http://sjcj.nuaa.edu.cn E-mail:sjcj@nuaa.edu.cn Tel/Fax: +86-025-84892742

# 低秩张量子空间学习红外小目标检测

王 衍<sup>1</sup>, 胡宏博<sup>2</sup>, 彭真明<sup>2</sup>

(1. 北京空间机电研究所,北京 100094;2. 电子科技大学信息与通信工程学院,成都 611731)

摘 要: 红外目标检测系统是可靠探测和识别背景辐射与其他干扰条件下高价值目标的有效技术手段之一,广泛应用于各个领域。红外弱小目标检测作为系统的重要组成部分,仍是当前具有挑战性的关键核心技术。本文提出了一种基于低秩张量子空间学习的方法,该方法在考虑序列在空时连续一致性的同时,也保留了红外图像结构的完整性。通过空时滑动窗获得空时张量块模型,利用多子空间学习策略构建不同场景下的红外张量字典模型。最后,采用最优化算法求解所提出的红外张量目标函数,获得低秩背景和稀疏目标张量,通过重构图像检测出感兴趣的红外弱小目标。实验结果表明,在复杂背景高反虚警环境及组合强干扰场景下,该方法目标检测性能优于其他现有检测算法。
 关键词:空时结构张量;低秩稀疏逼近;子空间学习;红外小目标检测;组合干扰场景
 中图分类号: TP391

# Infrared Small Target Detection Based on Low-Rank Tensor Subspace Learning

WANG Yan<sup>1</sup>, HU Hongbo<sup>2</sup>, PENG Zhenming<sup>2</sup>

(1. Beijing Institute of Space Mechanics & Electricity, Beijing 100094, China; 2. School of Information and Communication Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China)

**Abstract**: Infrared target detection system is one of the effective technical means for reliably detecting and identifying high-value targets under the conditions of background radiation and other interferences, and it is widely used in various fields. Infrared weak target detection, as an important part of the system, is still a challenging key core technology at present. In this paper, a method based on low-rank tensor spatial learning is proposed, which preserves the structural integrity of the infrared image while considering the consistency of the sequences in the spatio-temporal continuum. The spatio-temporal tensor block model is obtained through a spatio-temporal sliding window, and the infrared tensor dictionary model is constructed under different scenes using a multi-subspace learning strategy. Finally, an optimization algorithm is used to solve the proposed infrared tensor objective function to obtain the low-rank background and sparse target tensor, and the interested infrared weak targets are detected by reconstructing the image. Experimental results show that the method outperforms other existing detection algorithms for target detection in complex-background environments with high-reflection-induced false alarms and combined strong interference scenarios.

**Key words:** spatio-temporal structure tensor; low-rank sparse approximation; subspace learning; infrared small target detection; combined interference scenarios

基金项目:四川省自然科学基金(2025ZNSFSC0522);国家自然科学基金(61571096)。

# 引 言

红外探测具有全天候工作、夜视范围广、远距离探测、背景冗余信息少、穿透力强和抗干扰等优点, 广泛应用于天基探测、地面和海洋监控搜救等领域。在空间探测、灾害预警和工业缺陷检测等方面,红 外弱小目标的检测更具有重要意义<sup>[1-2]</sup>。由于成像距离较远,当目标尺寸小于探测器成像空间分辨力 时,目标在探测器像面上的成像属于点目标或斑点目标,尺寸一般不超过9像素×9像素,并且没有纹理 结构和几何形状等特征。在一幅128像素×128像素的图像中,目标大小约为整幅图像的0.49%。再加 上受复杂的自然背景、各类随机噪声杂波及大气辐射散射等诸多不确定因素的干扰<sup>[34]</sup>,造成红外图像 信噪比较低,更有目标几乎被背景淹没的极端情况发生。虽然红外弱小目标在单帧图像中具有随机 性,但是在多帧序列图像中,相邻帧间的目标位置却具有一定的时间相关性。红外时敏目标在探测器 像面上的速度一般能达到1~2像素/帧,因此具有红外时敏目标的图像经多帧累积后,往往能得到一条 连续的带有上下波动的轨迹曲线。同时在常用的军事领域红外图像中,如天空背景、海面背景、地面背 景及其组合背景,其绝大部分像素的灰度值变化是缓慢且均匀的,相邻像素的灰度值在空间上相关性 强。对于天基下视遥感卫星视频成像,其序列图像中相邻帧间图像的背景变化较之目标变化十分缓 慢,使得背景在时间域上同样具有相关性。

