、模态与模态之间的关联性。为了将这种关联性引入目标识别任务中，Yuan 等（2012）提出了联合正则化的思路，通过引入新的结构稀疏诱导项，来实现类别层面的稀疏表示 [139]。

对于每一个测试样本 y^{kl} ，其在字典 D^k 中的表示系数向量可以被写为 $W^{kl} = [(W_1^{kl})^T, \dots, (W_J^{kl})^T]^T$ ，这里 $W_j^{kl} \in \mathbb{R}^{n_j}$ 表示该系数对应于类别 j 的部分。对于每个类别 j ，其表示系数可以写为 $W_j = [W_j^{11}, \dots, W_j^{KL}] \in \mathbb{R}^{n_j \times KL}$ ，这里考虑了不同的特征以及不同的样本实例。为了能更全面地考虑类别 j 内所有实例以及其所对应的所有

特征的关联性，我们对 W_j 进行 L_2 范数约束，其目的是尽可能地充分利用该类别内所有样本对应的不同实例以及不同特征，使得在稀疏表示的过程中尽可能选择属于相同类别的样本。通过这样的方式，可以得到类别层面的稀疏诱导项，定义为：

$$\Omega(W) := \left\| \left[\|W_1\|_F, \dots, \|W_J\|_F \right] \right\|_0 \quad (5-10)$$

为了恢复稀疏表示系数 W ，Obozinski 等（2009）提出如下的多任务联合稀疏表示模型^[140]：

$$\hat{W} = \arg \min_W \Omega(W), \quad \text{s.t. } f(W) \leq \varepsilon \quad (5-11)$$

或者等价地，求解下式

$$\hat{W} = \arg \min_W f(W) + \lambda \Omega(W) \quad (5-12)$$

这里 $f(W)$ 以及 $\Omega(W)$ 的定义参见公式(5-9)和公式(5-10)； λ 起到了平衡目标函数中的两项的作用。然而，由于式(5-10)中用到了 L_0 范数，公式(5-12)是一个 NP 难解问题。对其进行凸松弛，可以得到下式：

$$\hat{W} = \arg \min_W f(W) + \lambda P(W) \quad (5-13)$$

其中 $P(W)$ 定义为如下的 $l_{1,2}$ 范数：

$$P(W) := \sum_{j=1}^J \|W_j\|_F \quad (5-14)$$

根据相关的组优化理论^[141]，最小化 $P(W)$ 会使得解更倾向于 $\|W_j\|_F = 0$ ，即 $W_j = 0$ 。因此，求解式(5-13)依然可以实现对 $\{y^{kl}\}$ 稀疏表示的效果，且选取的原子会更多地反映出类别信息。因此，式(5-13)被称为稀疏表示中的多任务联合协同选择模型。

5.2.1.3 分类准则

根据上节，当我们求解得到最优表示系数矩阵 \hat{W} 之后，我们可以将样本 y^{kl} 重构为 $\hat{y}^{kl} = X_j^k \hat{W}_j^{kl}$ ，而该样本的分类结果则由下式给出：

$$\hat{j} = \arg \min_{j \in \{1, \dots, J\}} \sum_{k=1}^K \sum_{l=1}^L \|y^{kl} - X_j^k \hat{W}_j^{kl}\|^2 \quad (5-15)$$

即如果 $K \times L$ 个任务在某一类别的原子上表现出最小的重构误差，则判定这些实例属于该类别。因此，公式(5-13)与公式(5-15)所示的分类准则一起，被称为多任

务联合稀疏表示与分类问题。

5.2.1.4 优化求解方法

为了准确而快速地求解 MTJSRC 问题，这里采用加速近端梯度方法（Accelerated Proximal Gradient, APG）^[142,143]，其原理参见第2.3.2节。考虑到目标函数中包含有混合稀疏优化项，Yuan 等针对性地设计了采用 APG 算法求解 MTJSRC 问题的流程，具体见表 5-1^[139]。

表 5-1 基于 APG 的 MTJSRC 求解方法

输入：图像字典 $\{D^k | k = 1, \dots, K\}$ ，待测试样本 $\{y^{kl} | k = 1, \dots, K, l = 1, \dots, L\}$ ；正则化参数 $\lambda > 0$ ，步长 $\eta > 0$

输出：表示系数 $W^{(t)}$ ，类别估计结果 \hat{j}

1. 初始化：设 $V^{(0)} = 0$ ， $\alpha_0 = 1$ ， $t = 0$
2. **while not converge do**
3. 梯度映射：计算 $W^{(t+1/2)} = V^{(t)} - \eta \nabla f(V^{(t)})$ ，这里 $\nabla f(V^{(t)})$ 定义为

$$[\nabla f(V^{(t)})]^{kl} = -(D^k)' y^{kl} + (D^k)' D^k [V^{(t)}]^{kl} \quad (5-16)$$

4. 计算 $W^{(t+1)}$

$$W_j^{(t+1)} = \left[1 - \frac{\lambda \eta}{\| [W^{(t+1/2)}]_j \|} \right]_+ W_j^{(t+1/2)}, \quad j = 1, \dots, J \quad (5-17)$$

5. $\alpha_{t+1} = \frac{2}{t+3}$
6. 更新 $V^{(t+1)}$

$$V^{(t+1)} = W^{(t+1)} + \frac{(1 - \alpha_t) \alpha_{t+1}}{\alpha_t} (W^{(t+1)} - W^{(t)}) \quad (5-18)$$

7. 更新 $t = t + 1$
8. **end while**
9. 确定类别 \hat{j} : $\hat{j} = \arg \min_{j \in [1, \dots, J]} \sum_{k=1}^K \sum_{l=1}^L \| y^{kl} - D_j^k [W^{(t)}]_j^{kl} \|^2$

值得注意的是，对于上述算法而言，最佳收敛效果和最佳分类效果不一定是同时出现的。换言之，若想实现准确的分类，则不一定要使目标函数达到严格的

收敛；而当目标函数达到严格收敛时，此时的分类效果未必是最好的。这是由 MTJSRC 的目标函数所决定的。由公式(5-13)可以看出，该目标函数的目的是最小化样本的重构误差，而非训练一个最佳的分类器，因此在某些情况下目标函数的收敛与最优分类结果之间存在一定出入是正常的^[139]。此外，通过对算法复杂度的分析表明，该算法中，以第三步的耗时最为显著，其计算复杂度为 $O(KLnd_k)$ 。其余步骤的计算复杂度均较低。

5.2.2 基于 MTJSRC 的红外弱小目标检测方法

由第 5.2.1 节可以看出，MTJSRC 方法的优势在于可以充分利用待分类样本的不同特征，采用联合范数约束，使之共同作用于目标分类问题，从而得到更加准确的分类结果。对于红外弱小目标而言，由于其所占面积小、无颜色及明显的纹理特征等特点，本身就面临特征缺失的困境。如果采用传统的基于单一特征的稀疏表示方法，很容易造成分类不准确，即出现漏检和误检。因此在本节中，我们将多任务联合稀疏表示的分类方法引入红外弱小目标的检测之中，构建一种基于 MTJSRC 的检测模型，详细阐述了该方法如何应用于红外弱小目标检测，以及其相应的优势。

5.2.2.1 图像分块及分类任务构建

与一般的图像分类识别问题不同，弱小目标检测的目的是从动态复杂背景中提取红外弱小目标，换言之，即将一幅图像分为“目标区域”以及“非目标区域”。一个直接的思路是对图像进行分块处理，即将输入图像转化为一系列大小固定的待分类图像块，这些图像块的类别可以用于定位目标所在位置，判断背景区域。特别注意的是，这里采用有重叠分块方式，最大程度地避免因图像块大小以及滑动步长对样本造成的影响。

由第 5.1.2 节可知，现有的基于稀疏表示的红外弱小目标检测方法往往将其视为一个二分类问题，对于每一个输入的图像块，分类系统给出其是目标或者不是目标的判断。在我们的研究中发现，简单的二分类方式会带来很多问题，尤其是在面对复杂背景时。以图 5-1 为例，其中所展示的两张实例图像中均含有变化的背景，并非是均匀平滑的。这样的背景容易影响目标的判断，在简单的二分类系统中会导致大量误检。基于上述原因，我们提出将红外背景进一步细化分类为“平滑背景”以及“变化背景”两个类别，用以捕捉复杂背景和目标之间的区别，这样就构建了一个基于三分类问题的红外弱小目标检测模型。

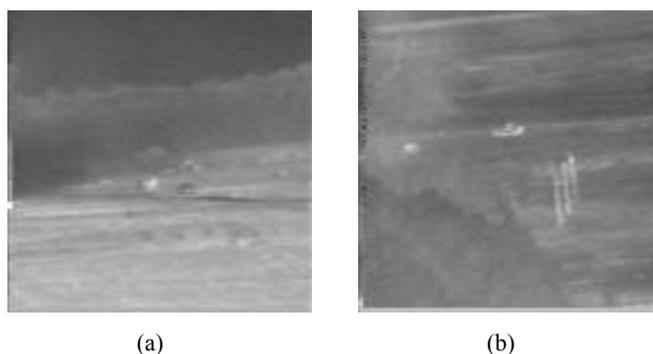


图 5-1 复杂背景红外图像示意图。(a) 场景 1；(b) 场景 2

5.2.2.2 特征选取

对于红外目标和背景样本而言，单一特征难以全部描述其性质。例如，假设我们采用亮度特征，则不能很好地区分明亮的背景和目标；假设我们采用边缘特征，则无法很好地区分变化的背景和目标。因此我们需要结合多种特征来获得鲁棒性强的分类结果，在这样的要求下，MTJSRC 可以完成这一目标。对于每一个样本而言，我们可以提取多种特征对其进行描述和分类。

在特征选择方面，需要考虑哪些特征可以更好地区分红外弱小目标和多变的背景。首先，红外弱小目标往往是图像中的局部最大值（这里只考虑亮目标的情况）；其次，由于其局部对比度较高，一般可以提取到相对完整的边缘信息，且梯度的统计特征还可以用于区分弱小目标与变化的背景；最后，由于弱小目标面积较小，其内部的亮度变化往往不明显，而背景则不尽然。根据以上分析，我们最终选取了四组特征构建多特征字典，分别是：灰度特征，边缘特征，方向梯度直方图（Histogram of Oriented Gradient, HoG）特征，以及原始图像的灰度直方图特征。具体特征提取方式如下：

1. 灰度特征

灰度特征，顾名思义，即为图像块的灰度。假设某图像块 $s(x,y) \in \mathbb{R}^{m \times n}$ ，则其灰度特征定义为：

$$f_{Grey} = \text{vec}[s(x,y)] \quad (5-19)$$

这里 vec 表示将输入的块图像进行列向量化，则 $f_{Grey} \in \mathbb{R}^{mn \times 1}$ 。

2. 边缘特征

这里采用 Canny 算子^[144]提取样本的边缘信息，再对结果进行列向量化：

$$f_{Edge} = \text{vec}\{\text{Canny}[s(x,y)]\} \quad (5-20)$$

这里 $f_{Edge} \in \mathbb{R}^{mn \times 1}$ 。

3. HoG 特征

HoG 特征是由 Dalal 等 (2005) 提出的一种图像特征描述子, 在目标检测中取得了成功的应用^[145]。方向梯度直方图, 顾名思义, 就是计算图像中的梯度信息, 并统计其方向分布。其计算过程简要介绍如下: 对于待处理的图像块 $s(x, y) \in \mathbb{R}^{m \times n}$, 首先将其划分为大小为 $p \times q$ 的元胞 (Cell), 在每个元胞中, 统计方向梯度直方图。在统计过程中, 将所有梯度方向划分为 N 个条带, 统计每一个条带所对应的方向范围内的梯度值之和, 就得到了一个长度为 N 的元胞描述子。

随后, 对于相邻的 $M \times M$ 个元胞, 将其组合成为一个结构块 (Block), 对于图像块内的 M^2 个元胞所对应的方向梯度直方图特征, 将其视为一个整体, 采用 L_2 范数归一化, 即得到了长度为 $N \times M \times M$ 的结构块描述子。

最后, 对于待处理的图像 $s(x, y)$, 将结构块在其上有重叠地滑动, 滑动步长为 N 。若边界处无法构成一个完整的结构块, 则将其舍弃。最后得到的 HoG 特征为:

$$f_{HoG} \in \mathbb{R}^{\text{floor}(m/N) \times \text{floor}(n/N) \times NMM} \quad (5-21)$$

这里 floor 表示向下取整函数。可以看出, HoG 特征的长度不仅与图像块的大小有关, 还与计算过程中所选取的参数有关, 这里我们取元胞大小 $N = 9$, 结构块大小 $M = 2$ 。

4. 灰度直方图特征

为了更好地表征图像块中灰度的分布情况, 我们引入灰度直方图特征来进一步描述每个待分类的图像块。由于我们所处理的红外图像均为灰度图像, 其灰度值的范围是 $[0, 255]$ 。我们将其统计入 9 个条带中, 得到灰度直方图特征为:

$$f_{Hist} \in \mathbb{R}^{9 \times 1} \quad (5-22)$$

至此, 我们就完成了对于每一个红外图像块进行特征提取的过程, 上述四种特征共同构建了多任务联合字典。

5.2.2.3 求解方法

Yuan 等构建了一种基于 APG 的 MTJSRC 求解方法^[139]。由公式(5-13)以及(5-14)可以看出, 为了求解方便, 将稀疏选择步骤中原本的 L_0 范数凸松弛为 L_1 范数。但在实际中, L_1 范数仍然具有一定的多解性, 这是由其解空间的形态所决定的。而在稀疏选择问题中, 我们希望所选择出的样本是相对固定的, 这样会使得分类结果更鲁棒。

Mohimani 等 (2009) 提出了一种稀疏表示的快速求解方法, 称为平滑 L_0 范数 (Smoothed L_0 norm, SL0) [146]。Mohimani 等在该文献中指出, L_0 范数在应用中所遇到的问题, 包括其难解性以及其对噪声非常敏感的特性, 很大程度上是来源于 L_0 范数的非连续性。因此, 该文章提出将 L_0 范数近似为一个连续的函数, 表示如下:

$$\|s\|_0 \approx m - F_\sigma(s) \quad (5-23)$$

$$F_\sigma(s) = \sum_{i=1}^m f_\sigma(s_i) \quad (5-24)$$

这里 f_σ 表示可以用作稀疏近似的函数族 (其具体表达式见后文), σ 则表示该函数与 L_0 范数的近似程度, m 表示向量 s 的长度。当 $\sigma \rightarrow 0$ 时, 公式(5-23)左右两边完全相等。因此, 当 σ 取很小的值时, 最小化 L_0 范数的问题可以被转化为最大化 $F_\sigma(s)$ 的问题。同时, σ 的大小决定了 F_σ 的平滑程度: 当 σ 越大, 则函数 F_σ 越平滑, 但其与 L_0 范数的近似程度会降低; 反之, 当 σ 越小, F_σ 这个函数的平滑程度降低, 但其可以更好地近似 L_0 范数。

当 σ 较小时, F_σ 是高度非平滑的, 因此其包含很多的局部最大值, 使得 F_σ 的求解变得困难。当 σ 较大时, F_σ 的平滑性增强, 其包含的局部最大值变少, 因此更容易求解得到真正的最大值。因此, 这里采用一组逐渐减小的 σ 来对函数 F_σ 进行逐步搜索, 搜索结果会越来越接近 F_σ 在参数 σ 很小时的局部最大值情况, 即真实的 L_0 范数的最小值点 [146]。这就是平滑 L_0 范数的主要思想。

f_σ 可以用如下几种不同的函数来表示, 例如:

$$f_\sigma = \exp\left(\frac{-s^2}{2\sigma^2}\right) \quad (5-25)$$

或者

$$f_\sigma = \begin{cases} 1, & |s| \leq \sigma \\ \frac{(\sigma+s)}{\sigma}, & -\sigma \leq s \leq 0 \\ \frac{(\sigma-s)}{\sigma}, & 0 \leq s \leq \sigma \end{cases} \quad (5-26)$$

又或者

$$f_{\sigma} = \begin{cases} 1, & |s| \geq \sigma \\ 1 - (\frac{s}{\sigma})^2 & |s| \leq \sigma \end{cases} \quad (5-27)$$

可以看出，上述定义的 f_{σ} 均满足如下条件：

$$\lim_{\sigma \rightarrow 0} f_{\sigma}(s) = \begin{cases} 1, & s = 0 \\ 0, & s \neq 0 \end{cases} \quad (5-28)$$

或者近似地，满足

$$f_{\sigma} \approx \begin{cases} 1, & |s| \ll \sigma \\ 0, & |s| \gg \sigma \end{cases} \quad (5-29)$$

因此可以得出结论，凡是满足公式(5-28)以及(5-29)的函数，它们均可以用作 SL0 中关于向量 s 的稀疏程度的反向近似。更多的 f_{σ} 的定义形式参见文献 [146]。

作为 L_0 范数的连续函数近似，SL0 具有一些优势，例如计算速度快、求解精度高，特别适合于稀疏表示问题的求解。在红外弱小目标检测中，各个样本之间差异相对较小，且灰度图像不具有颜色信息，需要算法很好地选择样本。因此，我们提出用 SL0 方法求解多任务联合稀疏表示问题，以实现更加准确的目标检测，我们称之为 MTJSRC-SL0，其求解算法如表 5-2 所示。

5.2.2.4 算法流程

综合上述内容，基于 MTJSRC 以及 MTJSRC-SL0 的红外弱小目标检测算法流程如图 5-2 所示，这里以单个图像块的分类为例，两种方法的区别仅仅在于联合稀疏表示求解方式的不同。

对于一整幅输入的红外图像，我们采取有重叠滑窗的方式得到一系列图像块，并将其列向量化，如图 5-3 所示。这里图像块的大小与训练样本一致，滑动步长设置为 5 个像素，在水平和垂直方向保持一致。

最后，鉴于一幅图像中很可能会存在一个以上的图像块被判定为目标，我们提取这些图像块的重叠区域，作为最终的弱小目标检测结果，如图 5-4 所示。

表 5-2 MTJSRC-SL0 求解方法

输入: 图像字典 $\{D^k k = 1, \dots, K\}$, 待测试样本 $\{y^{kl} k = 1, \dots, K, l = 1, \dots, L\}$; 一组下降的 σ 数值序列, 即 $[\sigma_1, \dots, \sigma_M]$ 输出: 表示系数 $W^{(t)}$, 类别估计结果 \hat{j}
1. 初始化: $\hat{W}_j = D^{k-1} y^{kl}$, 这里 D^{k-1} 是 D^k 的伪逆矩阵。 2. for $m = 1, \dots, M$: 3. 令 $\sigma = \sigma_m$ 4. 用最速下降法求解 F_σ 的最大值: 5. $W^{(t)} = W^{(t-1)}$ 6. for $q = 1, \dots, Q$ 7. 令 $\delta = [W_{j(1)} \exp(-W_{j(1)}/2\sigma^2), \dots, W_{j(n)} \exp(-W_{j(n)}/2\sigma^2)]$ 8. $W_j = \mu\delta$ 9. 反向投影: $W_j \leftarrow W_j - D^{kT}(D^k D^{kT})^{-1}(D^k W_j - y^{kl})$ 10. end for 11. $\hat{W}_j = W_j$ 12. end for 13. 输出 $W_j = \hat{W}_j$ 14. 确定类别 \hat{j} : $\hat{j} = \arg \min_{j \in [1, \dots, J]} \sum_{k=1}^K \sum_{l=1}^L \ y^{kl} - D_j^k [W^{(t)}]_j^{kl}\ ^2$

5.3 实验与结果分析

5.3.1 样本库构建

由第 5.2.2 节中我们提到, 为了更好地处理弱小目标检测问题, 我们构建了三类样本: 目标样本、平滑背景以及变化背景。在实际中, 对于每一个类别, 我们又分别构建了三个大小分别为 15×15 , 21×21 以及 25×25 个像素的样本, 为了描述方便, 我们将其命名为 A、B、C 组。此外, 为了构建完备字典, 同时使得字典中的样本可以覆盖尽可能多的目标以及背景的形态, 我们采用人工合成样本的方式, 进一步充实了各个样本库。对于目标样本库而言, 我们采用现有的红外弱小目标正演方法, 即通过模拟不同形态、不同分布、不同信噪比的目标, 得到与实际红外弱小目标非常相似的样本, 以用作数据分析、场景模拟等^[124]。对于平滑背景, 我们通过模拟产生一系列平滑分布的数据样本, 并加入不同程度的噪声扰动, 模拟实际的红外平滑背景图像块。对于变化的非平滑背景, 我们的目标主要是通过模拟产生一些含有明显边缘特征的样本, 用以对实际收集到的变化样本进行补充和完善。图 5-5、5-6 和 5-7 分别展示了目标、平滑背景以及变化背景所对应的样本库中的部分样本, 其中包括真实样本与模拟产生的样本, 在构建样本库以