目前,国内外学者针对红外弱小目标序列检测已经提出多种检测算法。传统的空时滤波类算法虽 然具有实现简单、实时性好等优点,在简单的场景下也能达到不错的效果,但是对噪声和杂波极其敏 感,鲁棒性较低<sup>[56]</sup>。如何有效抑制背景和噪声、提高目标的检测能力、降低虚警,一直是红外搜索与跟 踪系统的关键环节和亟待解决的难点问题。

近年来提出的空时张量法是矩阵低秩稀疏分解方法的高阶推广,包含空间维度和时间维度,描述 目标随时间在空间中的动态变化信息。张量具有对高维数据强大的表示和降维能力,在挖掘序列图像 块在空时帧间的潜在特征相关关系的同时,还能够保持原有红外图像数据的完整局部先验结构,被普 遍应用于低秩稀疏分解问题的研究中。空时张量法同空时局部对比度方法一样,在当前帧中提取一个 滑动窗口,并与相邻帧在空时域中形成一个空时立方体,建立一个空时张量模型<sup>[79]</sup>。Gao等<sup>[10]</sup>针对复 杂背景噪声的特殊稀疏噪声分量,对小目标检测问题进行空时噪声建模,利用马尔科夫随机场和高斯 混合噪声模型分离目标与噪声。Sun等<sup>[11-13]</sup>将空时张量模型分别与加权p范数、全变分正则化和多子空 间学习相结合,对背景建模来分离目标和噪声,通过实验测试不同奇异值、正则化参数和数据结构,证 明这些方法的优越性和鲁棒性。Zhang等<sup>[14]</sup>提出了一种新的基于边和角感知的空时张量模型,通过边 缘和角落的可调节重要性测量来突出显示目标,同时还采用基于张量的非局部总变分来描述背景中的 边缘。Pang等<sup>[15]</sup>开发了一种具有显著滤波正则化的空时张量模型来检测小的红外目标。根据目标的 稀疏先验和背景的局部相关性,目标与背景的分离可以投射为低秩稀疏张量分解问题,再通过张量分 解从稀疏张量获得目标。

然而,空时张量法在面对不同场景时需要对超参数的选择进行严格的敏感性调整,还无法做到面 对场景的自适应检测。本文提出一种低秩张量子空间学习算法TMSL,针对如今空时算法在面向不同 噪声杂波分别干扰和复杂场景组合下的鲁棒性较低的问题,利用子空间强大的自适应表述能力,将复 杂高维的各种图像分量表示为具有独特重要信息的低秩张量特征。实验表明,本文算法充分地利用了 空时的上下文信息,在复杂背景的红外视频中获得了相对不错的检测性能。

本文的核心贡献可归纳为以下3方面:(1)提出支持多个组合复杂场景的抗虚警干扰强的多子空间 特征学习机制;(2)提出计算效率更高的核范数分解框架及其优化算法;(3)提出低秩多子空间红外弱 小目标检测的空时张量学习策略。

### 1 红外小目标检测

#### 1.1 空时块张量模型

在红外图像处理领域,图像主要是由被动成像的背景图像信号数据以及主动成像的目标图像信号数据组成。由于背景受红外元器件以及大气成像环境干扰等影响,背景占据图像面积大且内部元素之间具有高的空时内聚性,所以假设包含背景图像的信号可以被描述为低秩矩阵。对应的目标邻域图像由于成像距离限制以及采集设备精度等因素,通常表现为像素面积小且稀疏地分布在红外图像中,所以认为目标属于稀疏矩阵,同时在传播和接收时受随机加性噪声的污染,具体可表示为如下模型<sup>[16]</sup>

$$I(x, y) = B(x, y) + T(x, y) + N(x, y)$$
(1)

式中:x和y分别为各个图像信号分量的水平坐标和垂直坐标;I(x,y,t)表示输入的红外图像信号在坐标(x,y)处的数值;B(x,y)表示背景图像信号的灰度数值;T(x,y)表示目标图像信号的灰数值;N(x,y)表示随机加性噪声的强度概率分布。

为了充分地利用红外序列的帧间信息具有 时间连续性和空间一致性的时域约束条件,在 单帧低秩稀疏模型的基础上,通常采用空时块 张量模型的构建方法。首先在输入的红外序列 图像中依次按从前到后、从左到右、从上到下的 顺序滑动一个固定步长和固定大小的窗口,遍 历得到一系列的图像块;然后按前后顺序进行 堆叠,得到新的红外块图像张量序列,如图1所 示。具体可得到如下模型



图1 空时块张量构建示意图

Fig.1 Illustration of spatial-temporal patch tensor construction

$$\mathcal{X}(x, y, t) = \mathcal{B}(x, y, t) + \mathcal{T}(x, y, t) + \mathcal{N}(x, y, t)$$
(2)

式中:t表示块图像的当前序列位数; $\mathcal{X}(x, y, t)$ 表示输入的红外块图像分量在坐标(x, y, t)处的数值;  $\mathcal{B}(x, y, t)$ 表示背景块图像分量的灰度数值; $\mathcal{T}(x, y, t)$ 表示目标块图像信号的灰度数值; $\mathcal{N}(x, y, t)$ 表示随机加性噪声分量的强度概率分布。

#### 1.2 低秩张量子空间学习

鲁棒主成分分析(Robust principal component analysis, RPCA)<sup>[17]</sup>在其主成分追踪公式中,将图像矩阵 *I* 分离为其低秩分量矩阵 *B* 和稀疏分量矩阵 *T*。因此将 RPCA 模型应用到红外空时块张量模型的具体表述如下

$$\begin{cases} \min_{\boldsymbol{\mathcal{B}}, \mathcal{T}, \mathcal{N}} \|\boldsymbol{\mathcal{B}}\|_{*} + \lambda_{1} \|\boldsymbol{\mathcal{T}}\|_{p} + \lambda_{2} \|\boldsymbol{\mathcal{N}}\|_{Q} \\ \text{s.t.} \; \boldsymbol{\mathcal{X}} = \boldsymbol{\mathcal{B}} + \boldsymbol{\mathcal{T}} + \boldsymbol{\mathcal{N}} \end{cases}$$
(3)

式中:  $\mathcal{X} \in \mathbb{R}^{n_1 \times n_2 \times n_3}$ 表示输入的红外块图像张量( $n_1, n_2, n_3$ 分别表示张量的第一、二、三维度);  $\mathcal{B} \in \mathbb{R}^{n_1 \times n_2 \times n_3}$ 表示背景图像分量;  $\mathcal{T} \in \mathbb{R}^{n_1 \times n_2 \times n_3}$ 表示目标及其局部区域图像分量;  $\mathcal{N} \in \mathbb{R}^{n_1 \times n_2 \times n_3}$ 表示噪 声分布;  $\|\cdot\|_*$  为核范数,  $\|\cdot\|_p$ 为 L<sub>p</sub>范数(本文 P=1);  $\|\cdot\|_Q$ 为 L<sub>Q</sub>范数(本文 Q=2);  $\lambda_1, \lambda_2$ 为调谐正则化 因子。