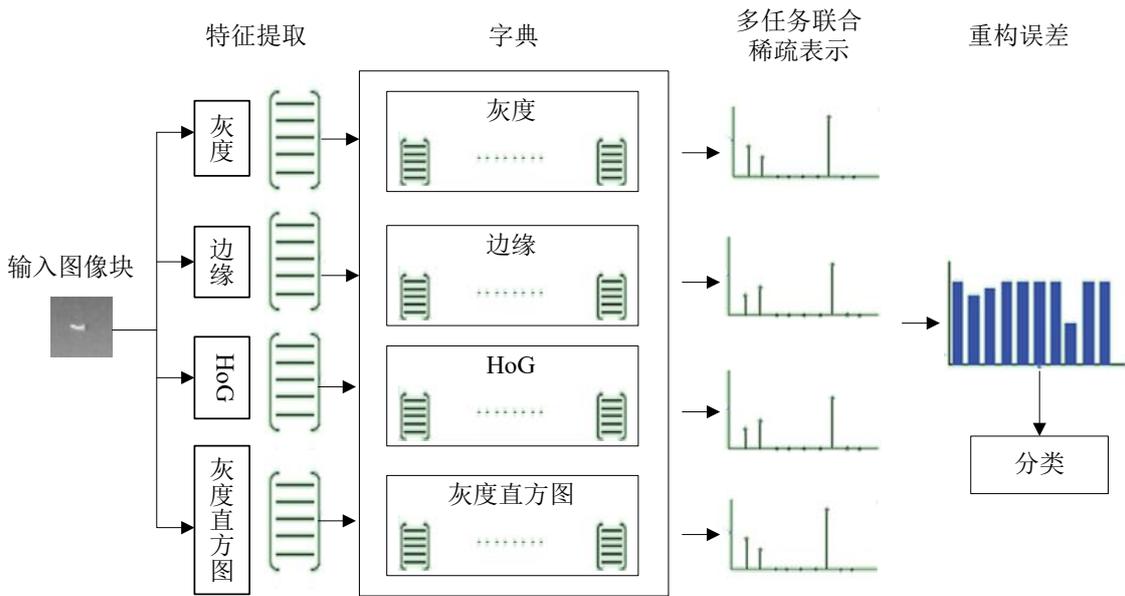


图 5-2 基于 MTJSRC/MTJSRC-SL0 的单个红外图像块分类识别流程图

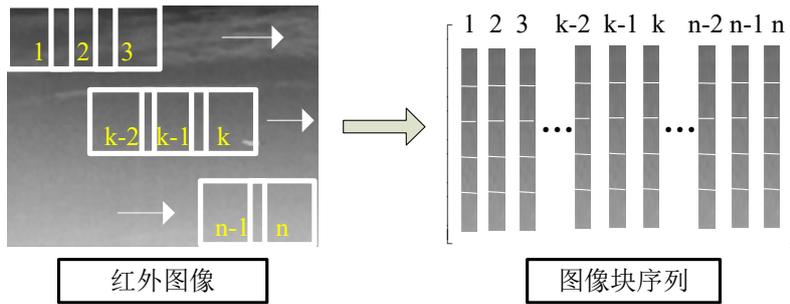


图 5-3 窗口滑动及图像块提取流程图

及后续稀疏表示时不再进行区分。考虑到实际红外目标的大小为 $2 \times 2 - 9 \times 9$ 个像素，一般不超过 11×11 个像素，在测试中我们采用 **B** 组样本构建字典，**B** 组样本的大小为 21×21 。这样既可以保证样本块中包含完整的目标，也可以尽量避免因为窗口滑动步长等原因引起的漏检和误检。这里，我们所构建的 **B** 组样本库中共包含 1705 个样本，参考上文所述的四种特征的提取方式可以知道，这里所得到的对应于不同特征的过完备字典大小分别为：灰度特征字典 $D^1 \in \mathbb{R}^{441 \times 1705}$ ，边缘特征字典 $D^2 \in \mathbb{R}^{441 \times 1705}$ ，HoG 特征字典 $D^3 \in \mathbb{R}^{144 \times 1705}$ 以及灰度直方图特征字典 $D^4 \in \mathbb{R}^{9 \times 1705}$ 。

5.3.2 评价指标

首先，我们介绍基于图像块稀疏表示和分类的红外弱小目标检测的评价方式。与传统的基于滤波以及基于矩阵分解的检测方法不同，基于稀疏表示的检测方法

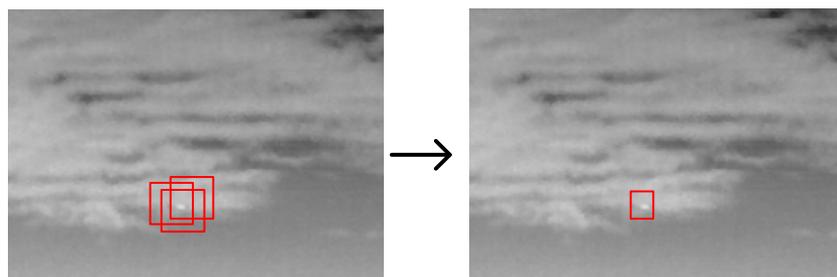


图 5-4 弱小目标检测结果判定示意图

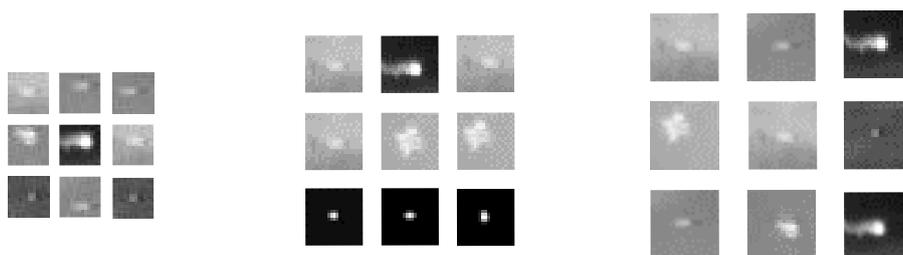


图 5-5 目标样本库中的部分样本。从左至右依次为：A 组，B 组，C 组

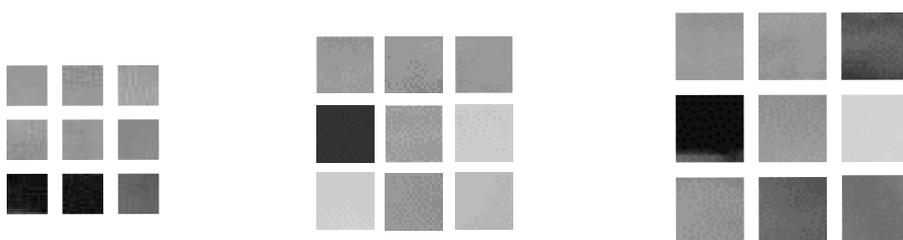


图 5-6 平滑背景样本库中的部分样本。从左至右依次为：A 组，B 组，C 组

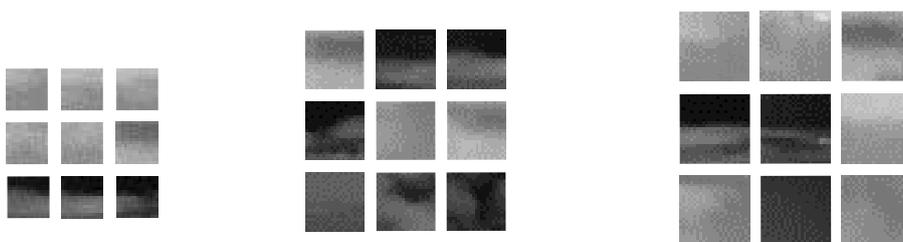


图 5-7 变化背景样本库中的部分样本。从左至右依次为：A 组，B 组，C 组

往往以图像块的方式来进行目标与非目标的判断，即检测结果是一系列包含目标或者非目标区域的的图像块。在本章的算法中，该图像块的大小是预先设定的，与训练样本的大小一致。

因此，我们提出用检测率（Probability of Detection, P_d ）和虚警率（False Alarm Rate, F_a ）来对该类算法进行评价。检测率，顾名思义，即为检测到的目标数量占

总目标的百分比，定义与公式(3-37)相同，即：

$$P_d = \frac{TD}{AT} \quad (5-30)$$

这里 TD 表示实际检测到的目标数量， AT 表示测试序列中真实存在的目标数量。而虚警率定义为被误认为目标的虚警区域的像素点个数与总像素点个数的比例，与公式(3-38)相同，即：

$$F_a = \frac{FD}{NP} \quad (5-31)$$

这里 FD 以及 NP 分别表示虚警区域中的像素个数以及测试序列中的总像素个数。

值得注意的是，如果输出图像块中包含或部分包含目标，则认为目标被检测到，该图像块为正确检测到目标的图像块，不认为是虚警；如果某输出图像块中完全不包含任何目标信息，则认为其是虚警，此时计算该图像块的面积，作为虚警率的统计。这是为了尽可能多地保留包含目标的区块，以便后续确定目标的中心位置及分布情况。

此外，由于基于稀疏表示的检测机制与传统方法不同，难以将此类方法与常用的基线方法进行比较，例如 Top-hat 滤波，最大中值/均值滤波等。故而本节中未将这些基线方法纳入评价。

5.3.3 检测结果与分析

我们选取 5 组测试数据来验证基于 MTJSRC 的分类方法在红外弱小目标检测中的效果，以及加入了平滑 L_0 求解之后的改进效果。这 5 组测试序列包含不同场景下的不同类型和大小的目标，具体信息见表 5-3。其中，序列 4 为公开的红外弱小目标检测数据集，其余数据为合作单位提供。序列 1 是一幅天空场景，包含变化的云层以及明亮的人工建筑物干扰，且噪声污染较严重，其中包含有单个形状不规则的目标；序列 2 是一幅天空及云层场景，背景的亮度在一个大的范围内变化，目标较小，呈点状，且对比度低；序列 3 是一幅明亮的天空场景，在某些区域中有丰富的细节，目标形状不规则，且在运动过程中带有旋转；序列 4 是一幅具有显著云层杂波的场景，属于典型的非均匀非平滑背景，目标是一架大小随时间变化的飞机，其成像距离较长；序列 5 可以看作是一幅平滑背景，但其中有明显的、形状较为固定、呈圆弧形干扰，场景中存在一定的椒盐噪声，目标是单个明亮的飞行物。本节中所有的测试均在 MATLAB R2014b 环境下完成，采用了配置有 8GB 内存以及 4G Hz 英特尔 i5 处理器的计算机。

我们比较了 MTJSRC 方法和本章提出的 MTJSRC-SL0 方法在上述 5 组测试序

表 5-3 测试场景描述

序号	帧数 (frames)	分辨率 (pixels)	背景	干扰物	目标个数	运动状态
1	31	128 × 128	天空	云层及人工建筑物	1	动态
2	40	128 × 128	天空	云层	1	动态
3	100	240 × 320	天空	云层	1	动态
4	30	200 × 256	天空	云层	1	动态
5	100	504 × 632	天空	明亮的圆弧状干扰	1	动态

列中的检测效果，各组测试序列的代表性图片及其检测结果直观展示如图 5-8 所示。可以看出，总体来说，两种方法都可以检测到目标，但都具有不同程度的虚警，这是由于背景的复杂程度及背景中所包含的干扰因素决定的。在序列 1 的检测结果中，可以看出虚警主要是由明亮的干扰物体的边缘决定的，分类器将某些包含明亮物体的图像块误认为目标；在序列 2 到 4 的检测结果中，某些云层杂波会对检测结果造成干扰。在序列 5 中，由于该场景含有椒盐噪声，虚警主要由椒盐噪声引起，采用针对性的滤波可以解决该问题。

表 5-4 展示了 5 组测试场景在 MTJSRC 算法以及 MTJSRC-SL0 算法处理下的检测率和虚警率结果。可以看出，在序列 1 到 3 中，两种方法都实现了 100% 的检测率，但在虚警率方面，基于 SL0 求解的算法明显优于传统 APG 求解，受到复杂背景的干扰更少。在序列 4 中，两种算法都没有能够完全检测到所有目标，但基于 SL0 求解的方法检测率高于传统 MTJSRC 算法。同样地，在序列 5 中，MTJSRC-SL0 检测到了所有的目标，但 MTJSRC 算法产生了漏检。尽管在虚警率方面，MTJSRC 略优于 MTJSRC-SL0，但 MTJSRC 丢失了目标信息，在实际应用中容易引起“硬误差”，即丢失目标等较为严重的后果。总体来说，该方法是一种基于数据和样本驱动的方法，在有足够样本的情况下，可以适应多种场景下的目标检测。

表 5-4 检测率及虚警率结果

	P_d		F_a	
	MTJSRC	MTJSRC-SL0	MTJSRC	MTJSRC-SL0
序列 1	1.000	1.000	0.477	0.416
序列 2	1.000	1.000	0.018	0.010
序列 3	1.000	1.000	0.052	0.045
序列 4	0.833	0.933	0.006	0.005
序列 5	0.960	1.000	0.064	0.067

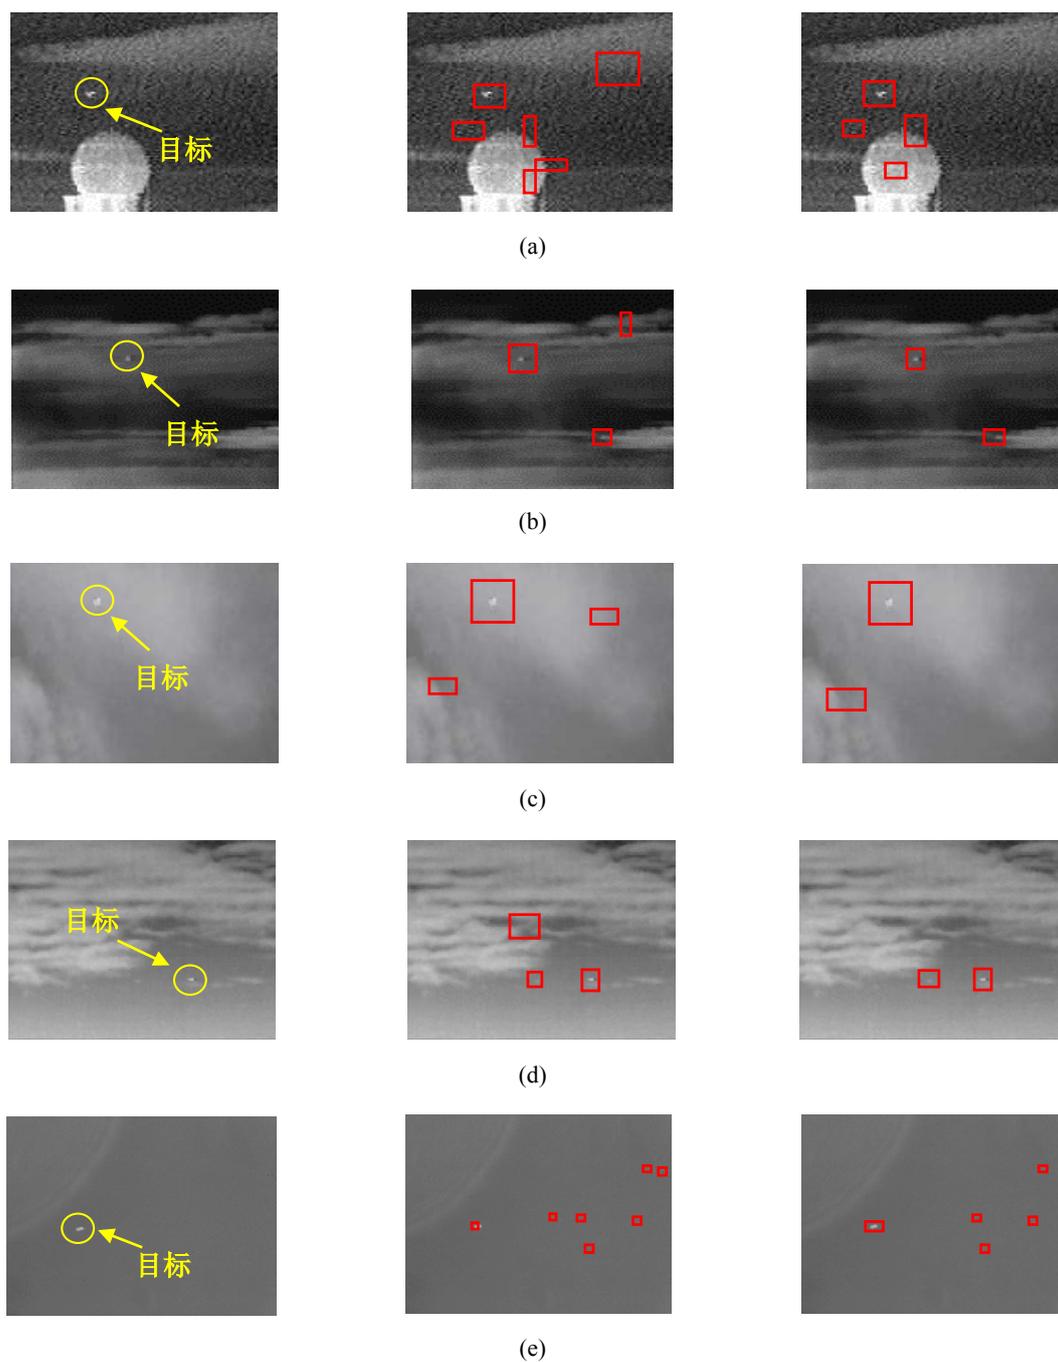


图 5-8 红外弱小目标检测结果，从左到右依次为：原图，基于 MTJSRC 的检测结果，以及基于 MTJSRC-SL0 的检测结果。(a) 序列 1 检测结果；(b) 序列 2 检测结果；(c) 序列 3 检测结果；(d) 序列 4 检测结果；(e) 序列 5 检测结果

5.4 本章小结

本章首先介绍了稀疏表示理论及其在红外弱小目标检测中的应用，其次介绍了一种基于多任务联合稀疏表示的图像分类方法。随后，我们提出了一种基于

MTJSRC 的红外弱小目标检测算法，以及采用 SLO 求解的 MTJSRC-SLO 算法。通过构建包含目标区域、平滑背景区域以及变化背景区域的样本库，并采用灰度、边缘、HoG 以及灰度直方图等特征作为对样本的描述，我们成功地构建了基于 MTJSRC 以及 MTJSRC-SLO 的红外弱小目标检测框架，在不同场景以及不同目标的测试序列中取得了较好的效果。同时我们也注意到，噪声以及云层杂波会对检测结果造成一定干扰，这是由于这些干扰成分有着与目标相似的分布，在后续研究中采用更丰富的样本库可以一定程度上解决这个问题。

第六章 基于变分模态反演的红外弱小目标检测

6.1 模态分解与变分理论

信号的频带分解是信号处理研究中的一个重要问题。从复杂信号中提取具有某些特定性质的分量，可以帮助我们了解该信号的性质，同时也利于信号的分析处理。本节介绍基于模态分解的信号分析理论，包括经验模态分解以及近年发展的变分模态分解，这些方法可以被视为信号的显微镜，使我们得以探知信号的本征特性。

6.1.1 经验模态分解

模态分解指的是将信号分解为具有不同性质的分量的过程。如果采用频率分量来定义模态，则模态分解就可以被理解为将信号分解为不同的频率分量的过程。最常用的模态分解方法包括经验模态分解（Empirical Mode Decomposition, EMD）以及在此基础上发展而来的改进算法。EMD 是由 N. Huang 等人（1998）提出的一种递归分解方法，将信号分解为一系列本征模态函数（Instinct Mode Function, IMF）以及残余项^[147]。在这里，模态即为 IMF，可以定义为如下的调频调幅信号：

$$u_k(t) = A_k(t) \cos(\varphi_k(t)) \quad (6-1)$$

这里 $A_k(t) \geq 0$ 表示信号的振幅， φ_k 表示信号的相位，是一个非衰减函数。该信号的瞬时频率可以定义为：

$$\omega_k(t) = \frac{\partial \varphi_k(t)}{\partial t}, \quad \omega_k(t) \geq 0 \quad (6-2)$$

换言之，在一段一定长度的时间间隔 $[t - \delta, t + \delta]$ 内，这里 $\delta \approx 2\pi/\omega_k(t)$ ，当前模态信号 $u_k(t)$ 可以被视为一个纯粹的谐波信号，其振幅为 $A_k(t)$ ，瞬时频率为 $\omega_k(t)$ 。直观来说，IMF 的主要性质包括：（1）该函数至少具有两个极值点，其中包括一个极大值点，以及一个极小值点；（2）信号的零点个数 p 与极值点个数 q 满足 $|p - q| \leq 1$ 。

EMD 的实现方法是递归地检测信号中的局部极大/极小值，结合插值方法，首先得到信号的上下包络；对信号的上下包络求平均值，将该平均值视为当前的低通中心线；随后从原信号中减去该低通中心线，即分离出信号中的“高频”部分，希望剩余量是一个满足条件的 IMF。重复此过程，直到达到停止条件，提取出所有满足条件的 IMF，递归过程结束，也就得到了信号的 EMD 分解结果。由于 EMD

方法具有突出的频带分解能力，其被广泛地应用于信号分析领域，包括地震信号处理^[148]，图像分解^[149]，声学信号处理等^[150]。

由上述算法描述可知，EMD 方法的效果极大地依赖于极值点位置计算，插值方法的选择以及停止条件的设定。值得注意的是，该方法没有严格的数学基础，即并没有理论保证其收敛性以及信号模态分解的完备性，这仅仅是一种“经验”分解方法。尽管有研究者提出了一些 EMD 的改进算法^[151,152]，但其理论基础的缺失依然限制了 EMD 方法的进一步发展及应用。

6.1.2 变分模态分解

由于 EMD 方法在实际中存在一定的缺陷，K. Dragomiretskiy 等（2014）提出了一种变分模态分解方法（Variational Mode Decomposition, VMD）方法，包括一维 VMD 以及二维 VMD^[153,154]。VMD 是一种具有很强自适应性的、用于进行信号频带分解的方法，其目的是将输入信号分解为一系列具有特定性质的子信号，称为模态。对于每一个子信号，作者希望其具有窄带频率分布，即频率成分分布在其中心频率附近一个很小的范围内，近似一个脉冲信号，每一个模态的中心频率是在分解过程中自适应确定的。

以一维信号为例，VMD 问题的构建方式如下：假设输入信号为 $f(t)$ ，待求的信号分量为 $u_k(t)$ ，这里 k 代表第 k 个子信号，首先计算 $u_k(t)$ 的解析信号 $\alpha_k(t)$ ，这里用到了希尔伯特变换：

$$\alpha_k(t) = \left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \quad (6-3)$$

其中 $\delta(t)$ 为脉冲信号， j 为虚数单位。接下来，将该解析信号进行频移，移动量为预估的中心频率数值，得到新信号 $A_k(t)$ ：

$$A_k(t) = \alpha_k(t) e^{-j\omega_k t} \quad (6-4)$$

这里 ω_k 为估计得到的子信号 $u_k(t)$ 的中心频率。随后估计 $A_k(t)$ 的带宽，记为 W_k ：

$$W_k = \|\partial_t A_k(t)\|_2^2 \quad (6-5)$$

对于所有的子信号分量，通过最小化各个分量的带宽之和，可以反演求解得到一系列满足条件的窄带子信号，实现自适应信号分解，这就是 VMD 的分解过程，描述如下：

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\}, \quad \text{s.t.} \quad \sum_k u_k(t) = f(t) \quad (6-6)$$

这里 u_k 表示所有的信号分量, ω_k 表示每一个信号分量的中心频率。根据第2.3.2节中的介绍, 该问题可以通过 ADMM 方法进行求解^[153]。

上面描述了 VMD 的算法原理及流程, 该算法可以将信号分解为一系列带限的本征模态函数。与传统的 EMD 方法相比, VMD 不需要对本征模态函数做出严格的假设, 相反, 这里采用调频-调幅信号来描述每一个本征模态函数, 其定义更加明确。但是需要注意到, 在 VMD 中我们需要预先设定好参数 K , 即要分解出的信号分量的个数, 随后才可以进行自适应本征模态函数分解, 这是 VMD 与 EMD 的另一处不同, 同时也是 VMD 过程不够灵活的一个方面。在 VMD 中, 每一个子信号 $u_k(t)$, 或者说模态, 都是严格的带限信号, 这样可以保证子信号的频带之间没有交叠。但与此同时, 由于目标函数中在计算带宽时采用了 L_2 范数约束, 会导致子信号的频带边界过度平滑。总体而言, VMD 实现了一定程度上的自适应信号本征模态分解, 同时具有较严格的理论基础, 在应用中可以取得很好的效果。VMD 以及其二维形式被广泛应用于去噪, 图像分类等方面^[155, 156]。