原始的低秩稀疏方法能够检测出背景成分单一时的红外小目标,这等价于利用单个低秩子空间的 方法来重构背景分量。但当背景中存在森林、建筑及云层等纹理复杂的虚警源甚至组合成异构场景 时,将背景分量看成单一子空间进行求解的方法通常不能完整描述红外序列图像。本文利用相似背景 分量的低秩性,以及不同虚警源之间的正交性,假设红外序列图像是由多个低秩子空间构成,其可被表 示为

$$\begin{cases} \min_{\mathcal{B},\mathcal{I},\mathcal{N}} \| \mathcal{B} \|_{*} + \lambda_{1} \| \mathcal{W} \circ \mathcal{T} \|_{P} + \lambda_{2} \| \mathcal{N} \|_{Q} \\ \text{s.t.} \ \mathcal{X} = \mathcal{B} + \mathcal{T} + \mathcal{N}, \ \mathcal{B} = \mathcal{D} * \mathcal{Z} \end{cases}$$
(4)

式中:  $\mathcal{W}$ 表示局部先验矩阵结构信息构建的先验结构张量; "\*"表示张量乘积; "。"为 Hadamard 乘积, 表示每个相同位置像素间的运算;  $\mathcal{D} \in \mathbb{R}^{n_1 \times r \times n_3}$ 表示多子空间字典(r表示字典的秩);  $\mathcal{Z} \in \mathbb{R}^{r \times n_2 \times n_3}$ 表示多子空间字典对应的系数。具体算法流程如图2所示。



图 2 基于低秩张量子空间学习的红外小目标检测整体架构图

Fig.2 Structure of infrared small target detection based on low-rank tensor subspace learning

文献[18-19]证明的核范数的一个引理,表达式为
$$\begin{cases} \|\boldsymbol{\mathcal{B}}\|_{*} = \min_{\mathcal{D}, \boldsymbol{\mathcal{Z}}} \frac{1}{2} (\|\boldsymbol{\mathcal{D}}\|_{F}^{2} + \|\boldsymbol{\mathcal{Z}}\|_{F}^{2}) \\ \text{s.t.} \quad \boldsymbol{\mathcal{B}} = \boldsymbol{\mathcal{D}} * \boldsymbol{\mathcal{Z}} \end{cases}$$

式中:||•||<sub>F</sub>为F范数。

由

假设多子空间字典 D 是列正交的,这对应于 D 的列向量是低秩的,则式(5)可被表示为

$$\begin{cases} \|\boldsymbol{\mathcal{B}}\|_{*} = \min_{\boldsymbol{\mathcal{Z}}} \|\boldsymbol{\mathcal{Z}}\|_{2,1} \\ \text{s.t.} \quad \boldsymbol{\mathcal{B}} = \boldsymbol{\mathcal{D}} * \boldsymbol{\mathcal{Z}}, \ \boldsymbol{\mathcal{D}}_{i}^{\mathrm{H}} * \boldsymbol{\mathcal{D}}_{i} = \boldsymbol{\mathcal{E}}_{i}, \quad \forall i \in \{1, 2, \cdots, r\} \end{cases}$$
(6)

(5)

式中: $\|\cdot\|_{2,1}$ 为L<sub>21</sub>范数; $\mathcal{E}_i$ 表示任意维度下的单位张量。

将式(6)代入式(4),得到

$$\begin{cases} \min_{\mathcal{Z},\mathcal{I},\mathcal{N}} \| \mathcal{Z} \|_{2,1} + \lambda_1 \| \mathcal{W} \circ \mathcal{T} \|_P + \lambda_2 \| \mathcal{N} \|_Q \\ \text{s.t.} \mathcal{X} = \mathcal{D} * \mathcal{Z} + \mathcal{T} + \mathcal{N}, \ \mathcal{D}_i^{\mathsf{H}} * \mathcal{D}_i = \mathcal{E}_i, \quad \forall i \in \{1, 2, \cdots, r\} \end{cases}$$
(7)