6.2 非负约束变分模态分解红外弱小目标检测

在第2.1节以及第2.2节的分析中我们知道, 红外背景以及弱小目标有着截然不同的性质, 表现在大小、形态、灰度分布等方面。从频域分析的角度来看, 背景, 包括背景中的不同区域, 弱小目标以及噪声, 这些不同的部分具有不同的频率分布特性。而弱小目标检测则是要利用不同部分之间的特征差异, 从而抑制背景和噪声, 增强目标。空域弱小目标检测方法往往利用目标与背景的灰度、视觉显著性等差异, 而频域方法则利用目标与其他部分的频率差异。通常认为红外弱小目标是红外图像中的高频部分^[157], 利用该先验信息, 可以采用高通滤波, 得到图像中的高频信息, 即弱小目标信息^[158]。但高通滤波具有一些局限性, 例如, 滤波器往往需要一些预先设定的参数, 难以根据实际情况自适应调整; 同时, 高通滤波极易受噪声以及变化的背景的影响, 容易出现误检。

上一节我们介绍了 VMD 方法, 同时, 我们可以将 VMD 扩展为二维的形式: 二维 VMD 可以自适应地将输入的二维信号分解为数个带限于信号, 从而展现二维信号的精细结构。据此, 本节我们提出一种基于非负约束二维 VMD 的红外弱小目标检测方法 (Nonnegativity-constrained Variational Mode Decomposition, NVMD), 利用变分模态分解算法可以进行窄带信号分解的优良性质, 自适应地对输入图像进行分解。通过对多个窄带信号的分析, 剔除其中的背景杂波及噪声, 保留单纯的目标成分, 实现红外弱小目标检测^[159]。在多个数据集上的实验验证了该方法的有效性和鲁棒性。

6.2.1 模型构建

与本文中所述的其他方法类似，含红外弱小目标的图像可以被认为是一个加性模型，包括目标、背景及噪声，即：

$$f(x,y) = f_T(x,y) + f_B(x,y) + f_N(x,y) \quad (6-7)$$

这里 $f(x,y)$ 表示输入图像， $f_T(x,y)$ 、 $f_B(x,y)$ 以及 $f_N(x,y)$ 分别表示目标图像、背景图像以及噪声，这里 (x,y) 表示图像的行/列索引。根据我们在第二章中的分析，在频率域中，相对于目标和噪声，背景往往占据了图像中频率较低的部分，而目标所占的频率成分往往高于背景，这是由于目标面积小而亮度高，因此在图像中表现为局部灰度值变化较大。噪声的情况则较为复杂，但为了简化研究，一般认为噪声占据了图像中最高的频带。

NVMD 方法是基于二维 VMD 的红外弱小目标检测方法，其中，核心步骤是利用二维 VMD 对图像进行窄带信号分解，以分离出目标成分。首先，对输入图像进行预处理，这里选用带通滤波器，其目的是为了滤除图像中最低频率和最高频率的成分，只保留中间的频率成分，即去除最平滑的背景成分以及最高频的成分，包括噪声。这样可以保证滤波结果是严格带限的，避免干扰后续的窄带信号分离过程，同时去除一些不相干的成分可以使得信号的分解更有效率。

带通滤波器有很多不同的种类，图 6-1 展示了理想带通滤波器、巴特沃斯带通滤波器、高斯带通滤波器以及高斯差分滤波器（Difference of Gaussian, DoG）的转移函数，这也是带通滤波器的核心特征，其形状和性质是由相应的参数决定的。可以看出，不同的带通滤波器之间的差别并不显著，但理想带通滤波器容易造成震荡的边界，因此不适用于该问题。其余带通滤波器均可以用于进行预处理工作。下面我们选用 DoG 滤波器作为预处理手段，用于去除 0 频率直流分量以及高频干扰。假设输入图像为 $f(x,y)$ ，滤波后的图像记为 $f'(x,y)$ 。

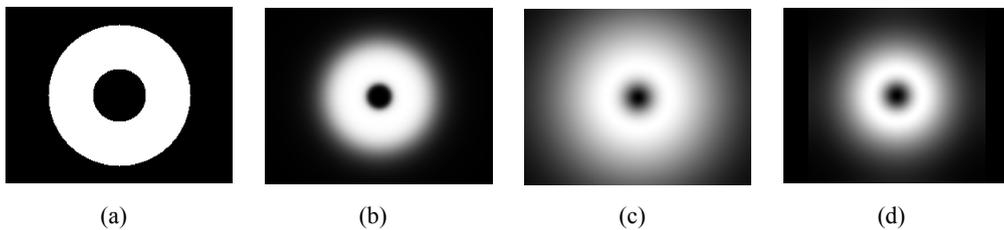


图 6-1 四种带通滤波器的转移函数示意图。(a) 理想带通过滤波器转移函数示意图；(b) 巴特沃斯带通滤波器转移函数示意图；(c) 高斯带通滤波器转移函数示意图；(d) 高斯差分滤波器转移函数示意图

为了进一步验证加入带通滤波做预处理的必要性，图 6-2 展示了一幅含有弱小目标的红外图像直接进行二维 VMD 分解的结果以及进行预处理后再采用二维 VMD 分解的结果。可以看出，在不经预处理图像分解结果中，模态 1 中包含的是近似直流成分，是平滑背景区域；模态 2 中虽然可以观测到目标成分，但可以看到在图像的边缘处有明显的震荡成分；模态 3 中也可以观测到目标成分，但同样有震荡干扰。并且很明显，目标能量被分散在了多个模态中，不利于目标提取。采用预处理后，再次对其进行二维 VMD 图像分解，可以看出，目标分量集中在最低模态中，且干扰很小，利于目标提取。这也进一步印证了预处理步骤的重要性和必要性。

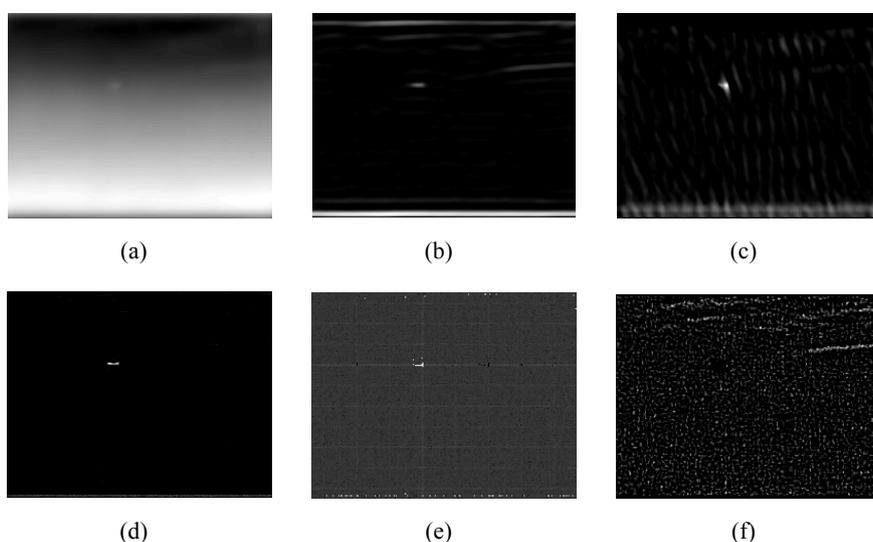


图 6-2 二维 VMD 分解结果。(a) 不经过预处理的图像分解得到的模态 1；(b) 不经过预处理的图像分解得到的模态 2；(c) 不经过预处理的图像分解得到的模态 3；(d) 经过预处理的图像分解得到的模态 1；(e) 经过预处理的图像分解得到的模态 2；(f) 经过预处理的图像分解得到的模态 3

随后我们构建 NVMD 的数学模型。由于红外弱小目标占据了图像的中间频带，同时，有 $f_T(x,y) > 0$ ，即具有非负性。假设经过预处理的红外图像 $f'(x,y)$ 可以被分解为 K 个子信号 $u_k(x,y)$ ， $k = 1, \dots, K$ 。 $u_k(x,y)$ 的二维解析信号可以写为：

$$u_{AS,k}(\mathbf{x}) = u_k(\mathbf{x}) * \left(\delta(\langle \mathbf{x}, \mathbf{e}_k \rangle) + \frac{j}{\pi \langle \mathbf{x}, \mathbf{e}_k \rangle} \right) \delta(\langle \mathbf{x}, \mathbf{e}_{k,\perp} \rangle) \quad (6-8)$$

这里我们用 \mathbf{x} 对二维坐标索引 (x,y) 进行简写， $*$ 是卷积符号， δ 是二维脉冲函数， \mathbf{e}_k 是单位向量，可以指代任何需要的方向。解析信号没有负频率，其频率的分布是普通信号的一半。

计算出 $u_k(\mathbf{x})$ 的解析信号之后，我们将其进行频率移动，移动量等于预先估计出的子信号中心频率 ω_k ，即 $u_{AS,k}(\mathbf{x})e^{-j(\omega_k, \mathbf{x})}$ ，其带宽 B_k 可以写为：

$$B_k = \left\| \nabla \left(u_{AS,k}(\mathbf{x}) e^{-j(\omega_k, \mathbf{x})} \right) \right\|_F^2 \quad (6-9)$$

通过最小化 B_k 之和，可以直观地求解得到各个子信号 $u_k(\mathbf{x})$ ， $k = 1, \dots, K$ 。

现在我们对子信号引入非负约束，其目的主要包括两个方面。首先，在弱小目标检测任务中，包含弱小目标的信号是我们首要考虑的目标。在预处理过程中采用带通滤波器是去除杂波的第一步，目标在该步骤中被完整地保留下来，因此，其非负性也同样被保留，即在 $f'_T(\mathbf{x})$ 中依然满足 $f'_T(\mathbf{x}) > 0$ 。其次，非负约束是我们根据待分解信号所提出的一种经验性约束。图 6-3 展示了直接对预处理后的图像 $f'_T(\mathbf{x})$ 进行二维 VMD 分解的结果。以子信号 $u_1(\mathbf{x})$ 为例， $u_1(\mathbf{x})$ 的正数部分中包含了我们所需要的目标信号以及一些杂波，而负数部分则大都是无意义的杂波以及一些震荡，不能表征信号的有效成分。该观测表明，对子信号加入非负约束可以迫使分解出的信号分量包含尽可能少的杂波，从而使得有效信号可以更明确地凸显出来。

根据上述分析，NVMD 的目标函数定义如下：

$$\begin{aligned} \min_{u_k, \omega_k} & \left\{ \sum_k \left\| \nabla [u_{AS,k}(\mathbf{x}) e^{-j(\omega_k, \mathbf{x})}] \right\|_F^2 \right\} \\ \text{s.t. } & \forall \mathbf{x} \geq 0; \left\| f'(\mathbf{x}) - \sum_k u_k(\mathbf{x}) \right\|_F^2 < \varepsilon \end{aligned} \quad (6-10)$$

这里 ε 代表着重构误差。

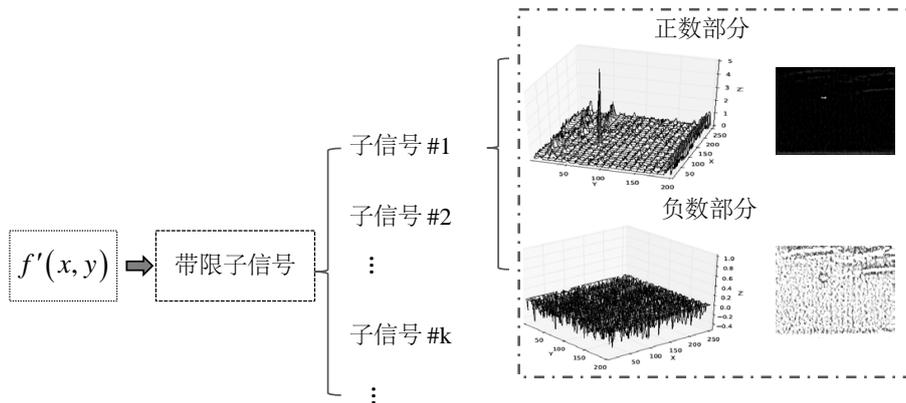


图 6-3 对 $f'(x, y)$ 直接进行二维 VMD 分解的结果示意图

6.2.2 求解方法

至此，我们构建了 NVMD 方法的目标函数，如公式(6-10)所示，该问题可以采用 ADMM 方法求解（参见第2.3.2节）。算法流程见表 6-1。值得注意的是我们引入非负约束的方式，即步骤 8。ADMM 是一种循环求解的算法，这里我们通过每次循环过程中将分解得到的子信号的负数部分去掉的方式来保证其非负性。这样，正数的部分将会被保留，并进入下一次循环计算过程，可以进一步地减小当前子信号的带宽。但这样会导致一个问题：分解出的子信号无法完全重构出原信号。但考虑到 NVMD 方法的目的并非严格的信号重构，而是从中提取出我们所需要的信息，因此这里的循环停止条件采用预先设定的最大循环次数 N 。在我们的实验中， $N < 10$ 即可取得很好的效果，一般取 $N = 8$ 。

表 6-1 基于 ADMM 的 NVMD 求解方法

输入：预处理后的红外图像 $f'(\mathbf{x})$ ，预先设定的子信号个数 K
输出：分解得到的子信号 $u_k(\mathbf{x})$ ， $k = 1, \dots, K$
1. 初始化： $u_k(\hat{\mathbf{x}}) = 0$ ， $\omega_k(\hat{\mathbf{x}}) = 0$ ， $n = 0$
2. while $n < N$ do
3. for $k = 1 : K$ do
4. $H_k^{n+1}(\boldsymbol{\omega}) = 1 + \text{sgn}(\langle \boldsymbol{\omega}_k^n, \boldsymbol{\omega} \rangle)$
5. 更新 $\hat{u}_{AS,k}$ ：
$\hat{u}_{AS,k}^{n+1}(\boldsymbol{\omega}) = H_k^{n+1}(\boldsymbol{\omega}) \left[\frac{\hat{f}(\boldsymbol{\omega}) - \sum_{i < k} \hat{u}_i^{n+1}(\boldsymbol{\omega}) - \sum_{i > k} \hat{u}_i^n(\boldsymbol{\omega}) + \frac{\hat{\lambda}_k^n(\boldsymbol{\omega})}{2}}{1 + 2\alpha \boldsymbol{\omega} - \boldsymbol{\omega}_k^n ^2} \right]$
6. 更新 ω_k ：
$\boldsymbol{\omega}_k^{n+1} = \frac{\int_{R^2} \boldsymbol{\omega} \hat{u}_{AS,k}^{n+1}(\boldsymbol{\omega}) ^2 d\boldsymbol{\omega}}{\int_{R^2} \hat{u}_{AS,k}^{n+1}(\boldsymbol{\omega}) ^2 d\boldsymbol{\omega}}$
7. 在时域中求解 u'_k ：
$u_k^{n+1}(\mathbf{x}) = \mathcal{R} \left\{ \mathcal{F}^{-1} \hat{u}_{AS,k}^{n+1}(\boldsymbol{\omega}) \right\}$
8. 加入非负约束：
$\forall \mathbf{x}, u_k^{n+1}(\mathbf{x}) = \begin{cases} u_k^{n+1}(\mathbf{x}) & \text{if } u_k^{n+1}(\mathbf{x}) \geq 0 \\ 0 & \text{if } u_k^{n+1}(\mathbf{x}) < 0 \end{cases}$
9. end for
10. $\hat{\lambda}^{n+1}(\boldsymbol{\omega}) = \hat{\lambda}^n(\boldsymbol{\omega}) + \tau \left(\hat{f}(\boldsymbol{\omega}) - \sum_k \hat{u}_k^{n+1}(\boldsymbol{\omega}) \right)$
11. $n = n + 1$
12. end while
13. $u_k(\mathbf{x}) = u_k^n(\mathbf{x})$ ， $k = 1, \dots, K$

至此，我们提出了完整的 NVMD 方法，基于 NVMD 的弱小目标检测流程见

图 6-4。简单来说，该算法分为三步：

- (1) 对输入的红外图像采用带通滤波器进行预处理，得到 $f'(x, y) \in \mathbb{R}^{m \times n}$ ；
- (2) 采用 NVMD 方法将 $f'(x, y)$ 分解为 K 个窄带信号 $u_k(x, y)$, $k = 1, \dots, K$ ，从中提取出包含潜在目标的子信号 $u_{\text{target}}(x, y) = u_1(x, y)$ 。其余子信号中包含了更多的高频振荡信息，故而被舍弃。
- (3) 采用阈值分割作为后处理方法，从 $u_{\text{target}}(x, y)$ 中分离出目标，完成目标定位及检测。这里的分割阈值可以自适应决定。

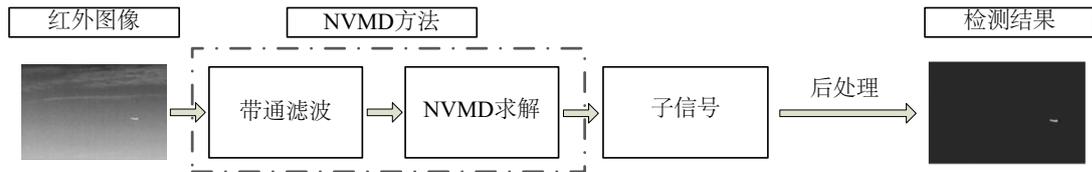


图 6-4 基于 NVMD 的红外弱小目标检测算法流程

6.3 实验与结果分析

为了验证 NVMD 算法的有效性以及效率，本节我们采用实际数据进行了算法测试。基于 NVMD 的红外弱小目标检测算法中包含着一些重要的参数，首先我们给出这些参数的取值。在预处理中，我们采用 DoG 滤波器对输入图像进行带通滤波，DoG 中两个高斯函数的方差分别为：

$$\sigma_1 = 0.5; \quad \sigma_2 = 2.0 \quad (6-11)$$

此外，在公式(6-10)中，另一个重要参数是重构误差 ε 。由于加入了非负约束，损失了一部分子信号中的能量，因此该重构误差不宜过小。我们在这里根据场景的不同，取 $\varepsilon = 1e - 3$ 或 $5e - 4$ 。同时在上一节中已经提到，循环次数 $N = 8$ 。

我们采用 6 组实际数据对 NVMD 算法进行测试，测试数据的具体信息见表 6-2。该 6 组测试序列均由合作单位提供。序列 1 中展示了一组背景较为干净的天空场景，有一定的流云及噪声干扰，目标呈长条状，在场景中从右至左运动；序列 2 同样是一组天空场景，但云层干扰很严重，目标在场景中缓慢运动，且出现一定的闪烁；序列 3 依然是一组天空场景，但其云层干扰程度介于序列 1 和序列 2 之间，目标较为明亮；序列 4 是一组信噪比极低的天空场景，看不出具体的干扰物，但噪声较重；序列 5 是一组特殊的天空场景，包含一个圆弧形的干扰物，除此之外背景较为干净；序列 6 是一组低空场景，有植物等背景杂波干扰，目标面积很小。

表 6-2 六组模拟数据的基本信息

序号	帧数 (frames)	背景描述	干扰物描述	目标个数	运动状态
1	40	天空	云层	1	动态
2	100	天空	云层	1	动态闪烁
3	50	天空	云层	1	动态
4	50	天空	云层/噪声	1	动态闪烁
5	50	天空	圆弧形干扰/噪声	1	动态
6	50	低空	植物等	1	动态闪烁

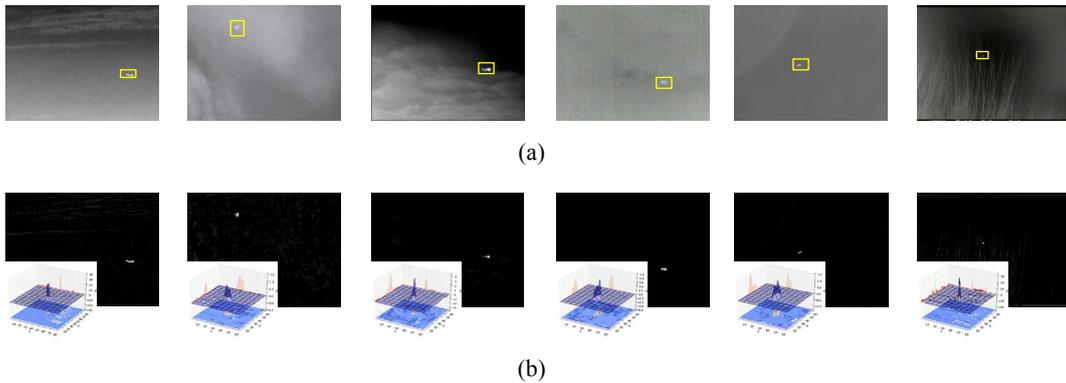


图 6-5 测试序列代表性图片以及 NVMD 方法检测结果。(a) 测试序列 1 到 6 中的代表性图片；(b) 对应的 NVMD 检测结果及目标周围局部邻域三维投影图

图 6-5展示了上述每组数据中的代表性图片以及 NVMD 方法的检测结果。可以看出，NVMD 方法的检测结果呈现清晰、干净的特点，检测结果中，只含有少量或者不含有任何杂波干扰，目标得到了很好的突出。从局部三维投影中同样可以看出，目标周围的背景被抑制地非常干净，利于目标提取及跟踪。

为了进一步验证 NVMD 方法的效果，这里引入 5 种其他方法作为对比，分别是：传统 Top-hat 滤波方法，自适应巴特沃斯高通滤波方法（Adaptive Butterworth High-pass Filter, ABHPF）^[158]，基于最小二乘自适应支持向量机（Least-square Support Vector Machine, LS-SVM）的方向高通滤波方法^[160]，基于核的非参数回归方法（Kernel-based Nonparametric Regression），根据原作者的写法，将其简记为 KR-CFAR^[12]，以及基于相位谱的四元组傅里叶变换（Phase Spectrum of Quaternion Fourier Transform, PQFT）方法^[18]。在评价指标方面，与第3.3.2节中相同，我们采用信杂比增益 G_{SCR} ，背景抑制因子 BSF 以及检测率 P_d ，虚警率 F_a ，且定义方式全部与第3.3.2节中描述相同。

表 6-3和表 6-4分别展示了包括 NVMD 在内的六种测试方法在六组测试序列

中的信杂比增益和背景抑制因子结果。可以看出，在 G_{SCR} 方面，NVMD 方法在测试序列 1 到 5 中都达到了最好的效果；在测试序列 6 中，LS-SVM 算法的信杂比增益最高，NVMD 方法次之。而对于 BSF，在测试序列 2 到 6 中，NVMD 方法取得了最好的背景抑制效果；在测试序列 1 中，LS-SVM 方法的背景抑制因子高于 NVMD 方法。综合上述两组数据可以看出，在大部分序列中，NVMD 可以在信杂比增益和背景抑制因子两个方面都取得很好的效果，仅仅在少数测试序列中，在某个指标上被个别方法超越。

表 6-3 6 组测试序列的平均信杂比增益 ($\overline{G_{SCR}}$)

	Top-hat	ABHPF	LS-SVM	KR-CFAR	PQFT	NVMD
序列 1	4.0907	3.3776	1.9978	0.9974	4.5409	4.6144
序列 2	2.0979	2.0440	1.1265	0.8334	2.0524	3.6152
序列 3	2.9106	0.9925	5.2317	1.0536	3.0275	5.9209
序列 4	1.5703	2.0937	1.0403	0.2930	1.7337	4.9755
序列 5	1.0074	1.0506	1.2013	0.2088	1.3048	1.3134
序列 6	1.3594	1.7690	2.7101	0.6292	1.0775	2.5353

表 6-4 6 组测试序列的平均背景抑制因子 (\overline{BSF})

	Top-hat	ABHPF	LS-SVM	KR-CFAR	PQFT	NVMD
序列 1	9.7581	6.7916	134.6170	9.2509	51.5555	56.6139
序列 2	12.0404	10.7980	74.4708	10.8794	25.2831	737.8575
序列 3	13.1325	1.0044	9.0771	6.6287	32.8696	311.6139
序列 4	2.6486	3.2007	31.0763	3.0979	23.4065	47.0275
序列 5	1.8060	2.1207	9.1319	1.9865	3.7970	40.8632
序列 6	2.9762	3.8166	3.1882	3.4700	14.5046	24.4592

图 6-6 展示了六组测试序列中各个方法的 ROC 曲线。尽管在各个序列中，NVMD 方法的检测效果有一些区别，但是可以看出，该方法的检测效果好于其它方法，可以在虚警率很低时达到最高的检测率。

此外，表 6-5 中展示了对应于图 6-6 的曲线下面积 (Area Under Curve, AUC) 的数值。可以看出，在全部六组测试序列中，NVMD 方法的曲线下面积都是最大的，这也印证了 NVMD 方法的检测效果。

图 6-7 展示了六种测试方法在六组测试序列中的计算耗时，图中不同的颜色表示了不同算法测试一幅图像的平均时间。测试环境为 8 GB 内存的 Intes i5 处理器，测试在 MATLAB R2014b 环境下进行。可以看出，NVMD 方法的计算速度略慢于

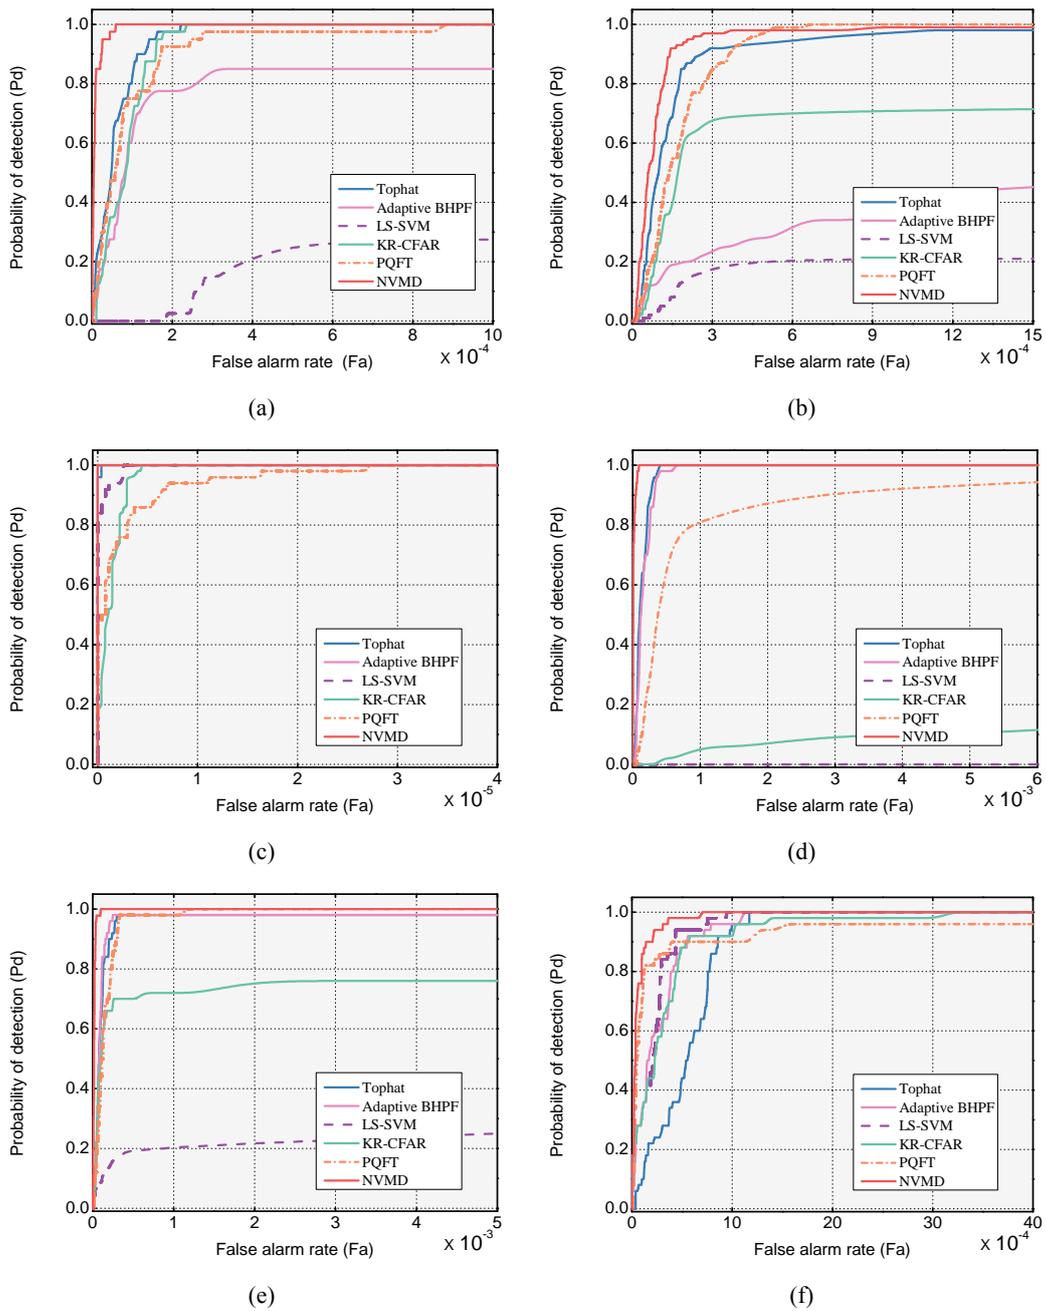


图 6-6 六组测试序列的 ROC 曲线图。(a) 序列 1 的 ROC 曲线图；(b) 序列 2 的 ROC 曲线图；(c) 序列 3 的 ROC 曲线图；(d) 序列 4 的 ROC 曲线图；(e) 序列 5 的 ROC 曲线图；(f) 序列 6 的 ROC 曲线图

Top-hat 方法以及 LS-SVM 方法，快于其他的方法，总体来说，可以满足实际应用中对计算效率的要求。

另外需要指出的一点是，本节中所采用的测试序列大部分为天空场景，其中一些场景中具有云层和噪声的干扰，根据第 2.1 节中的分析，云层场景在某些情况

表 6-5 六组测试序列的 AUC 数值 ($\times 10^{-3}$)

	Top-hat	ABHPF	LS-SVM	KR-CFAR	PQFT	NVMD
序列 1	999.94	999.30	730.17	999.92	999.91	999.99
序列 2	999.70	970.02	631.64	860.88	99.83	999.87
序列 3	1000.00	1000.00	1000.00	1000.00	1000.00	1000.00
序列 4	999.87	999.84	387.95	691.81	997.17	999.99
序列 5	998.38	983.85	619.44	876.58	999.85	999.98
序列 6	999.47	999.74	999.73	999.67	999.56	999.93

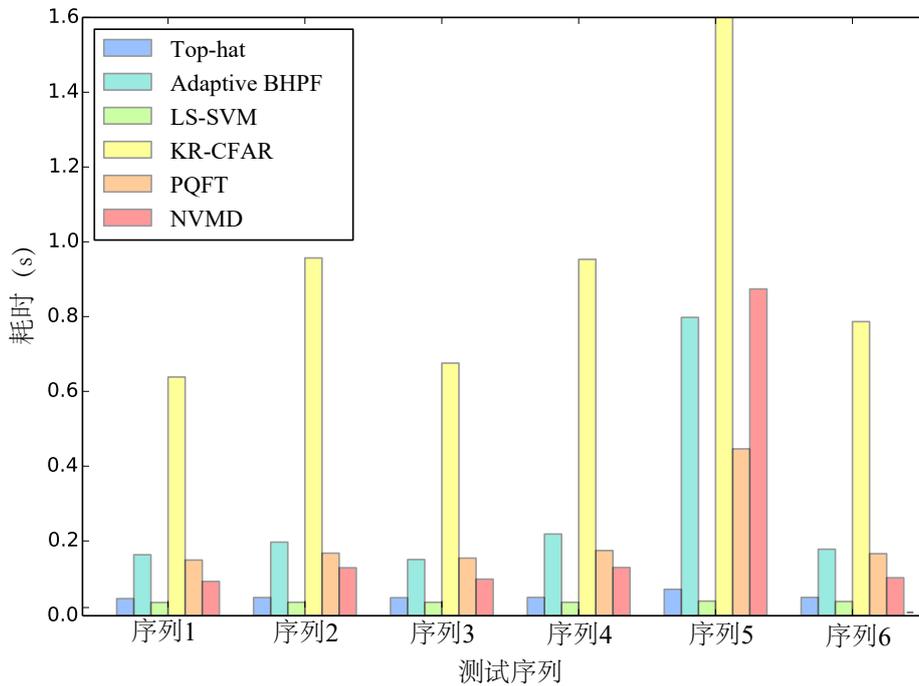


图 6-7 不同方法在六组测试序列中的耗时对比 (单位: s)

下较为复杂, 但大部分情况下, 在云层干扰不严重时, 天空背景的灰度分布较为均匀, 适合于采用 NVMD 进行窄带信号分解, 分离出弱小目标。这也反映出了 NVMD 方法的局限性, 在非常复杂的环境下, 信号的频谱分布变得更复杂, NVMD 方法的使用会带来一些问题。但 NVMD 可以在其适用的范围内取得比其他方法更好的效果, 这是其优势。

6.4 本章小结

本章首先介绍了传统的信号模态分解方法, 分析了其在实际应用中的缺陷。随后介绍了一种近年提出的自适应模态分解方法——变分模态分解, 该方法可以

将一维及二维带限信号自适应地分解为一系列窄带信号的集合。随后我们基于此提出了一种基于非负约束变分模态分解的红外弱小目标检测算法，简称为 NVMD 方法。首先预处理输入的红外图像，滤除最低频的信号以及最高频的噪声成分，随后采用非负约束变分模态分解方法对预处理后的信号进行自适应分解，目标信号就在分解出的窄带信号中，可以采用简单的阈值分割提取出目标信号。实验证明，NVMD 方法可以在保证计算效率的同时，取得很好的检测效果，非常适用于天空场景及低空场景下的弱小目标检测。

第七章 基于显著性的红外弱小目标检测

7.1 显著性检测理论

人类视觉系统 (Human Visual System, HVS) 的基本能力之一是在复杂系统中快速定位感兴趣的物体或信息, 该过程即为显著性检测 (Saliency Detection) [161]。显著性检测方法一般分为两类, 自顶向下 (Top-down) 的方法 [162] 以及自底向上 (Bottom-up) 的方法 [163]。自顶向下的方法采用图像特征进行显著性描述, 一般分为特征提取和显著性计算两个步骤; 自底向上的方法则基于生物视觉感知结构相关的研究, 简单来说, 可以理解为一个快速定位与周边区域不同的区域的过程, 采用的特征包括颜色、纹理、形状等。近年来有研究表明, 某区域与周边区域的对比度可以认为是视觉系统感知内容时最重要的信息之一 [20], 与此同时, 在动态场景中, 人眼更倾向于关注那些运动的部分而非静止背景 [164]。显著性检测的处理结果可以为后续更高级别的计算机视觉任务研究提供可靠的关于感兴趣区域的信息, 因此, 被广泛地应用于目标检测、识别、跟踪等方面 [165, 166]。

近年来, 显著性检测方法逐渐被引入红外弱小目标检测领域, 取得了一系列成果。根据红外弱小目标的特殊性, 常用的显著性检测方法可以被分为空域显著性、频域显著性和时域显著性方法。空域显著性即为利用红外弱小目标亮度较高、与周围背景相比对比度较高的特点, 采用基于 HVS 机制的算法用以突出这一性质, 最终实现目标检测。代表性算法包括 C. Chen 等 (2014) 提出的基于局部对比度的算法 [20], 以及 J. Han 等 (2014) 提出的改进型局部对比度算法 [167]。除此之外, DoG 滤波器也是一种常见的用以描述人眼的对比度机制的方法, 可以用来进一步突出红外弱小目标, 典型的方法包括 X. Wang 等 (2012) 提出的 DoG 结合赢家通吃以及返回抑制策略的红外弱小目标检测算法 [168], 以及 X. Dong 等 (2014) 提出的结合对比度机制以及高斯滤波的红外弱小目标检测算法 [19]。在频域显著性方面, 最典型的成果即为我们在第一章中提到过的基于四元数傅里叶变换的红外图像小目标增强方法 [18], 以及在此基础上发展出的一些改进算法 [169]。至于时域显著性, 由于弱小目标极易受到背景干扰以及噪声影响, 往往采用时域显著性结合空域显著性的方法, 例如 Y. Han 等 (2015) 提出的基于运动信息以及空域对比度的红外弱小目标检测方法 [170], Y. Li 等 (2016) 提出的结合局部对比度和轨迹确认的红外弱小目标检测方法 [171], Z. Cui 等 (2016) 提出的高速运动状态下的局部对比度检测算法等 [172]。综上, 基于显著性的红外弱小目标检测算法往往采用多种显著性度量方式相结合的策略, 以充分突出弱小目标, 并抑制背景。

7.2 局部对比度结合区域显著性红外弱小目标检测

7.2.1 红外图像区域显著性度量

在上一节中我们简要介绍了人类视觉系统的基本特点以及因此衍生出的显著性计算研究。简单来说，就是人类自身的视觉系统可以以极快的速度处理复杂场景，获取其中的信息^[173]。这一过程一般是通过大脑对于图片的某些部分进行忽略和压缩来实现的，因此，图像中的一些部分往往可以吸引我们的视觉注意力，该过程被称为视觉关注（Visual Attention）。与第二章中所讨论的相同，对于输入的含有弱小目标的红外图像，其弱小目标对比度较高，其所在区域在人眼中属于显著性较高，信息量较大的区域。在本章中，我们的目标是通过显著性度量的方法去除图像中相对不重要的区域，从而在抑制背景的同时突出目标。这是一种相对其他目标/背景建模方法而言更高效，更经济的方式。因此，在本节中，首先提出了一种基于图像信息熵和局部相似性的红外图像区域显著性度量方法。

根据第2.1节中的描述，对于红外搜索和跟踪系统来说，其处理的图像背景较为复杂，包括但不限于海空背景，天空背景，以及地面背景等。同时，在这些背景中，往往还掺杂有各种类型的不同杂波和干扰。虽然这些背景的表现形态非常不同，但却拥有相同的特征——低信息量。在红外图像中，这种低信息量表现为大面积灰度值较为单一，变化不明显。最常用的图像信息量的度量就是图像信息熵（Image Information Entropy）。图像信息熵是对于整幅图像的信息量的度量。但是该度量是一个针对全图的全局度量，无法衡量图像某特点区域的信息量。因此，我们可以将图像信息熵扩展为局部信息熵，即：

$$H(x,y) = H[\Omega(x,y)] = - \sum_{b=1}^K p_b(x,y) \log p_b(x,y) \quad (7-1)$$

这里 $\Omega(x,y)$ 表示像素点 (x,y) 周围的一个局部区域，在该局部区域内计算信息熵，即人为确定灰度区间的个数 K ，将该区域内的像素值投影到 K 个区间中， $p_b(x,y)$ 表示某像素值落在区间 b 内的概率。通过分图像块计算局部信息熵，可以得到整幅图像的信息熵图。如果一个点所对应的周围邻域的熵值越大，则代表该点附近的邻域内，图像灰度级变化丰富，那么该区域包含有用信息的概率就相应地越大；而熵值越小，相反地，则代表该像素点附近邻域内，灰度级的变化很小，一般来说，包含的信息量也相应较少。设定信息熵分割阈值 k ，则基于信息熵的显著性区域 $\hat{H}(x,y)$ 可由如下的二值图像表示：

$$\hat{H}(x,y) = \begin{cases} 1 & H(x,y) \geq k \\ 0 & H(x,y) < k \end{cases} \quad (7-2)$$

上述提出的局部信息熵只考虑了每个小区域内的灰度统计分布，缺乏对于空间分布的考量。但在实际红外图像中，红外背景图像常常呈现出一定的空间相似性，如层叠的海浪、大面积分布的云层等。上述这些重复的区域容易造成视觉冗余，对于目标检测而言，这些冗余的区域是没有意义的。因此，如何去除图像中的视觉冗余区域，是视觉显著性度量需要考虑的问题之一。在本章中，我们提出一种基于图像的空间局部相似性的视觉显著性度量方法。

通过在第二章中对于红外图像的分析 and 观察，可以看到在红外图像中，表现相似的区域往往其空间位置相距较近。因此，我们可以得到一个简单、直接的结论，即一个像素点的自相似性往往是由其邻域性质决定的^[174]。因此，可以选取图像中的两块区域 Ω_1 和 Ω_2 ，定义这两个图像块的相似性 $\rho_{\Omega_1, \Omega_2}$ ，如下式所示：

$$\rho_{\Omega_1, \Omega_2} = \frac{1}{\|F_{\Omega_1}(x,y) - F_{\Omega_2}(x,y)\|_2^2} \quad (7-3)$$

其中， $F_{\Omega_1}(x,y)$ 和 $F_{\Omega_2}(x,y)$ 分别表示 Ω_1 和 Ω_2 两个区域中的像素值。该显著性的计算过程如图 7-1 所示。在此，我们采用 Ω_1 区域为例来说明该相似性判别过程：首先设定一个相似性判别标准，即阈值 τ 。然后将图像中的 Ω_1 区域与水平方向的邻域 Ω_2 进行相似性度量，若 $\rho_{\Omega_1, \Omega_2} \geq \tau$ ，则证明此两区域具有较强相似性。那么将这两个区域的像素值同时设为 0，意为“不显著”；接着在垂直方向上进行类似的相似性度量，如图 7-1 所示， Ω_1 与其垂直方向邻域 Ω_3 之间的相似性 $\rho_{\Omega_1, \Omega_3} < \tau$ ，即说明两个区域之间的相似性较低，在表现上表现为像素之间有较大差异，则我们将两个区域同时设为 1，意为“显著”。以此过程遍历全图，直到每一个区域都分别进行了水平和垂直方向的显著性度量。之后将两个方向的两个显著性图像做逐像素的与（And）运算，从而融合得到最终的显著性图。因此，一个区域只有在水平方向和垂直方向两次被标记为“显著”，才最终确认该区域具有高显著性，否则，一律标记为“不显著”。由此我们可以得到基于图像局部区域相似性的区域显著性图像 \hat{S} 。

至此，我们得到了两幅不同的显著性二值图像：基于局部图像信息熵的区域显著性图像 \hat{H} 和基于图像局部相似性的区域显著性图像 \hat{S} 。之后，我们便可以对这两幅图像进行融合，从而得到当前帧红外图像的显著性区域（Saliency Region，

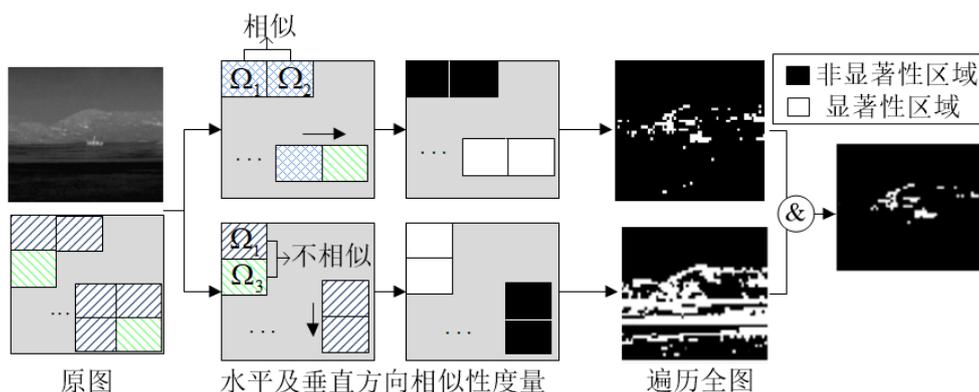


图 7-1 基于局部相似性的图像视觉显著性度量流程图

SR), 具体融合方式如下式所示:

$$SR(x,y) = \begin{cases} 1 & \hat{H}(x,y) = 1 \ \& \ \hat{S}(x,y) = 1 \\ 0 & \text{otherwise} \end{cases} \quad (7-4)$$

7.2.2 局部对比度策略

2014年, C. Chen 等人通过模仿人类视觉系统中的衍生核模型, 设计了一种简洁, 且有效的红外弱小目标增强及提取算法, 被称为局部对比度策略 (Local Contrast Method, LCM) [20]。之后, 在此基础上, J. Han 及其合作者 (2014) 通过引入不同的图像分块策略, 增强了算法的稳定性 [167]。