#### 2 模型迭代求解优化算法

将式(7)的部分约束写成增广拉格朗日函数,表达式为

$$\begin{cases} L(\boldsymbol{\mathcal{Z}}, \boldsymbol{\mathcal{T}}, \boldsymbol{\mathcal{N}}, \boldsymbol{\mathcal{Y}}_{1}, \boldsymbol{\mathcal{Y}}_{2}) = \|\boldsymbol{\mathcal{Z}}\|_{2,1} + \lambda_{1}\| \boldsymbol{\mathcal{W}} \circ \boldsymbol{\mathcal{T}}\|_{P} + \lambda_{2}\| \boldsymbol{\mathcal{N}}\|_{Q} + \\ \langle \boldsymbol{\mathcal{Y}}_{1}, \boldsymbol{\mathcal{X}} - \boldsymbol{\mathcal{D}} * \boldsymbol{\mathcal{Z}} - \boldsymbol{\mathcal{T}} - \boldsymbol{\mathcal{N}} \rangle + \frac{\mu}{2} \| \boldsymbol{\mathcal{X}} - \boldsymbol{\mathcal{D}} * \boldsymbol{\mathcal{Z}} - \boldsymbol{\mathcal{T}} - \boldsymbol{\mathcal{N}} \|_{F}^{2} \\ \text{s.t. } \boldsymbol{\mathcal{D}}_{i}^{H} * \boldsymbol{\mathcal{D}}_{i} = \boldsymbol{\mathcal{E}}_{i}, \forall i \in \{1, 2, \cdots, r\} \end{cases}$$
(8)

式中: $\mu$ 为拉格朗日惩罚项,是一个正则化参数; $\mathcal{Y}_1$ 、 $\mathcal{Y}_2$ 表示拉格朗日乘子项; $\langle a, b \rangle = tr(a^{H*b})$ ,其中

王 衍 等:低秩张量子空间学习红外小目标检测

tr(•)为迹函数。

本文通过使用交替方向乘子法来更新式(9~14),第 k次迭代后各个子问题更新如下。 更新 **R**:通过施密特正交化求解剩余约束 **R**,表达式为

$$\begin{cases} \boldsymbol{\mathcal{R}}_{i}^{k} = \boldsymbol{\mathcal{X}} - \boldsymbol{\mathcal{T}}^{k} - \boldsymbol{\mathcal{N}}^{k} + \frac{\boldsymbol{\mathcal{Y}}_{i}^{k}}{\mu^{k}} - \sum_{j < i} \boldsymbol{\mathcal{D}}_{j}^{k+1} * \boldsymbol{\mathcal{Z}}_{j}^{k+1} - \sum_{j > i} \boldsymbol{\mathcal{D}}_{j}^{k} * \boldsymbol{\mathcal{Z}}_{j}^{k} \\ \boldsymbol{\mathcal{R}}_{i}^{k} = \boldsymbol{\mathcal{R}}_{i}^{k} - \sum_{j=1}^{i-1} \boldsymbol{\mathcal{D}}_{j}^{k+1} * (\boldsymbol{\mathcal{D}}_{j}^{k+1})^{\mathrm{H}} * \boldsymbol{\mathcal{R}}_{i}^{k} \end{cases}$$

$$\tag{9}$$

更新 **D**:对于子空间字典 **D**,将上述 R 与字典系数 **Z**进行张量乘积,可得 **D**参数的更新式,表达 式为

$$\boldsymbol{\mathcal{D}}_{i}^{k+1} = \boldsymbol{\mathcal{R}}_{i}^{k} * (\boldsymbol{\mathcal{Z}}_{i}^{k})^{\mathrm{H}}$$

$$(10)$$

更新 Z:对于多子空间字典对应的系数 Z,表达式为

$$\boldsymbol{\mathcal{Z}}_{i}^{k+1} = \frac{1}{\left\|\boldsymbol{\mathcal{D}}_{i}^{k+1}\right\|_{2}} \overline{\boldsymbol{\mathcal{S}}}_{\frac{1}{\mu^{i}}} \left( \left(\boldsymbol{\mathcal{D}}_{i}^{k+1}\right)^{\mathrm{H}} \ast \boldsymbol{\mathcal{R}}_{i}^{k} \right)$$
(11)