前文中我们已经分析过, 弱小目标占全图面积较小, 同时, 目标像素与背景像素相比具有较大的不连续性。因此, 我们可以使用合适的区域增强策略, 该增强策略的结果中局部对比度较强的区域就有较大概率为目标区域。在原始的 LCM 方法中, 局部对比度被用作一种用以表示每个区域的表现特征。其中, 数据分块的基本步骤如图 7-2 所示。正如图 7-2(a) 所表示的, 该方法采用滑动窗口的策略, 从而获得局部图像块, 其中 w 表示当前帧的红外图像, u 表示存在弱小目标的区域; 窗口 v 可以在当前帧图像 w 中滑动, 从而使其遍历整幅图像, 得到多个大小为 v 且相互交叠的不同的红外图像块。此外, 子图像块 u 可以在 v 中滑动。每一次移动都可以将原有图像块 v 划分为九个大小相同, 且互不重叠的图像单元。其中, 我们将对应中心区域子图像块的标记为“0”号单元, 周围区域也依次标记, 如图 7-2(b) 所示。

对于每个图像块 v , 其中都包含有 9 个图像单元, 其局部对比度的详细计算过程如下所述: 首先, 计算位于图像块正中心的“0”号图像单元的最大像素值:

$$L_n = \max I_j^0, \quad j = 1, 2, \dots, N_0 \quad (7-5)$$

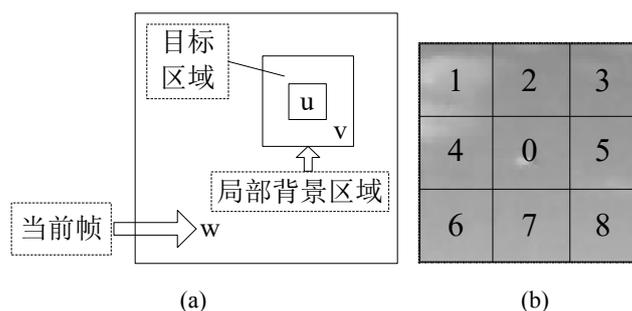


图 7-2 LCM 的数据分块策略描述。(a) 窗口滑动示意图；(b) 图像块划分单元示意图

式中 I_j^0 表示“0”号单元中第 j 个像素点的灰度值； N_0 表示每一个单元所包含的像素点个数。分别计算 1 到 8 号单元的平均灰度值：

$$m_i = \frac{1}{N_i} \sum_j I_j^i, \quad j = 1, \dots, N_i, \quad i = 1, 2, \dots, 8 \quad (7-6)$$

式中 I_j^i 表示第 i 个图像单元中第 j 个像素点的灰度值； N_i 表示第 i 个图像单元中所包含的像素点个数； i 表示图像单元的序号。局部对比度的数值定义为：

$$C_n = \min_i \left(\frac{L_n^2}{m_i} \right), \quad i = 1, 2, \dots, 8 \quad (7-7)$$

之后，我们将“0”号单元的中心像素的灰度值替换为 C_n ，从而计算得出当前图像块 v 所对应的局部对比度。对于图像中的每一个图像块重复该过程，则可得到原图像的局部对比度图像 C 。在算法的实际应用中，由于不同图像中的弱小目标的尺寸相差较大，从较小的 2×2 到较大的 9×9 都有可能，因此，C. Chen 及其合作者引入了多尺度策略。即对窗口 u 的尺寸进行逐次缩放，从而使得基于局部对比度的方法具有一定的尺度不变性，这种改进可以使得算法适用于不同尺寸的目标检测^[20]。多尺度 LCM 的基本策略为：设置多个窗口大小（即尺度） $l = 1, 2, \dots, l_{\max}$ ；同时对于每个尺度 l ，分别求出对应不同尺度的局部对比度图像 C^l ；最终，与 SIFT 特征类似，在不同尺度上对于每个像素选取其在所有尺度上的最大值，从而得到多尺度局部对比度图像：

$$\hat{C}_{p,q} = \max_l C_{p,q}^l, \quad l = 1, 2, \dots, l_{\max} \quad (7-8)$$

其中， p 及 q 表示 C^l 中像素点的行、列坐标。该过程又被称为最大值池化（Max-pooling）方法。经过上述过程，我们可以得到当前帧的具有尺度不变性的局部对比度图像。

7.2.3 LCM 结合区域显著性红外弱小目标检测算法

上文所述的 LCM 方法是通过逐个计算像素点所在区域及其邻域的对比度来实现对弱小目标的增强和检测，同时其具有抑制背景的作用。但在实际测试中，我们可以明显地观察到，上文所述的 LCM 方法的效率非常低。原因在于，LCM 方法作为一种对逐个像素的操作，我们要对每个像素进行相同的处理，则当图片尺寸较大，同时目标较小的情况下，大量的计算操作将会花费在低对比度的、近似为各向同性的背景之上，耗费大量时间，不利于实现高效而准确的弱小目标检测。基于前文的分析，我们知道，人类视觉系统存在注意力转移机制（Attention Shift Mechanism, ASM），这种机制可以使得人类的视觉神经系统优先处理视野中信息量大且具有强显著性的部分^[174,175]。这类图像部分往往可以被认为具有大梯度和高信息熵，因此，本节我们提出了一种结合了区域显著性和局部对比度度量的红外弱小目标检测方法。我们利用 7.2.1 节中提出的基于局部图像信息熵和局部相似性的方法，用于剔除各向同性的冗余背景区域。剩余的区域为显著性高的区域，在这些区域中进行 LCM 计算，即前文所述的区域 LCM 策略（Part Local Contrast Measure, PLCM）^[73]。

在我们所提出的方法中，先通过 PLCM 计算获得当前红外图像的部分局部对比度图像，得到的结果中的局部对比度最大值则为弱小目标所在位置；再经过针对性的自适应阈值分割，做为后处理过程，可以得到最终的检测结果。基于 PLCM 的弱小目标检测流程介绍如下：输入为一幅待处理的含有弱小目标的红外图像 I ，第一步为计算基于图像局部信息熵的显著性图像 \hat{H} 以及基于局部对比度的区域的显著性图像 \hat{S} ，根据公式(7-4)将两张结果图进行融合，即可以得到最终的区域显著性图像 R_S ；最后，在 R_S 的范围内计算区域 LCM，即可得到最终的 PLCM 图像 I_{PLCM} 。最后，对该图像进行自适应分割，从而得到红外弱小目标检测的结果。自适应分割的阈值由下式确定：

$$T = \bar{I} + \lambda * \sigma_{I_{PLCM}} \quad (7-9)$$

其中 \bar{I} 表示 I_{PLCM} 的均值， $\sigma_{I_{PLCM}}$ 表示对应图像的方差， λ 是自适应阈值调节因子，在本文的实验中一般取 $\lambda \in [4.5, 7]$ 。基于 PLCM 的红外弱小目标检测流程如图 7-3 所示。

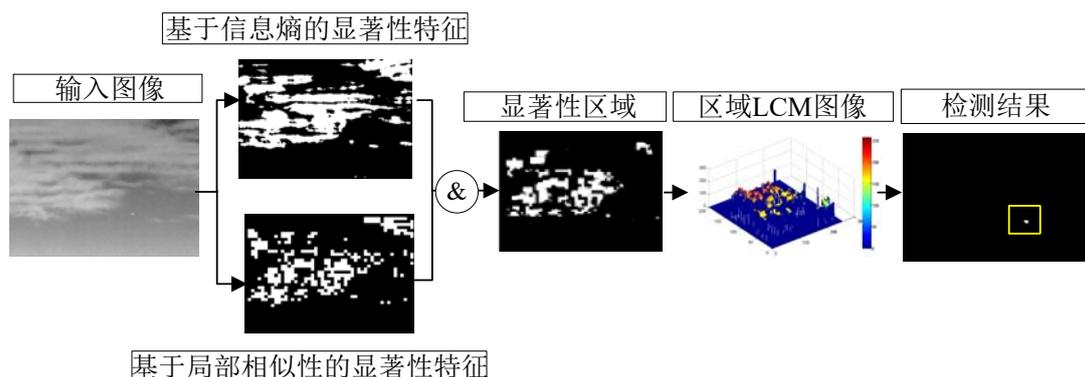


图 7-3 PLCM 算法流程图

7.3 基于二值图显著性与运动信息的红外弱小目标检测

7.3.1 二值图显著性

二值图显著性（Boolean Map Saliency, BMS）是一种自底向上的（Bottom-up）显著性检测方法^[176]。经典的显著性检测方法往往采用局部特征来对显著性进行描述，例如对比度、局部特异性等^[177-179]。但这些方法在描述图像的全局感观方面效果十分有限，换言之，基于局部特征的方法很难准确描述出人眼中的“感兴趣物体”。而 BMS 更加强调对于引起人眼视觉注意的目标的形态描述，因此可以应用于感兴趣目标分割、识别以及视觉跟踪等方面。

BMS 的实现基于图形-背景分离理论^[180]，将包围度（Surroundedness）作为描述前景图像的最重要的信息。在特征方面，BMS 方法仅仅利用当前图像的颜色特征来构建特征空间，不再引入额外的特征。考虑到视觉感知均匀性（Visual Perceptual Uniformity），这里选取 CIE *Lab* 颜色空间作为特征空间；并且考虑到数字图像处理习惯的一致性，*Lab* 空间中的每一个通道的数值都被归一化到 [0 - 255] 范围。

BMS 的计算过程如下。首先，通过对输入图像的 *Lab* 颜色图像进行随机阈值分割，得到了一组二值图像（Boolean Maps）

$$B_i = \text{THRESH}(\varphi(I), \theta)$$

$$\varphi \sim p_\varphi, \theta \sim p_\theta \quad (7-10)$$

这里 $\text{THRESH}(\cdot, \theta)$ 是阈值分割函数，即将大于阈值 θ 的部分设为 1，小于 θ 的部分设为 0。 $\varphi(I)$ 是输入的特征图像，即 *Lab* 颜色通道。通过改变阈值 θ ，即可得到一组二值图像。从视觉角度解释，每一张二值图像都代表了观察者的瞬时意识觉

知^[181]。

其次，将每一张二值图转化为注意力图像（Attention Map） $A(B_i)$ 。顾名思义，注意力图像表示的是前景图像与背景图像在吸引视觉注意力上的区别。基于格式塔心理学（Gestalt Psychological）中关于前景-背景分离的研究，在一幅图像中，被完整包围，或者说具有完整闭合轮廓的区域更容易被认为是前景^[182]。在注意力图像的计算过程中，BMS 将被完整包围的区域标记为显著区域，其他区域被标记为 0。该过程采用的是一种叫做洪水填充（Flood Fill）的算法^[183]。随后，将所有的注意力图像结合起来形成一副平均注意力图像：

$$\bar{A} = \frac{1}{n} \sum_{k=1}^n A_k \quad (7-11)$$

在计算平均注意力图像之前，采用 Frobenius 范数对每张注意力图像进行归一化。至此，我们就得到了 BMS 显著性图像。

7.3.2 BMS 结合运动信息的红外弱小目标检测

如第 7.2 节所述，由于其亮度高、运动速度快等原因，弱小目标在红外图像中往往会吸引更多的视觉关注，即弱小目标属于红外图像中的显著区域（这里以亮目标为例，暂时不讨论暗目标的情况）。在本节中我们提出一种 BMS 结合运动信息的红外弱小目标检测方法，利用红外图像的灰度信息与运动特征构建特征空间，在该特征空间中采用 BMS 策略：通过对每个特征通道的分割，得到一系列二值图像；其次，将二值图像转化为注意力图像；最后就可以得到基于灰度的显著性图像和基于运动信息的显著性图像。将二者结合，得到最终的显著性区域，即为弱小目标区域^[184]。

7.3.2.1 灰度显著性图像

在原始的 BMS 的计算过程中，考虑到视觉感知均匀性，采用 Lab 颜色空间作为特征空间。而红外图像是灰度图像，并非彩色图像，因而不具有颜色信息，其灰度值代表该点的灰度强度。因此采用灰度图像本身作为一个特征通道，用于描述弱小目标高红外辐射、高亮度的特点，这也是使其区分与背景的一个重要特征之一。在灰度特征通道中，其二值图像 B_G^i 可以通过对输入图像的灰度值进行随机阈值分割而实现：

$$B_G^i = \text{THRESH}(I, \theta) \quad (7-12)$$

这里 I 表示输入的灰度图像， θ 的数值由 $[0,255]$ 范围内的均匀分布函数随机产生。对于每一幅二值图像 B_G^i ，在其中找到具有闭合轮廓的连通区域，将其标记为注意力图像 A_G^i 。与原始 BMS 算法的处理方式不同，这里我们采用 L_1 范数对每张注意力图像进行归一化，因为相比与 L_2 范数， L_1 范数对于保持小面积区域有更好的效果，有利于红外弱小目标检测。将所有的注意力图像融合在一起，可以得到当前灰度图像的显著性图。该显著性图可以视为一个初步的检测结果，包含有潜在的目标区域，我们将其称为灰度显著性图（Gray Saliency Map, GSM）。

7.3.2.2 运动显著性图像

除了灰度特征之外，运动特征也可以被用于检测红外图像中的弱小目标。在一组红外图像序列中，目标的运动是快速而连续的，与此同时，背景和噪声的变化是随机的。在本节中我们提出一种将运动特征图像作为 BMS 特征通道的显著性计算方式。首先，通过帧差法，我们可以得到当前帧的运动信息。假设 $f(x,y,t)$ 是当前红外序列的第 t 帧，其运动信息可以表示为：

$$Mov(x,y,t) = \begin{cases} 0 & \text{if } f(x,y,t) = f(x,y,t-1) \\ 1 & \text{if } f(x,y,t) \neq f(x,y,t-1) \end{cases} \quad (7-13)$$

Mov 代表了相邻两帧之间是否存在运动的信息，但是该特征对于变化的背景以及噪声不具有鲁棒性。因此，我们引入另一种运动信息的计算方法，称为运动累积方法（Motion Charge, MC），代表了某物体的运动在时间上的累积效果^[185]。其定义如下：

$$Ch_{Mov}(x,y,0) = Ch_{\max}$$

$$Ch_{Mov}(x,y,t) = \begin{cases} Ch_{\min} & \text{if } Mov(x,y,t) = 1 \\ \min(Ch_{Mov}(x,y,t-1) + C_{Motion}, Ch_{\max}) & \text{if } Mov(x,y,t) = 0 \end{cases} \quad (7-14)$$

这里 C_{Motion} 是运动累积增量参数，这里设置为 $C_{Motion} = 2$ 。 Ch_{\max} 以及 Ch_{\min} 的值分别设置为 255 和 0。从公式(7-14)中可以看出，如果 $Ch_{Mov} = Ch_{\min}$ ，则代表在 (x,y,t) 处检测到了运动；如果 $Ch_{Mov} = Ch_{\max}$ ，则代表在 (x,y,t) 处没有检测到运动，并且上一次运动发生的时间是未知的；如果 $Ch_{Mov}(x,y,t) = Ch_{\min} + k \cdot C_{Motion}$ ，则代表在 (x,y,t) 处没有检测到运动，但是上一次运动发生的时间为 $t - k \cdot \Delta t$ 。运动累积方法的流程如图 7-4 所示。

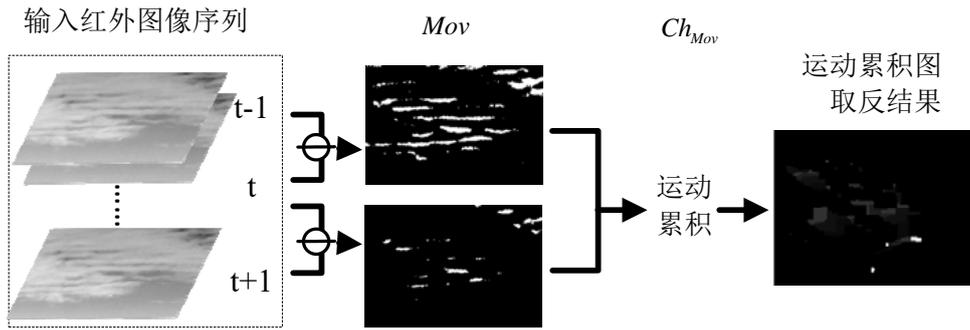


图 7-4 运动累积方法流程图

运动累积 Ch_{Mov} 不仅描述了当前帧的运动，同时也包含了之前帧的运动信息。考虑到 BMS 对图像中像素值大的区域更敏感，我们对运动累积图像取反，即 $255 - Ch_{Mov}$ ，作为运动特征图。将该运动特征图作为 BMS 的另一个特征通道，我们可以得到潜在运动区域的显著性图，称为运动显著性图（Motion Saliency Map, MSM）。该运动特征的引入可以在降低变化背景对运动检测的影响的同时，保留目标真正的运动轨迹信息。同时，与第 7.3.1 节中所描述的相同，我们采用 Frobenius 范数对运动特征图进行归一化，以去除背景杂波的影响，同时对所捕获到的感兴趣目标的运动进行增强。

7.3.2.3 基于二值图显著性与运动信息的弱小目标检测

本节我们提出一种基于 BMS 结合运动信息的红外弱小目标检测方法，称为 BMS_{motion} [184]。通过将灰度图像以及运动累积图像作为特征通道，结合 BMS 算法，我们得到了灰度显著性图以及运动显著性图。灰度显著性图强调了图像中具有较高红外辐射的区域，而运动显著性图突出了弱小目标的运动轨迹信息。将这两个显著性图像结合，通过对应位置相乘的方式，我们可以得到最终的弱小目标检测结果。该方法不仅考虑到了红外弱小目标具有高亮度的特点，同时将连续的运动轨迹也作为判断目标是否存在的一个指标。 BMS_{motion} 方法的流程如图 7-5 所示。

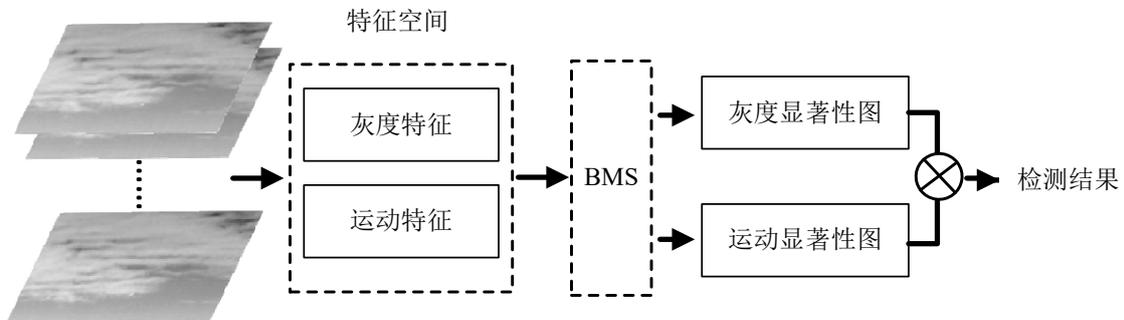


图 7-5 基于二值图显著性与运动信息的红外弱小目标检测流程图

值得注意的是，该流程仅仅考虑了亮目标的情况。针对暗目标，需要在计算灰度显著性图时将输入图像进行反转；运动显著性图则不会受到影响。

7.4 实验结果与分析

在本节中，我们分别展示了本章中提出的局部对比度结合区域显著性方法以及二值图显著性结合运动信息的红外弱小目标检测方法的效果，并对实验结果进行了评价。

7.4.1 局部对比度结合区域显著性方法

为了验证本章所提出的 PLCM 算法的有效性，在本节中，我们采用三组实际红外图像序列对提出的算法进行测试，其中场景一为公开的红外测试数据集，其余数据由合作单位提供。这三组实际红外图像序列包括了天空场景，海空场景以及海面场景，采取这些场景的意义在于验证 PLCM 算法的通用性和有效性。同时，本节中，我们将 PLCM 方法与传统 Top-hat 滤波方法和传统 LCM 算法进行了比较。测试环境为配置有 2.30 GHz 英特尔 i5 处理器的计算机，内存为 8 GB。仿真软件为 Matlab R2014b。对应的弱小目标检测结果如图 7-6 所示。

场景一为以一架战斗机为目标的红外图像，背景是天空以及灰度非常高的明亮的云层。其中的目标为一个数个像素大小的亮点，该图像分辨率为 200×256 像素。可以看到，由于该图像背景中存在非常明亮的云层，而传统的 Top-hat 检测方法对于云层中的亮点无法较好的处理，在结果中体现为若干虚警点，并且检测到的正确的目标尺寸很小，无法反映实际的情况；而传统的 LCM 方法以及本文所提出的方法均可以较好地检测到图中的战机目标，同时检测结果不含有任何的虚警目标。但可以看到，PLCM 方法的检测结果与实际目标的大小和形状更加吻合。LCM 检测方法的结果比实际目标更大，其对目标的定位能力要弱于本文所提出的 PLCM 方法。

场景二为含有一艘舰船目标的大小为 240×320 像素的海空背景红外图像。在该图像中，海空分界线位于图像中央，目标处于海空分界线上。图像整体背景亮度低，目标与背景的表现特征较相似；海空分界线上的成像质量较低。在检测结果中可以看到，Top-hat 方法在海空分界线上存在若干虚警，这是由于在海空分界线上灰度变化剧烈，杂波较多导致的。传统 LCM 方法在图像上部的暗色天空区域存在较多虚警。这些虚警的出现是 LCM 方法的固有缺陷，在低灰度区域，根据式(7-7)，当 $m_i \rightarrow 0$ ，则 $C_n \rightarrow \infty$ ，从而我们拥有无穷大的局部对比度，因而在检测结果中表现为虚警。而本文方法则不存在这些虚警，因为图像上部的暗色背景

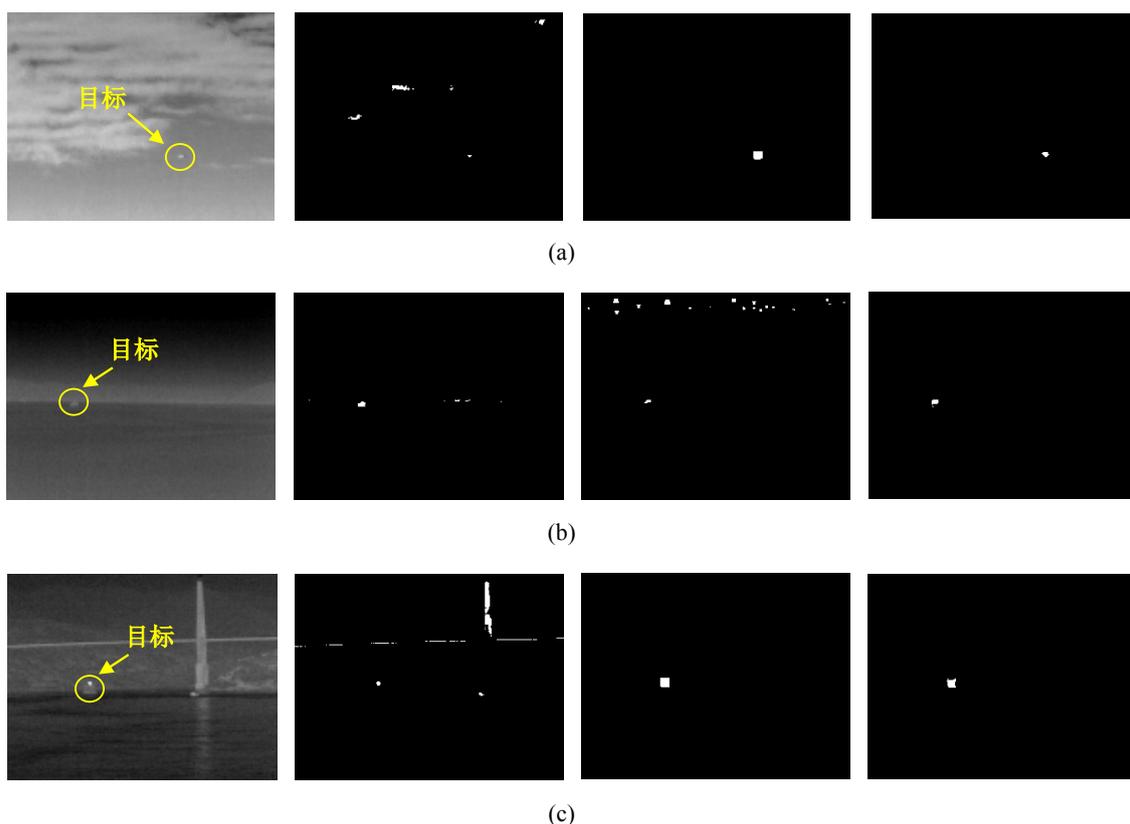


图 7-6 红外弱小目标检测结果图，从左到右依次为：原图，Top-hat 方法检测结果图，LCM 检测结果图以及 PLCM 检测结果图。(a) 场景 1 检测结果；(b) 场景 2 检测结果；(c) 场景 3 检测结果

不属于含有较多信息量的显著区域，这些区域的检测在显著性检测步骤中即被排除，从而不存在误检。同时，PLCM 方法所检测出的目标在大小与形状上与图中目标更为类似。

场景三中的目标是一艘靠近港口的船只，该场景中含有大量人工建筑物，与之前两幅图相比更加复杂。该图像大小为 240×320 像素，成像质量较低，图像中含有大量的噪声。我们可以从检测结果中看到，两种传统方法均无法较好地检测出图中的船只。Top-Hat 方法中，噪声和人工建筑物带来了大量的虚警；同时 LCM 方法所检测出的目标在大小和形状上与原图差距较大。PLCM 方法所检测出的目标形状更加精确。这是由于 PLCM 方法抑制了部分近似各向同性的背景区域，这样减少了目标的邻域背景对于检测过程的干扰，具有更高的检测精度。

为了进一步展示本章所提出的 PLCM 方法的目标增强和背景抑制效果，以场景一为例，图 7-7 中展示了原图的三维投影，与 PLCM 方法处理后的检测结果的三维投影。

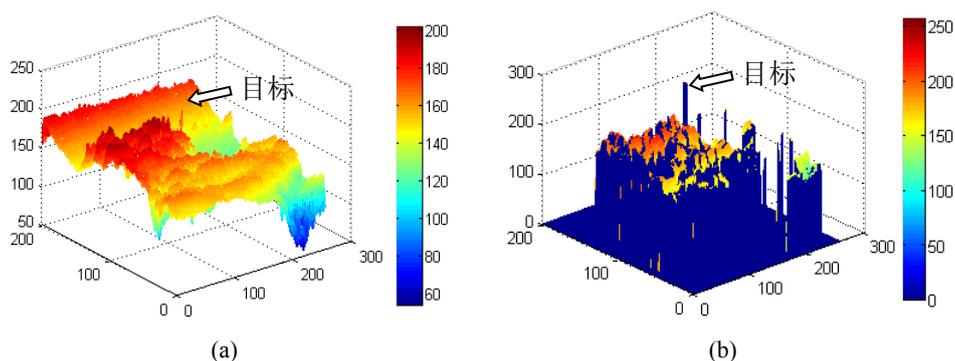


图 7-7 PLCM 处理前后的三维投影图。(a) 原图的三维投影图；(b)PLCM 处理结果的三维投影图

可以看出在原始图像中，背景与目标的亮度值相差不大，目标淹没在复杂背景中；在处理后的 PLCM 结果图中，背景被极大地抑制，而目标得到了突出，其数值远远高于背景，容易被识别。因此，PLCM 方法的优势之一在于可以极大地提高弱小目标的信噪比（Signal-to-Noise Ratio, SNR），与第 3.3.2 节定义的信杂比不同，这里的信噪比是一个表征全局背景抑制的概念，定义如下：

$$\text{SNR} = \frac{|U_t - U_b|}{\sigma_b} \quad (7-15)$$

其中， U_t 和 U_b 表示目标和背景区域的平均灰度值， σ_b 表示背景的标准差。此外，信噪比增益可以表示为：

$$G_{\text{SNR}} = \frac{\text{SNR}_{\text{out}}}{\text{SNR}_{\text{in}}} \quad (7-16)$$

信噪比增益可以有效地表征算法的目标增强效果。表 7-1 全面展示了本章所使用的三组实际红外图像序列经过 PLCM 方法处理前后的平均信噪比以及对应的信噪比增益。

表 7-1 PLCM 处理前后信噪比对比

	$\overline{\text{SNR}}_{\text{in}}$	$\overline{\text{SNR}}_{\text{out}}$	$\overline{G}_{\text{SNR}}$
场景 1	0.6624	2.5109	2.1045
场景 2	1.2579	22.2644	17.6997
场景 3	4.5069	16.1441	3.5821

从表 7-1 中可以看到，在我们所使用的三组红外图像测试序列中，本文所提出的 PLCM 方法大幅提高了图像的信噪比。处理后的图像的信噪比较输入图像提升了 2 倍以上。特别对于场景二，其信噪比提升达到了 20 倍。可以看到，本文

提出的 PLCM 算法对于场景信噪比的提升有明显效果。另外，由于在本方法中我们采取了仅仅对于信息量较大的局部图像进行局部对比度增强策略，抛弃了传统 LCM 方法的逐像素扫描的滑动窗口操作，因而本方法的处理效率有了极大提升。图 7-8展示了在不同测试场景下传统 LCM 算法与本文所提出的 PLCM 方法运行耗时对比，其中绿色条带表示 LCM 方法的运行耗时，而灰色条带表示了 PLCM 方法的运行耗时。我们可以看到，PLCM 方法将 LCM 的运行效率提高了数十倍。其中，对于场景 2，由于海天背景包含了大量的近似各向同性的背景区域，几乎占到全图 95.5%，对于这些背景区域的处理均可视为是冗余计算。这些部分的处理均被 PLCM 方法所避免。因此，本文所提出的 PLCM 算法可以达到实时处理的要求。

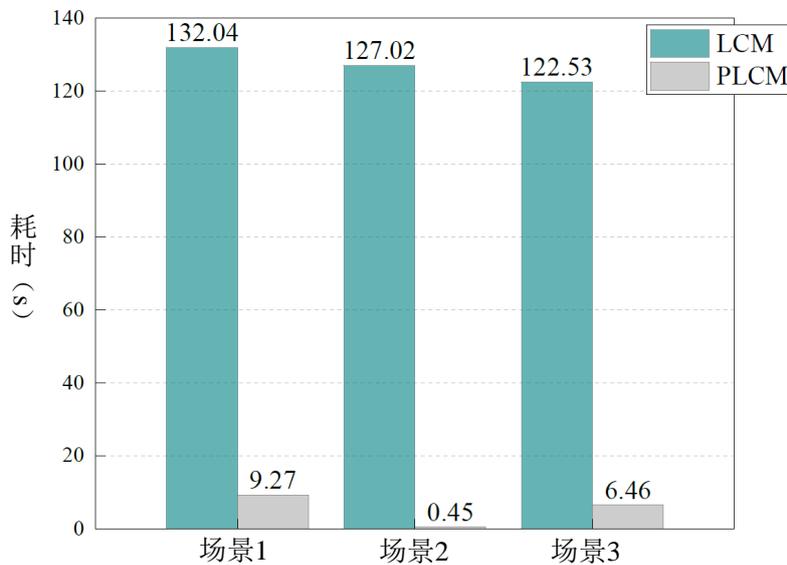


图 7-8 LCM 与 PLCM 计算耗时对比

7.4.2 二值图显著性结合运动信息方法

为了验证第 7.3 节中所提出的红外弱小目标检测方法的有效性，我们选取了四组图像序列进行测试，其中场景 1 为公开的红外测试数据集，其余数据由合作单位提供。测试环境为配置有 2.30 GHz 英特尔 i5 处理器的计算机，内存为 8 GB。仿真软件为 Matlab R2014b 以及 Microsoft Visual Studio 2013。检测结果如图 7-9 所示。

在场景 1 中，背景相对复杂，且具有丰富的纹理以及边缘信息，因此可以清楚地看到在灰度显著性图中具有一些虚警点，这是由于背景杂波所导致的。通过引入运动信息，可以去除这些虚警点，最终准确检测到弱小目标。在场景 2 中，目标的信杂比很低，可以视为典型的弱目标。其灰度显著性图表现为一个很小的亮点。而在运动显著性图中，展示了该序列中目标的运动轨迹。在最终检测结果中，弱小目标被准确定位，且形状检测也较为准确。在场景 3 及场景 4 中，我们可以

看到，灰度显著性图中所突出的弱小目标区域往往小于实际目标的面积，这是由于二值图以及注意力图像的计算过程所导致的。通过结合运动信息，可以较好地保留弱小目标的形状。

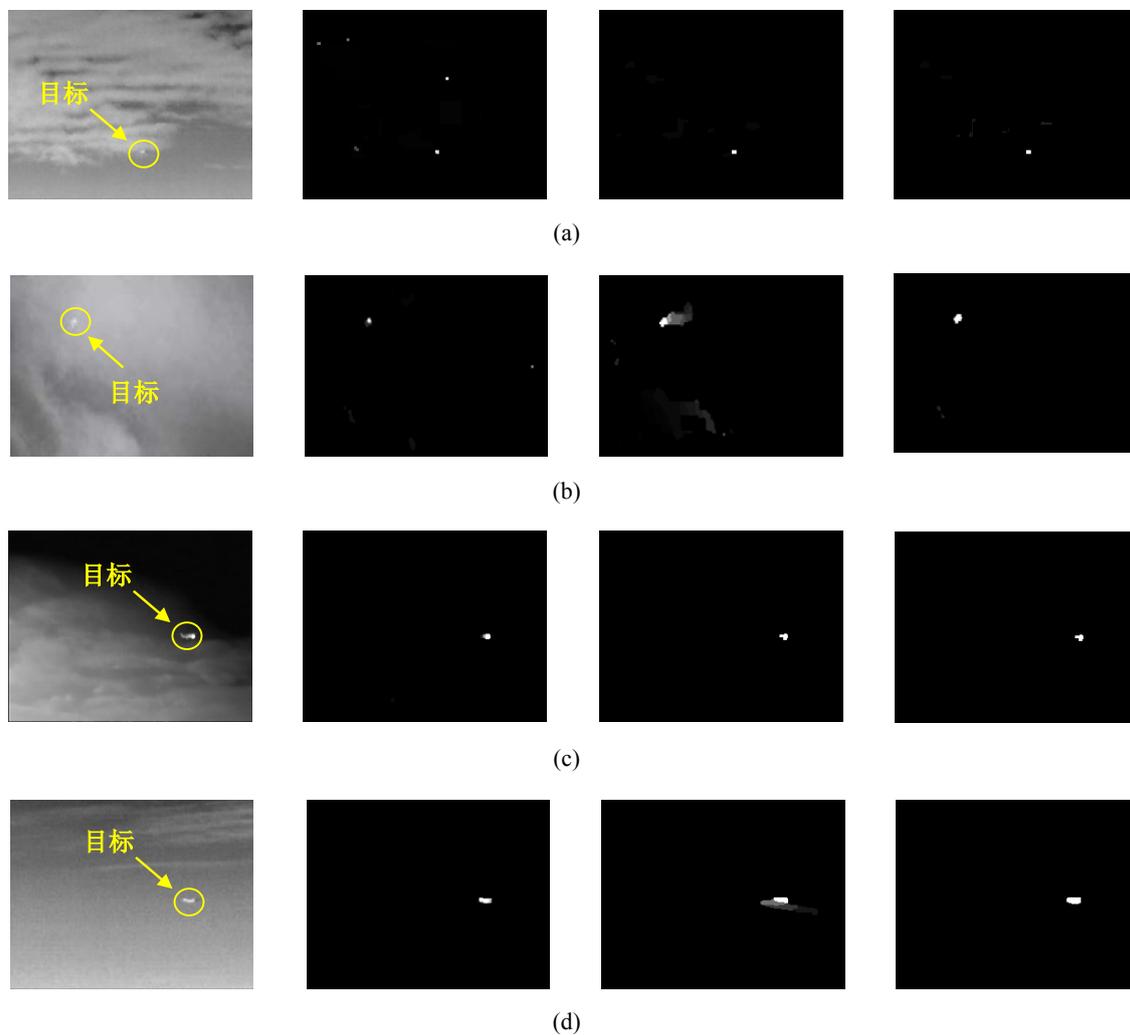


图 7-9 BMS 结合运动信息的弱小目标检测方法结果，从左到右依次为：原图；灰度显著性图像；运动显著性图像；红外弱小目标最终检测结果。(a) 场景 1 检测结果；(b) 场景 2 检测结果；(c) 场景 3 检测结果；(d) 场景 4 检测结果

为了进一步说明该方法的有效性，我们选取虚警率（False Alarm Rate）作为评价指标。与前文相同，虚警率定义如下：

$$F_a = \frac{FD}{NP} \quad (7-17)$$

这里 FD 以及 NP 分别表示虚警区域中的像素个数以及测试序列中的总像素个数。可以看出，虚警率表征了检测结果中虚警点所占整幅图像的比例，该比例越小，

说明检测结果中虚警越少。此外，我们选取经典的 Top-hat 方法，最大均值滤波 (Maxmean) 以及最大中值滤波 (Maxmedian) 方法作为比较方法。经典滤波方法的检测过程可以视为是利用了红外弱小目标的灰度分布特性，或者说是灰度值信息。BMS 方法同样利用了灰度图像作为一个输入通道，来提取显著性高的目标。但不同的是，这里加入了运动信息作为补充，这样的对比可以说明 BMS 显著性在弱小目标检测中的实用性，以及运动信息的重要性。表 7-2 展示了上述四种方法在四组测试场景中的虚警率结果。

表 7-2 虚警率比较 (%)

	Top-hat	Maxmean	Maxmedian	BMS _{motion}
序列 1	83.60	99.87	99.87	0.53
序列 2	58.53	99.87	99.87	0.26
序列 3	61.79	99.91	99.91	0.43
序列 4	83.46	99.90	99.90	0.03

可以看出，BMS 结合运动信息的红外弱小目标检测方法具有极低的虚警率，这是由其中的显著性检测策略决定的。并且，在四组测试场景中，该方法都取得了很好的效果，说明了 BMS_{motion} 方法对于场景的鲁棒性。该方法适用于检测高速运动的目标，例如空中飞行的飞机、导弹等。

7.5 本章小结

本章介绍了基于显著性度量的红外弱小目标检测方法。首先回顾了显著性检测的基本理论，随后提出了两种基于显著性检测的红外弱小目标检测算法：PLCM 以及 BMS_{motion} 算法。PLCM 算法是一种基于显著性度量以及局部对比度策略的检测方法，通过计算基于局部熵以及局部相似性的显著性区域，将 LCM 的计算限制在显著性区域中，在提高计算效率的同时也可以进一步避免虚警；BMS_{motion} 方法将灰度信息以及运动累积图作为 BMS 显著性计算的输入通道，最后计算出包含弱小目标的显著性区域。实验结果证明了所提出算法的有效性。

第八章 总结与展望

8.1 全文总结

红外弱小目标检测是红外搜索与跟踪系统中的核心模块之一，在交通、安防及军事方面都有着广泛而重要的用途。由于红外探测器精度有限、成本较高，以及多数应用场景中成像距离长、受大气干扰等原因，红外弱小目标很容易被淹没在背景杂波及噪声之中，给检测带来了很大的困难。传统方法往往面临着检测率低、场景鲁棒性差等问题，容易造成漏检及误检，给实际应用带来一定困难。稀疏表示及动态优化反演方法是近年来信号处理和图像处理领域的研究热点与难点之一，本文利用上述新方法和手段，将红外弱小目标检测视为一个反演问题，从观测量，即输入图像中，根据预先设定的模型，求解得到红外弱小目标，构建了全新的红外弱小目标检测体系和方法，获得了高质量的检测结果。

本文的主要工作包括以下几个方面：

1. 红外成像场景分析及动态反演理论研究

动态反演方法，即模型构建及优化求解方法，是本文的最主要的理论研究内容。而基于该理论的红外弱小目标检测算法是本文的核心研究工作以及研究成果。由于红外弱小目标和背景具有不同的性质，且红外背景复杂多变，在不同的场景下，需要设计不同的背景、目标及噪声模型，构建反演问题，同时采用不同的求解方法。本文充分地研究了包括海面背景、天空背景以及地面背景在内的常见红外成像场景，分析了各个场景的特性，是后续红外场景和目标建模的基础。同时我们研究了经典的反演理论及方法，并将其运用到红外弱小目标反演检测中。

2. 红外弱小目标联合正则化反演检测方法研究

针对复杂场景下的红外弱小目标检测问题，单一的数学模型很难充分地描述场景的复杂性，从而限制了弱小目标检测的精度。我们研究了基于联合正则化的红外弱小目标反演检测方法，深入探讨了存在灰度突变的非平滑背景的表达方式，完成了红外弱小目标联合正则化反演检测的框架。具体来说，我们将全变差正则化与低秩模型相结合，很好地恢复了非平滑红外背景，进而促进了目标检测。

3. 基于多子空间学习的红外弱小目标检测方法研究

常见的复杂红外成像场景中，有一类场景，其显著特点是场景中包含多于一个强红外辐射源。这样的场景很容易发生误检。针对这种情况，我们从场景入手，研究了多子空间模型这种广泛使用的数据分类方式，得到了一种红外图像多子空间背景表示模型。从输入图像本身出发，学习得到其多子空间结构，进而对背景

的分布有清楚的认知和表达，利于从中提取弱小目标。

4. 基于稀疏表示的红外弱小目标检测方法研究

稀疏表示是一种常用的图像处理、目标检测及分类方法。对于红外弱小目标检测任务，由于其样本量有限，且图像中缺少颜色、形状及纹理信息等原因，简单的稀疏表示方法往往难以准确地检测到目标。我们在充分研究红外弱小目标图像的基础上，研究了适合于该任务的样本提取方式、字典构建方式以及求解方式等，使得稀疏表示方法可以很好地用于弱小目标检测。

5. 基于频域模态分解的红外弱小目标检测方法研究

除了空域、时域信息之外，红外弱小目标与背景的差异性还体现在频域上。我们研究了一种基于频域模态分解的红外弱小目标检测算法，在频域中构建了稀疏动态反演模型，采用窄带信号分解的方式，结合对目标的非负约束，反向求解得到目标所在的频带。尽管该研究内容的应用场景较为有限，在复杂场景下不可避免地受到一定干扰，但其在复杂度不高的红外成像场景中，检测效果和效率都体现了其优越性。

6. 基于视觉显著性的红外弱小目标检测方法研究

视觉显著性是图像中待检测目标所经常具有的一种性质，该性质也可以用于红外弱小目标检测中。在充分分析红外弱小目标的灰度、局部特性以及运动特性的基础上，我们研究了基于对比度、灰度以及运动信息的显著性检测方法，从多个方面刻画了目标与背景的不一致性，突出了目标的特点，利用该显著性实现了准确的目标检测。

本文的主要贡献和创新包括以下几个具体的方面：

(1) 提出一种基于全变差-主成分追踪的红外弱小目标动态反演检测方法，以及相应的求解算法。通过分析现有的红外背景表示模型在复杂场景中不再适用的原因，引入全变差项，用以保留背景中灰度变化显著的区域，即边缘区域，避免对目标检测产生干扰，从而准确地从输入图像中分离出目标区域并恢复背景，实现复杂场景下的高精度目标检测。

(2) 提出一种基于稳定多子空间学习的红外弱小目标检测方法，以及相应的求解算法。通过分析复杂多源红外背景的特点，我们认为将其视为在单一子空间上的分布这种做法是不合适的，遂提出一种基于多子空间学习的背景描述方式，从红外数据本身出发，自适应地学习出该图像所处的多子空间，并在其上对背景进行表示，从而分离背景，并检测目标。同时，在优化求解过程中，我们将 APG 算法与行 L1 范数软阈值分割相结合，得到了一种新的求解方法，实现了高度复杂场景下的目标检测。

(3) 提出一种基于非负约束变分模态分解的红外弱小目标检测方法。通过分析红外弱小目标的频率分量特性,采用近年来提出的窄带信号自适应分解方法,结合对目标信号的非负约束,自适应地分解出目标所在频带的子信号,从而检测得到红外弱小目标,是对红外目标与背景频率差异性质的一种应用。

(4) 提出一种基于部分局部对比度的红外弱小目标检测方法。红外弱小目标的重要特性之一是在局部范围内具有较高的对比度。局部对比度的计算可以准确地检测出目标所在位置,但缺点是比较耗时。我们设计提出了一种基于局部熵以及局部图像相似度的红外图像显著性度量方法,先检测出潜在的目标区域,再在潜在目标区域内进行局部对比度计算,高效且准确地检测出了红外弱小目标。

总之,本文利用稀疏表示、动态反演等方法实现了鲁棒的红外弱小目标检测,构建了完整的红外弱小目标检测框架,同时也研究了基于视觉显著性等方法的红外弱小目标检测新方法,实现了多种场景下的稳定的目标检测,为后续开展更深层的理论研究及开发针对性的应用系统打下了良好的基础。

8.2 后续工作展望

红外弱小目标检测技术,从方法上来说已经趋于成熟,大多数方法都可以达到非常高的检测率(95%以上),同时具有很低的虚警率,同时也已经发展成为了具有完整理论体系的研究内容。因此,其后续发展的重点可能集中在两个方面:特殊场景下的红外弱小目标检测研究以及稳定的红外搜索与跟踪系统研究。这里的特殊场景包括有强烈干扰源的背景、变化剧烈的场景以及某些情况下的特定应用场景等,这些场景与通常研究的红外成像场景不同,普适性的方法不再适用,因此需要进行针对性的研究。此外,稳定的红外搜索与跟踪系统也是很重要的一个研究方向。其核心内容,红外弱小目标检测与跟踪,该研究已经趋于成熟,但是如果如果没有稳定的实际系统,则这些算法无法发挥实际的作用。

具体到本文提出的方法,也存在一定的不足,可以继续深入研究。主要包括:

(1) 在联合正则化问题中,多重约束项之间的平衡往往会带来不一样的效果,而如何自适应地根据场景确定这些权重的值,可以作为今后的一个研究方向。一般认为,处理不同类型的场景时,应该对这些权重赋予不同的数值。可以根据所处理的场景的不同,构建场景特性及场景复杂度描述子,据此自适应地确定联合正则化中的权重值。

(2) 在基于稳定多子空间学习的红外弱小目标检测方法中,我们采用整个数据空间作为提取子空间的样本。而近年来的一些其他研究表明,可以对输入数据

进行随机采样，在一定条件下，不仅不会影响到子空间的训练，还可以极大地提高计算效率。具体到红外弱小目标检测方法中，采用随机采样的方式，更适合于处理红外卫星图像等大面积、高分辨率的图像。

(3) 在基于多任务联合稀疏表示的检测算法中，我们没有考虑目标的尺度问题。尽管在构建字典时考虑了不同大小的目标，但实际应用中目标的尺度变化范围更大，因此在选取目标区块时应该对目标区块进行尺度变换，更好地实现稀疏表示。

此外，我们通过手动方式选取了多任务联合稀疏表示中的特征，但手动选取的特征适应性有限。而近年来发展的深度神经网络可以被认为是一种很好的特征训练及选择机制，可以考虑将其引入红外弱小目标检测中，或者用其进行特征选择。

除了理论研究之外，如何将本文所提出的方法真正地应用于实际的军用或者民用红外系统，构建高效的、鲁棒性强的检测系统，实现实时场景下的红外弱小目标检测与跟踪，同样是后续重要的研究内容之一，也是最重要的研究内容之一。

总之，红外弱小目标检测的研究会更多地向着具体应用层面以及系统层面去发展，在此过程中，信号处理领域新的思路以及新的工具可以帮助红外弱小目标检测方法实现进一步的发展，进而构造出高精度的红外目标搜索与跟踪系统，促进相关领域的发展。

致 谢

攻读博士学位的五年半期间结识了很多老师及朋友，借此机会想要感谢这些一路同行的人们。首先感谢我的博士生导师彭真明教授，从大四进入教研室起，已经与彭老师一起工作了六年多的时间。期间每一次研究方向的调整 and 改变，都有彭老师的细心考量和引导；取得的每一点成果也都离不开彭老师在背后的指导和付出。最初接触科研时眼光只局限于一个问题、一个算法，现在得以从更高的角度、更广阔的视野去看待所面临的问题，这其中的成长都离不开彭老师潜移默化的影响以及实验室良好氛围的熏陶。

感谢乐观积极的何艳敏老师一直以来的鼓励和引导，让我得以不急不徐地在这条道路上前进；感谢亦师亦友的张萍老师，与您的每次交流都很愉快并且受益匪浅；感谢蒲恬老师在我参与工程项目期间的指导，以及职业规划方面的帮助；感谢王卓然教授、陶冰洁老师以及张靖老师对我做出的指导，帮助我顺利完成博士学业。

对五年来一起工作过的同窗伙伴们表示衷心的感谢。感谢已经毕业的岳碧波博士，田琳博士，郑欣博士，冯谦，王圣川，张晓燕，谢成芳，赵敏等，与你们一起学习和工作的时间无论长短，都是一份重要的经历；感谢同级的孔德辉博士以及王雨青博士，我们一起度过了很多互相陪伴的时光；感谢同时进入实验室的李江阳，胡丽华，何戒娇，以及同级的张帆，钟露，郑佳等，我们的友谊不会因为离开学校而改变；感谢在读的李美惠博士，黄苏琦博士，吴昊博士，刘雨菡博士，孙翎马博士，谢谢你们的帮助和包容。特别感谢大洋彼岸的范弘毅博士在科研思维、写作方式以及工作和生活态度上对我的影响和改变。

Special thanks to Dr. Dima Damen, the year I spent in Bristol would always be a treasured memory. Thanks for expanding my vision and sharing the valuable experiences with me. Although what I did with you is not related to the PhD thesis, but it matters a lot in the path from a student to a researcher.

感谢范睿博士，庞蔚然博士，杨兴锐博士在英国的支持和交流，与你们的讨论产生了很多思维的火花；感谢 Dr. Bani Avari, Junaid Bocas, Will Andrew, Robert Richardson 等合作者与同窗的信任及帮助。感谢杨慧博士，祈冉博士以及林巧一年来的陪伴。

感谢父母对我的爱以及对我的学业的支持；感谢王和月一直做我最好的朋友，陪伴我一起探索生活中的一切。

参考文献

- [1] 董维科. 天空起伏背景中红外弱小目标检测新方法研究 [D]. 西安: 西安电子科技大学, 2013, 3-4
- [2] 魏芳. 基于多尺度几何分析的红外弱小目标检测方法研究 [D]. 成都: 电子科技大学, 2012, 17-18
- [3] 彭真明. 地震反演中的非线性优化方法及应用研究 [D]. 成都: 成都理工学院, 2001, 4-10
- [4] 王会改. 基于空时域稀疏表示的弱小运动目标检测技术 [D]. 重庆: 重庆大学, 2014, 2-6
- [5] M. M. Hadhoud, D. W. Thomas. The two-dimensional adaptive lms (TDLMS) algorithm[J]. IEEE Transactions on Circuits and Systems, 1988, 35(5): 485-494
- [6] D. S. Bright, E. B. Steel. Two-dimensional top hat filter for extracting spots and spheres from digital images[J]. Journal of Microscopy, 1987, 146(2): 191-200
- [7] B. Ye, J. Peng. Small target detection method based on morphology top-hat operator[J]. Journal of Image and Graphics, 2002, 7(7): 638-642
- [8] L. Deng, H. Zhu, Q. Zhou, et al. Adaptive top-hat filter based on quantum genetic algorithm for infrared small target detection[J]. Multimedia Tools and Applications, 2018, 77(9): 10539-10551
- [9] G. Davidson, H. Griffiths. Wavelet detection scheme for small targets in sea clutter[J]. Electronics letters, 2002, 38(19): 1128-1130
- [10] W. Tong, Y. Ling, C. Huang, et al. Processing method of IR image based on mathematical morphology and wavelet transform[J]. Optics and Precision Engineering, 2007, 1: 024
- [11] Y. Cao, R. M. Liu, J. Yang. Infrared small target detection using PPCA[J]. International Journal of Infrared and Millimeter Waves, 2008, 29(4): 385-395
- [12] Y. Gu, C. Wang, B. Liu, et al. A kernel-based nonparametric regression method for clutter removal in infrared small-target detection applications[J]. IEEE Geoscience and Remote Sensing Letters, 2010, 7(3): 469-473
- [13] K. Xie, T. Zhou, Y. Qiao, et al. Learning to detect small target: a local kernel method[J]. Infrared Physics & Technology, 2015, 69: 7-12
- [14] C. Q. Gao, L. Wang, Y. Xiao, et al. Infrared small-dim target detection based on markov random field guided noise modeling[J]. Pattern Recognition, 2018, 76: 463-475

- [15] C. Q. Gao, T. Q. Zhang, Q. Li. Small infrared target detection using sparse ring representation[J]. IEEE Aerospace and Electronic Systems Magazine, 2012, 27(3): 21-30
- [16] C. Q. Gao, D. Meng, Y. Yang, 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
- [17] H. Wang, F. Yang, C. Zhang, et al. Infrared small target detection based on patch image model with local and global analysis[J]. International Journal of Image and Graphics, 2018, 18(01): 1850002
- [18] S. Qi, J. Ma, H. Li, et al. Infrared small target enhancement via phase spectrum of quaternion fourier transform[J]. Infrared Physics & Technology, 2014, 62: 50-58
- [19] X. Dong, X. Huang, Y. Zheng, et al. Infrared dim and small target detecting and tracking method inspired by human visual system[J]. Infrared Physics & Technology, 2014, 62: 100-109
- [20] C. P. Chen, H. Li, Y. Wei, et al. A local contrast method for small infrared target detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(1): 574-581
- [21] J. Han, K. Liang, B. Zhou, et al. Infrared small target detection utilizing the multiscale relative local contrast measure[J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(4): 612-616
- [22] I. S. Reed, R. M. Gagliardi, L. B. Stotts. Optical moving target detection with 3D matched filtering[J]. IEEE Transactions on Aerospace and Electronic Systems, 1988, 24(4): 327-336
- [23] R. W. Fries. Three dimensional matched filtering[C]. Infrared Systems and Components III, Los Angeles, 1989, 19-28
- [24] A. Aridgides. Adaptive three-dimensional spatio-temporal filtering techniques for infrared clutter suppression[C]. Signal and Data Processing of Small Targets, Los Angeles, 1990, 63
- [25] M. Li, T. Zhang, W. Yang, et al. Moving weak point target detection and estimation with three-dimensional double directional filter in ir cluttered background[J]. Optical Engineering, 2005, 44(10): 107007
- [26] T. Zhang, M. Li, Z. Zuo, 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
- [27] 赵小明, 袁胜春, 马晓丽, 等. 基于移动式管道滤波的红外小目标检测方法研究 [J]. 红外技术, 2009, 31(5): 295-297
- [28] S. D. Blostein, T. S. Huang. Detecting small, moving objects in image sequences using sequential hypothesis testing[J]. IEEE Transactions on Signal Processing, 1991, 39(7): 1611-1629

- [29] T. W. Bae, B. I. Kim, Y. C. Kim, et al. Small target detection using cross product based on temporal profile in infrared image sequences[J]. *Computers & Electrical Engineering*, 2010, 36(6): 1156-1164
- [30] R. Succary, A. Cohen, P. Yaractzi, et al. Dynamic programming algorithm for point target detection: practical parameters for DPA[C]. *Signal and Data Processing of Small Targets*, San Diego, 2001, 96-101
- [31] Y. Yu, L. Guo. Infrared small moving target detection using facet model and particle filter[C]. *Congress on Image and Signal Processing*, Sanya, 2008, 206-210
- [32] M. Wan, G. Gu, E. Cao, et al. In-frame and inter-frame information based infrared moving small target detection under complex cloud backgrounds[J]. *Infrared Physics & Technology*, 2016, 76: 455-467
- [33] Z. Z. Li, J. Chen, Q. Hou, et al. Sparse representation for infrared dim target detection via a discriminative over-complete dictionary learned online[J]. *Sensors*, 2014, 14(6): 9451-9470
- [34] Z. Z. Li, Z. Dai, H. Fu, et al. Dim moving target detection algorithm based on spatio-temporal classification sparse representation[J]. *Infrared Physics & Technology*, 2014, 67: 273-282
- [35] Z. Z. Li, Q. Hou, H. Fu, et al. Infrared small moving target detection algorithm based on joint spatio-temporal sparse recovery[J]. *infrared physics & Technology*, 2015, 69: 44-52
- [36] W. Wang, H. Qin, W. Cheng, et al. Small target detection in infrared image using convolutional neural networks[C]. *Optical Sensing and Imaging Technology and Applications*, Beijing, 2017, 1046250
- [37] Z. Fan, D. Bi, L. Xiong, et al. Dim infrared image enhancement based on convolutional neural network[J]. *Neurocomputing*, 2018, 272: 396-404
- [38] Q. Liu, X. Lu, Z. He, et al. Deep convolutional neural networks for thermal infrared object tracking[J]. *Knowledge-Based Systems*, 2017, 134: 189-198
- [39] Z. Cui, J. Yang, S. Jiang, et al. An infrared-small-target detection method in compressed sensing domain based on local segment contrast measure[J]. *Infrared Physics & Technology*, 2018, 93: 41-52
- [40] H. Zhu, Y. Guan, L. Deng, et al. Infrared moving point target detection based on an anisotropic spatial-temporal fourth-order diffusion filter[J]. *Computers & Electrical Engineering*, 2018, 68: 550-556
- [41] J. Liu, Z. He, Z. Chen, et al. Tiny and dim infrared target detection based on weighted local contrast[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 99): 1-5

-
- [42] A. Tikhonov, V. Y. Arsenin. *Methods for solving ill-posed problems*[M]. John Wiley and Sons, Inc, 1977
- [43] G. E. Backus, J. Gilbert. Numerical applications of a formalism for geophysical inverse problems[J]. *Geophysical Journal International*, 1967, 13(1-3): 247-276
- [44] G. Backus, F. Gilbert. The resolving power of gross earth data[J]. *Geophysical Journal International*, 1968, 16(2): 169-205
- [45] A. Tarantola. *Inverse problem theory and methods for model parameter estimation*[M]. SIAM, 2005
- [46] M. Elad, M. Aharon. Image denoising via sparse and redundant representations over learned dictionaries[J]. *IEEE Transactions on Image processing*, 2006, 15(12): 3736-3745
- [47] K. Dabov, A. Foi, V. Katkovnik, et al. Image denoising by sparse 3D transform-domain collaborative filtering[J]. *IEEE Transactions on image processing*, 2007, 16(8): 2080-2095
- [48] M. Protter, M. Elad. Image sequence denoising via sparse and redundant representations[J]. *IEEE Transactions on Image Processing*, 2009, 18(1): 27-35
- [49] D. Guo, X. Qu, X. Du, et al. Salt and pepper noise removal with noise detection and a patch-based sparse representation[J]. *Advances in Multimedia*, 2014, 2014(1): 1-14
- [50] T. Lu, S. Li, L. Fang, et al. Spectral-spatial adaptive sparse representation for hyperspectral image denoising[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(1): 373-385
- [51] A. M. Adam. Sparse representation and non-negative matrix factorization for image denoise[J]. *Journal of Computer Science Approaches*, 2017, 4(1): 337-341
- [52] J. Yang, J. Wright, T. S. Huang, et al. Image super-resolution via sparse representation[J]. *IEEE transactions on image processing*, 2010, 19(11): 2861-2873
- [53] S. Mallat, G. Yu. Super-resolution with sparse mixing estimators[J]. *IEEE transactions on image processing*, 2010, 19(11): 2889-2900
- [54] W. Dong, L. Zhang, G. Shi, et al. Image deblurring and super-resolution by adaptive sparse domain selection and adaptive regularization[J]. *IEEE Transactions on Image Processing*, 2011, 20(7): 1838-1857
- [55] W. Dong, F. Fu, G. Shi, et al. Hyperspectral image super-resolution via non-negative structured sparse representation[J]. *IEEE Transactions on Image Processing*, 2016, 25(5): 2337-2352
- [56] J. Jiang, J. Ma, C. Chen, et al. Noise robust face image super-resolution through smooth sparse representation[J]. *IEEE transactions on cybernetics*, 2017, 47(11): 3991-4002

- [57] J. Mairal, M. Elad, G. Sapiro. Sparse representation for color image restoration[J]. IEEE Transactions on image processing, 2008, 17(1): 53-69
- [58] J. Mairal, F. Bach, J. Ponce, et al. Non-local sparse models for image restoration[C]. IEEE International Conference on Computer Vision, 2009, 2272-2279
- [59] B. Yang, S. Li. Multifocus image fusion and restoration with sparse representation[J]. IEEE Transactions on Instrumentation and Measurement, 2010, 59(4): 884-892
- [60] W. Dong, L. Zhang, G. Shi. Centralized sparse representation for image restoration[C]. IEEE International Conference on Computer Vision (ICCV), 2011, 1259-1266
- [61] J. Zhang, D. Zhao, W. Gao. Group-based sparse representation for image restoration[J]. IEEE Transactions on Image Processing, 2014, 23(8): 3336-3351
- [62] W. He, H. Zhang, L. Zhang, et al. Total-variation-regularized low-rank matrix factorization for hyperspectral image restoration[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(1): 178-188
- [63] G. Yuan, B. Ghanem. l_0 TV: A sparse optimization method for impulse noise image restoration[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 1-1
- [64] S. Agarwal, A. Awan, D. Roth. Learning to detect objects in images via a sparse, part-based representation[J]. IEEE transactions on pattern analysis and machine intelligence, 2004, 26(11): 1475-1490
- [65] V. Cevher, A. Sankaranarayanan, M. F. Duarte, et al. Compressive sensing for background subtraction[C]. European Conference on Computer Vision, Marseille, 2008, 155-168
- [66] Y. Chen, N. M. Nasrabadi, T. D. Tran. Sparse representation for target detection in hyperspectral imagery[J]. IEEE Journal of Selected Topics in Signal Processing, 2011, 5(3): 629-640
- [67] J. J. Zhao, Z. Y. Tang, J. Yang, et al. Infrared small target detection based on image sparse representation[J]. Journal of Infrared and Millimeter Waves, 2011, 2: 12
- [68] H. Zhang, N. M. Nasrabadi, Y. Zhang, et al. Multi-view automatic target recognition using joint sparse representation[J]. IEEE Transactions on Aerospace and Electronic Systems, 2012, 48(3): 2481-2497
- [69] H. Sun, X. Sun, H. Wang, et al. Automatic target detection in high-resolution remote sensing images using spatial sparse coding bag-of-words model[J]. IEEE Geoscience and Remote Sensing Letters, 2012, 9(1): 109-113

- [70] J. Zhang, J. Tan, Y. Zhang. Joint sparse tensor representation for the target detection of polarized hyperspectral images[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(12): 2235-2239
- [71] M. Wan, G. Gu, W. Qian, et al. Total variation regularization term-based low-rank and sparse matrix representation model for infrared moving target tracking[J]. Remote Sensing, 2018, 10(4): 510
- [72] . 光电图像处理及应用 author=彭真明, year=2013, address=成都, pages=25-31, publisher=电子科技大学出版社 [M]. ,
- [73] 王晓阳, 彭真明, 张萍, 等. 局部对比度结合区域显著性红外弱小目标检测 [J]. 强激光与粒子束, 2015, 9: 091005-1 - 091005-7
- [74] Z. Peng, X. Zheng, S. Yang, et al. Real-time detection and recognition of infrared beacons in opto-electronic guiding system[C]. International Conference on Experimental Mechanics, Nanjing, 2009, 73752A
- [75] M. R. Hestenes. Multiplier and gradient methods[J]. Journal of optimization theory and applications, 1969, 4(5): 303-320
- [76] M. J. Powell. A method for non-linear constraints in minimization problems[M]. New York: UKAEA, 1967, 283 - 298
- [77] J. Eckstein, D. P. Bertsekas. On the douglas—rachford splitting method and the proximal point algorithm for maximal monotone operators[J]. Mathematical Programming, 1992, 55(1-3): 293-318
- [78] Y. Z. J. F. Yang. Alternating direction algorithms for L1-problems in compressive sensing[J]. SIAM Journal on Scientific Computing, 2011, 33(1): 250-278
- [79] M. V. Afonso, J. M. Bioucas-Dias, M. A. Figueiredo. Fast image recovery using variable splitting and constrained optimization[J]. IEEE transactions on image processing, 2010, 19(9): 2345-2356
- [80] A. Neumaier. Solving ill-conditioned and singular linear systems: A tutorial on regularization[J]. SIAM review, 1998, 40(3): 636-666
- [81] M. D. Iordache, J. M. Bioucas Dias, A. Plaza. Total variation spatial regularization for sparse hyperspectral unmixing[J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 50(11): 4484-4502
- [82] 孔德辉. 基于压缩感知的地震数据重建及若干问题研究 [D]. 成都: 电子科技大学, 2017, 48-74

- [83] X. X. Zhu, R. Bamler. Tomographic sar inversion by l_1 -norm regularization —the compressive sensing approach[J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(10): 3839-3846
- [84] R. Marxer, J. Janer. A tikhonov regularization method for spectrum decomposition in low latency audio source separation[C]. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Kyoto, 2012, 277-280
- [85] C. Jordan. Sur la series de fourier[J]. CR Acad. Sci., Paris, 1881, 92: 228-230
- [86] L. I. Rudin, S. Osher, E. Fatemi. Nonlinear total variation based noise removal algorithms[J]. Physica D: nonlinear phenomena, 1992, 60(1-4): 259-268
- [87] J. P. Oliveira, J. M. Bioucas-Dias, M. A. Figueiredo. Adaptive total variation image deblurring: a majorization–minimization approach[J]. Signal Processing, 2009, 89(9): 1683-1693
- [88] T. F. Chan, C.-K. Wong. Total variation blind deconvolution[J]. IEEE transactions on Image Processing, 1998, 7(3): 370-375
- [89] A. Beck, M. Teboulle. A fast iterative shrinkage-thresholding algorithm for linear inverse problems[J]. SIAM journal on imaging sciences, 2009, 2(1): 183-202
- [90] W. Yin, D. Goldfarb, S. Osher. A comparison of three total variation based texture extraction models[J]. Journal of Visual Communication and Image Representation, 2007, 18(3): 240-252
- [91] M. Liu, X. Chen, X. Wang. Latent fingerprint enhancement via multi-scale patch based sparse representation[J]. IEEE Transactions on Information Forensics and Security, 2015, 10(1): 6-15
- [92] D. Kong, Z. Peng. Seismic random noise attenuation using shearlet and total generalized variation[J]. Journal of Geophysics Engineering, 2015, 12(6): 1024-1035
- [93] A. Beck, M. Teboulle. Fast gradient-based algorithms for constrained total variation image denoising and deblurring problems[J]. IEEE Transactions on Image Processing, 2009, 18(11): 2419-2434
- [94] E. J. Candès, X. Li, Y. Ma, et al. Robust principal component analysis?[J]. Journal of the ACM, 2011, 58(3): 11
- [95] C. Eckart, G. Young. The approximation of one matrix by another of lower rank[J]. Psychometrika, 1936, 1(3): 211-218
- [96] S. S. Chen, D. L. Donoho, M. A. Saunders. Atomic decomposition by basis pursuit[J]. SIAM review, 2001, 43(1): 129-159
- [97] J. Liu, P. Musialski, P. Wonka, et al. Tensor completion for estimating missing values in visual data[J]. IEEE transactions on pattern analysis and machine intelligence, 2013, 35(1): 208-220

- [98] P. Favaro, R. Vidal, A. Ravichandran. A closed form solution to robust subspace estimation and clustering[C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Colorado Springs, 2011, 1801-1807
- [99] X. Zhou, C. Yang, W. Yu. Moving object detection by detecting contiguous outliers in the low-rank representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(3): 597-610
- [100] X. Y. Wang, Z. M. Peng, D. Kong, et al. Infrared dim target detection based on total variation regularization and principal component pursuit[J]. Image and Vision Computing, 2017, 63: 1-9
- [101] J. F. Cai, E. J. Candès, Z. Shen. A singular value thresholding algorithm for matrix completion[J]. SIAM Journal on Optimization, 2010, 20(4): 1956-1982
- [102] C. B. Li. An efficient algorithm for total variation regularization with applications to the single pixel camera and compressive sensing[D]. Houston: Rice University, 2010, 37-39
- [103] Z. Lin, M. Chen, Y. Ma. The augmented lagrange multiplier method for exact recovery of corrupted low-rank matrices[arXiv Preprint]. <https://arxiv.org/pdf/1009.5055.pdf>, Oct 18, 2013, arXiv
- [104] Z. Li, J. Liu, J. Tang, et al. Robust structured subspace learning for data representation[J]. IEEE transactions on pattern analysis and machine intelligence, 2015, 37(10): 2085-2098
- [105] F. De La Torre, M. J. Black. A framework for robust subspace learning[J]. International Journal of Computer Vision, 2003, 54(1-3): 117-142
- [106] D. Cai, X. He, Y. Hu, et al. Learning a spatially smooth subspace for face recognition[C]. IEEE Conference on Computer Vision and Pattern Recognition, Minneapolis, 2007, 1-7
- [107] C. W. Gear. Multibody grouping from motion images[J]. International Journal of Computer Vision, 1998, 29(2): 133-150
- [108] G. Liu, S. Yan. Latent low-rank representation for subspace segmentation and feature extraction[C]. IEEE International Conference on Computer Vision (ICCV), Barcelona, 2011, 1615-1622
- [109] Y. Ma, H. Derksen, W. Hong, et al. Segmentation of multivariate mixed data via lossy data coding and compression[J]. IEEE transactions on pattern analysis and machine intelligence, 2007, 29(9):
- [110] S. Wold, K. Esbensen, P. Geladi. Principal component analysis[J]. Chemometrics and intelligent laboratory systems, 1987, 2(1-3): 37-52

- [111] M. A. Hearst, S. T. Dumais, E. Osuna, et al. Support vector machines[J]. *IEEE Intelligent Systems and their applications*, 1998, 13(4): 18-28
- [112] J. Huang, X. Huang, D. Metaxas. Learning with dynamic group sparsity[C]. *IEEE 12th International Conference on Computer Vision*, Kyoto, 2009, 64-71
- [113] G. Liu, Z. Lin, Y. Yu. Robust subspace segmentation by low-rank representation[C]. *27th International conference on machine learning*, Haifa, 2010, 663-670
- [114] X. Y. Wang, Z. M. Peng, D. Kong, et al. Infrared dim and small target detection based on stable multisubspace learning in heterogeneous scene[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(10): 5481-5493
- [115] Y. He, M. Li, J. Zhang, et al. Small infrared target detection based on low-rank and sparse representation[J]. *Infrared Physics & Technology*, 2015, 68: 98-109
- [116] C. Yang, H. Liu, S. Liao, et al. Small target detection in infrared video sequence using robust dictionary learning[J]. *Infrared Physics & Technology*, 2015, 68: 1-9
- [117] L. Li, H. Li, T. Li, et al. Infrared small target detection in compressive domain[J]. *Electronics Letters*, 2014, 50(7): 510-512
- [118] R. Tomioka, T. Suzuki, M. Sugiyama, et al. A fast augmented lagrangian algorithm for learning low-rank matrices[C]. *27th International Conference on Machine Learning*, Haifa, 2010, 1087-1094
- [119] X. Shu, F. Porikli, N. Ahuja. Robust orthonormal subspace learning: Efficient recovery of corrupted low-rank matrices[C]. *IEEE Conference on Computer Vision and Pattern Recognition*, Columbus, 2014, 3874-3881
- [120] E. J. Candes, Y. Plan. Matrix completion with noise[J]. *Proceedings of the IEEE*, 2010, 98(6): 925-936
- [121] M. Chen, A. Ganesh, Z. Lin, et al. Fast convex optimization algorithms for exact recovery of a corrupted low-rank matrix[Coordinated Science Laboratory Report]. http://perception.csl.illinois.edu/matrix-rank/Files/rpca_algorithms.pdf, 2009, Control Systems Laboratory, University of Illinois at Urbana-Champaign
- [122] Y. Xu, W. Yin. A block coordinate descent method for regularized multiconvex optimization with applications to nonnegative tensor factorization and completion[J]. *SIAM Journal on imaging sciences*, 2013, 6(3): 1758-1789
- [123] P. Tseng. Convergence of a block coordinate descent method for nondifferentiable minimization[J]. *Journal of optimization theory and applications*, 2001, 109(3): 475-494

- [124] 钟露. 复杂背景下红外弱小目标的正演模拟与仿真技术研究 [D]. 成都: 电子科技大学, 2016, 37-50
- [125] P. Pérez, M. Gangnet, A. Blake. Poisson image editing[J]. *ACM Transactions on graphics*, 2003, 22(3): 313-318
- [126] Z. Zhang, Y. Xu, J. Yang, et al. A survey of sparse representation: algorithms and applications[J]. *IEEE access*, 2015, 3: 490-530
- [127] D. L. Donoho. Compressed sensing[J]. *IEEE Transactions on information theory*, 2006, 52(4): 1289-1306
- [128] E. J. Candès, J. Romberg, T. Tao. Robust uncertainty principles: Exact signal reconstruction from highly incomplete frequency information[J]. *IEEE Transactions on information theory*, 2006, 52(2): 489-509
- [129] M. Elad, M. A. Figueiredo, Y. Ma. On the role of sparse and redundant representations in image processing[J]. *Proceedings of the IEEE*, 2010, 98(6): 972-982
- [130] A. M. Bruckstein, D. L. Donoho, M. Elad. From sparse solutions of systems of equations to sparse modeling of signals and images[J]. *SIAM review*, 2009, 51(1): 34-81
- [131] Y. Xu, D. Zhang, J. Yang, et al. A two-phase test sample sparse representation method for use with face recognition[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2011, 21(9): 1255-1262
- [132] J. Wright, Y. Ma, J. Mairal, et al. Sparse representation for computer vision and pattern recognition[J]. *Proceedings of the IEEE*, 2010, 98(6): 1031-1044
- [133] E. J. Candes, J. K. Romberg, T. Tao. Stable signal recovery from incomplete and inaccurate measurements[J]. *Communications on pure and applied mathematics*, 2006, 59(8): 1207-1223
- [134] D. L. Donoho. For most large underdetermined systems of linear equations the minimal l_1 -norm solution is also the sparsest solution[J]. *Communications on pure and applied mathematics*, 2006, 59(6): 797-829
- [135] S. Becker, J. Bobin, E. J. Candès. NESTA: A fast and accurate first-order method for sparse recovery[J]. *SIAM Journal on Imaging Sciences*, 2011, 4(1): 1-39
- [136] R. P. Rao, B. A. Olshausen, M. S. Lewicki. Probabilistic models of the brain: Perception and neural function[M]. Cambridge: MIT press, 2002, 39-41
- [137] J. Wright, A. Y. Yang, A. Ganesh, et al. Robust face recognition via sparse representation[J]. *IEEE transactions on pattern analysis and machine intelligence*, 2009, 31(2): 210-227

- [138] J. Zhao, Z. Tang, J. Yang, et al. Infrared small target detection using sparse representation[J]. *Journal of Systems Engineering and Electronics*, 2011, 22(6): 897-904
- [139] X. T. Yuan, X. B. Liu, S. C. Yan. Visual classification with multitask joint sparse representation[J]. *IEEE Transactions on Image Processing*, 2012, 21(10): 4349-4360
- [140] G. Obozinski, B. Taskar, M. I. Jordan. Joint covariate selection and joint subspace selection for multiple classification problems[J]. *Statistics and Computing*, 2010, 20(2): 231-252
- [141] M. Yuan, Y. Lin. Model selection and estimation in regression with grouped variables[J]. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 2006, 68(1): 49-67
- [142] X. Chen, W. Pan, J. T. Kwok, et al. Accelerated gradient method for multi-task sparse learning problem[C]. *IEEE International Conference on Data Mining (ICDM)*, Miami, 2009, 746-751
- [143] M. Kowalski. Sparse regression using mixed norms[J]. *Applied and Computational Harmonic Analysis*, 2009, 27(3): 303-324
- [144] J. Canny. A computational approach to edge detection[J]. *Readings in Computer Vision*, 1987, 184-203
- [145] N. Dalal, B. Triggs. Histograms of oriented gradients for human detection[C]. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, San Diego, 2005, 886-893
- [146] H. Mohimani, M. Babaie-Zadeh, C. Jutten. A fast approach for overcomplete sparse decomposition based on smoothed ℓ^0 norm[J]. *IEEE Transactions on Signal Processing*, 2009, 57(1): 289-301
- [147] N. E. Huang, Z. Shen, S. R. Long, et al. The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis[C]. *Proceedings of the Royal Society of London A: mathematical, physical and engineering sciences*, 1998, 903-995
- [148] Y. Wang, Z. M. Peng, Y. M. He. Instantaneous attributes analysis of seismic signals using improved hht[J]. *Journal of Earth Science*, 2015, 26(4): 515-521
- [149] J. C. Nunes, Y. Bouaoune, E. Delechelle, et al. Image analysis by bidimensional empirical mode decomposition[J]. *Image and vision computing*, 2003, 21(12): 1019-1026
- [150] K. Khaldi, A. Boudraa. Audio watermarking via emd[J]. *IEEE transactions on audio, speech, and language processing*, 2013, 21(3): 675-680
- [151] S. Meignen, V. Perrier. A new formulation for empirical mode decomposition based on constrained optimization[J]. *IEEE Signal Processing Letters*, 2007, 14(12): 932-935

- [152] N. Pustelnik, P. Borgnat, P. Flandrin. A multicomponent proximal algorithm for empirical mode decomposition[C]. European Signal Processing Conference (EUSIPCO), Bucharest, 2012, 1880-1884
- [153] K. Dragomiretskiy, D. Zosso. Variational mode decomposition[J]. IEEE transactions on signal processing, 2014, 62(3): 531-544
- [154] K. Dragomiretskiy, D. Zosso. Two-dimensional variational mode decomposition[C]. International Workshop on Energy Minimization Methods in Computer Vision and Pattern Recognition, Venice, 2015, 197-208
- [155] S. Lahmiri, M. Boukadoum. Physiological signal denoising with variational mode decomposition and weighted reconstruction after dwt thresholding[C]. IEEE International Symposium on Circuits and Systems (ISCAS), Lisbon, 2015, 806-809
- [156] S. Lahmiri. High-frequency-based features for low and high retina haemorrhage classification[J]. Healthcare technology letters, 2017, 4(1): 20
- [157] S. Qi, D. Ming, J. Ma, et al. Robust method for infrared small-target detection based on boolean map visual theory[J]. Applied optics, 2014, 53(18): 3929-3940
- [158] L. Yang, J. Yang, K. Yang. Adaptive detection for infrared small target under sea-sky complex background[J]. Electronics Letters, 2004, 40(17): 1083-1085
- [159] X. Y. Wang, Z. M. Peng, P. Zhang, et al. Infrared small target detection via nonnegativity-constrained variational mode decomposition[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(10): 1700-1704
- [160] P. Wang, J. Tian, C. Q. Gao. Infrared small target detection using directional highpass filters based on ls-svm[J]. Electronics letters, 2009, 45(3): 156-158
- [161] 蒋鹏. 图像内容显著性检测的理论和方法研究 [D]. 济南: 山东大学, 2016, 11-13
- [162] A. Oliva, A. Torralba, M. S. Castelhana, et al. Top-down control of visual attention in object detection[C]. International Conference on Image Processing (ICIP), Barcelona, 2003, 250 - 253
- [163] D. Gao, N. Vasconcelos. Bottom-up saliency is a discriminant process[C]. IEEE International Conference on Computer Vision (ICCV), Rio de Janeiro, 2007, 1-6
- [164] V. Mahadevan, N. Vasconcelos. Spatiotemporal saliency in dynamic scenes[J]. IEEE transactions on pattern analysis and machine intelligence, 2010, 32(1): 171-177
- [165] G. Zhang, Z. Yuan, N. Zheng, et al. Visual saliency based object tracking[C]. Asian conference on computer vision, Xi'an, 2009, 193-203

- [166] K. Rapantzikos, Y. Avrithis, S. Kollias. Dense saliency-based spatiotemporal feature points for action recognition[C]. IEEE Conference on Computer Vision and Pattern Recognition, Miami, 2009, 1454-1461
- [167] J. Han, Y. Ma, B. Zhou, et al. A robust infrared small target detection algorithm based on human visual system[J]. IEEE Geoscience and Remote Sensing Letters, 2014, 11(12): 2168-2172
- [168] X. Wang, G. Lv, L. Xu. Infrared dim target detection based on visual attention[J]. Infrared Physics & Technology, 2012, 55(6): 513-521
- [169] C. Yang, J. Ma, M. Zhang, et al. Multiscale facet model for infrared small target detection[J]. Infrared Physics & Technology, 2014, 67: 202-209
- [170] Y. Han, P. Zhang, C. Fei, et al. Infrared small target detection based on spatio-temporal saliency in video sequence[C]. International Computer Conference on Wavelet Active Media Technology and Information Processing, Chengdu, 2015, 279-282
- [171] Y. Li, Y. Zhang, J.-G. Yu, et al. A novel spatio-temporal saliency approach for robust dim moving target detection from airborne infrared image sequences[J]. information sciences, 2016, 369: 548-563
- [172] Z. Cui, J. Yang, S. Jiang, et al. An infrared small target detection algorithm based on high-speed local contrast method[J]. Infrared physics & technology, 2016, 76: 474-481
- [173] J. Wu, G. Shi, W. Lin, et al. Just noticeable difference estimation for images with free-energy principle[J]. IEEE Transactions on Multimedia, 2013, 15(7): 1705-1710
- [174] A. Buades, B. Coll, J.-M. Morel. A non-local algorithm for image denoising[C]. IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), San Diego, 2005, 60-65
- [175] 张桦, 夏一行, 周文晖, 等. 基于注意转移机制的图像质量评价方法 [J]. 仪器仪表学报, 2010, 31(9): 2056-2061
- [176] J. Zhang, S. Sclaroff. Saliency detection: A boolean map approach[C]. IEEE International Conference on Computer Vision (ICCV), Sydney, 2013, 153-160
- [177] L. Itti, C. Koch, E. Niebur. A model of saliency-based visual attention for rapid scene analysis[J]. IEEE Transactions on pattern analysis and machine intelligence, 1998, 20(11): 1254-1259
- [178] N. D. Bruce, J. K. Tsotsos. Saliency, attention, and visual search: An information theoretic approach[J]. Journal of vision, 2009, 9(3): 5-5

- [179] A. Borji, L. Itti. Exploiting local and global patch rarities for saliency detection[C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Providence, 2012, 478-485
- [180] V. A. Lamme. The neurophysiology of figure-ground segregation in primary visual cortex[J]. Journal of Neuroscience, 1995, 15(2): 1605-1615
- [181] L. Q. Huang, H. Pashler. A boolean map theory of visual attention.[J]. Psychological review, 2007, 114(3): 599
- [182] S. E. Palmer. Vision science: Photons to phenomenology[M]. Cambridge: MIT press, 1999, 13-15
- [183] A. Asundi, Z. Wensen. Fast phase-unwrapping algorithm based on a gray-scale mask and flood fill[J]. Applied optics, 1998, 37(23): 5416-5420
- [184] X. Y. Wang, Z. M. Peng, P. Zhang. Boolean map saliency combined with motion feature used for dim and small target detection in infrared video sequences[C]. Infrared Technology and Applications, and Robot Sensing and Advanced Control, Beijing, 2016, 1015712-1 - 1015712-7
- [185] M. T. López, A. Fernández-Caballero, M. A. Fernández, et al. Motion features to enhance scene segmentation in active visual attention[J]. Pattern Recognition Letters, 2006, 27(5): 469-478
- [186] H. Li, Y. Wei, L. Li, et al. Similarity learning for object recognition based on derived kernel[J]. Neurocomputing, 2012, 83: 110-120
- [187] H. Deng, J. Liu, Z. Chen. Infrared small target detection based on modified local entropy and emd[J]. Chinese Optics Letters, 2010, 8(1): 24-28
- [188] M. Fazel, H. Hindi, S. P. Boyd. A rank minimization heuristic with application to minimum order system approximation[C]. American Control Conference, Arlington, 2001, 4734-4739
- [189] N. Srebro, J. Rennie, T. S. Jaakkola. Maximum-margin matrix factorization[C]. Conference on Neural Information Processing Systems, Vancouver, 2005, 1329-1336

攻读博士学位期间取得的成果

一、已发表的学术论文

- [1] **X.Y. Wang**, Z.M. Peng*, D.H. Kong, Y.M. He. Infrared dim and small target detection based on stable multisubspace learning in heterogeneous scene[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(10): 5481-5493. (SCI: FK6ZH)
- [2] **X.Y. Wang**, Z.M. Peng*, D.H. Kong, P. Zhang, Y.M. He. Infrared dim target detection based on total variation regularization and principal component pursuit[J]. Image and Vision Computing, 2017, 63: 1-9. (SCI: EY9IN)
- [3] **X.Y. Wang**, Z.M. Peng*, P. Zhang, Y.M. He. Infrared small target detection via nonnegativity-constrained variational mode decomposition[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(10): 1700-1704. (SCI: FL1FX)
- [4] Y.Q. Wang, Z.M. Peng*, **X.Y. Wang**, Y.M. He. Matching pursuit-based sliced Wigner higher order spectral analysis for seismic signals[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 10(8): 3821-3828. (SCI: FD7KY)
- [5] M.H. Li, Z.M. Peng*, Y.P. Chen, **X.Y. Wang**, L.B. Peng, Z.R. Wang, G.H. Yuan, Y.M. He. A novel reverse sparse model utilizing the spatio-temporal relationship of target templates for object tracking[J]. Neurocomputing, 2018. (SCI)
- [6] 王晓阳, 彭真明*, 张萍, 孟晔铭. 局部对比度结合区域显著性红外弱小目标检测 [J]. 强激光与粒子束, 2015, 27(9): 091005-1-7. (EI: 20154301444447)
- [7] **X.Y. Wang**, Z.M. Peng*, P. Zhang. Boolean map saliency combined with motion feature used for dim and small target detection in infrared video sequences[C]. International Symposium on Optoelectronic Technology and Application, Beijing, 2016: 1015712-1-7. (EI: 20170503310183)
- [8] Y. Han, P. Zhang*, C. Fei, **X.Y. Wang**. Infrared small target detection based on spatial saliency in video sequence[C]. International Computer Conference on Wavelet Active Media Technology and Information, Chengdu, 2015: 279-282. (EI: 20162902615825)
- [9] S.Q. Huang, M.H. Li, **X.Y. Wang**, X.G. Zhao, L.F. Yang, Z.M. Peng*. Infrared small target detection with directional difference of Gaussian filter[C]. IEEE International Conference on Computer and Communications, Chengdu, 2017:1698-1701.
- [10] R.C. Hu, **X.Y. Wang**, Y.C. Zheng, Z.M. Peng*. Moving target detection and tracking for smart-phone automatic focusing[J]. ZTE Communications, 2017, 15(1): 55-60.

二、申请专利

- [1] 彭真明, 王晓阳, 陈响, 王酉祥, 黄苏琦, 龙鸿峰, 杨琛, 范文澜, 王慧, 马沪敏, 蒲恬, 何艳敏, 一种基于非负约束 2D 变分模态分解的红外弱小目标检测方法 [P]. 中国, 发明专利

- 利, 申请号: 201710093303.6, 申请日期: 2017-02-21
- [2] 彭真明, 王晓阳, 张帆, 钟露, 孔德辉, 江阳, 浦洋, 张倩, 一种基于“谱”反演的红外图像增强与重建方法 [P]. 中国, 发明专利, 专利号: ZL201410811549.9, 授权日期: 2017-05-10
- [3] 彭真明, 王雨青, 李新彦, 王晓阳, 孔德辉, 何艳敏, 田琳, 一种基于匹配追踪的 Wigner 高阶谱地震信号谱分解方法 [P]. 中国, 发明专利, 专利号: ZL201510815579.1, 授权日期: 2017-09-07
- [4] 王俊, 刘延利, 彭真明, 王晓阳, 杨春平, 李霞, 云层图像检测方法 [P]. 中国, 发明专利, 申请号: 201710345541.1, 申请日期: 2017-05-16
- [5] 彭真明, 张天放, 曹思颖, 吕昱霄, 黄苏琦, 王晓阳, 彭凌冰, 刘雨菡, 杨昕梅, 蒲恬, 杨春平, 一种空中背景下的红外弱小目标检测方法 [P]. 中国, 发明专利, 申请号: 201810768557.8, 申请日: 2018-07-13
- [6] 彭真明, 李美惠, 陈科, 潘嵩, 陈颖频, 王晓阳, 孙伟嘉, 任丛雅旭, 卓励然, 蒲恬, 张萍, 一种多模板时空关联的局部反联合稀疏表示目标跟踪方法 [P]. 中国, 发明专利, 申请号: 201710100030.3, 申请日期: 2017-02-23.
- [7] 李健, 彭真明, 李美惠, 龙鸿峰, 曹思颖, 何艳敏, 王卓然, 杨立峰, 黄苏琦, 王晓阳, 赵学功, 一种烟草收购重复过磅行为自动视觉检测与识别方法 [P]. 中国, 发明专利, 申请号: 2017106970024, 申请日期: 2017-08-15

三、参与科研项目

- [1] 中央高校基本科研业务费项目 (A03012099901013), 空间时敏红外弱小目标检测新技术研究, 主持人, 研究年限: 2015.09-2016.09
- [2] 中科院光束控制重点实验室基金课题 (2014LBC002), 基于正演模拟和稀疏动态反演的红外弱小目标检测, 主研人, 研究年限: 2014.08-2016.06
- [3] 国家自然科学基金 (61571096), 结合背景特性与目标正演的稀疏动态反演空间红外弱小目标检测方法, 主研人, 研究年限: 2016.01-2019.12
- [4] 中国航天科工集团二院 xxx 所合作课题: × 波段仿真图像自适应滤波及粒子滤波算法研究及实现, 参与人, 研究年限: 2015.04-2015.07
- [5] 中国科学院光束控制重点实验室基金 (2017LBC003), 时空谱多特征融合空间时敏红外目标检测与跟踪方法研究, 参与人, 研究年限: 2017.08-2019.06