式中: $\overline{S}$ 表示求解 $\mathcal{D}$ 的秩的阈值算子。

更新 au:对于目标及其局部区域图像分量 au,在任意参数 P下的范数  $L_P$ 求解可使用式(12),这需要 使用 Hadamard 乘积进行逐像素求解,然而当 P=1时公式退化到可用软阈值算子求解。

$$\mathcal{T}^{k+1} = \arg\min_{\mathcal{T}} \lambda_{1} \| \mathcal{W} \circ \mathcal{T}^{k} \|_{P} + \frac{\mu^{k}}{2} \left\| \mathcal{T}^{k} + \mathcal{D}_{*} \mathcal{Z}^{k+1} + \mathcal{N}^{k} - \mathcal{X} - \frac{\mathcal{Y}_{1}^{k}}{\mu^{k}} \right\|_{F}^{2} \Rightarrow \left( \lambda_{1} \| \mathcal{W} \circ \mathcal{T}^{k} \|_{P}^{1-P} * \left( \mathcal{W} \circ \mathcal{T}^{k} \right)^{\circ (P-1)} + \mu^{k} \left( \mathcal{T}^{k} + \mathcal{A}^{k} \right) = 0 \right) = S_{\frac{\lambda_{1}}{\mu^{k}}} \left( \mathcal{X} - \mathcal{D}_{*} \mathcal{Z}^{k+1} - \mathcal{N}^{k+1} + \frac{\mathcal{Y}_{1}^{k}}{\mu^{k}} \right)$$
(12)

式中:S表示软阈值算子; $\mathcal{A}^{k} = \mathcal{D}*\mathcal{Z}^{k+1} + \mathcal{N}^{k} - \mathcal{X} - \mathcal{Y}_{1}^{k}/\mu^{k}$ 。

更新*N*:对于噪声分布*N*,同样地在任意参数*Q*下的范数L<sub>*Q*</sub>的求解可使用式(13),当*Q*=2时公式可退化到常规梯度求导进行求解。

$$\mathcal{N}^{k+1} = \arg\min_{\mathcal{N}} \lambda_{2} \| \mathcal{N}^{k} \|_{Q} + \frac{\mu^{k}}{2} \left\| \mathcal{N}^{k} + \mathcal{D}_{*} \mathcal{Z}^{k+1} + \mathcal{T}^{k+1} - \mathcal{X} - \frac{\mathcal{Y}_{1}^{k}}{\mu^{k}} \right\|_{F}^{2} \Rightarrow \\ \left( \lambda_{2} \| \mathcal{N}^{k} \|_{Q}^{1-Q} * (\mathcal{N}^{k})^{\circ (Q-1)} + \mu^{k} (\mathcal{N}^{k} + \mathcal{C}^{k}) = 0 \right) = \\ \frac{1}{\mu^{k} + \lambda_{2} / \| \mathcal{N}^{k} \|_{F}} (\mathcal{Y}_{1}^{k} + \mu^{k} (\mathcal{X} - \mathcal{D}_{*} \mathcal{Z}^{k+1} - \mathcal{T}^{k}))$$

$$(13)$$

式中: $\mathcal{C}^{k} = \mathcal{D}_{*}\mathcal{Z}^{k+1} + \mathcal{T}^{k+1} - \mathcal{X} - \mathcal{Y}_{l}^{k}/\mu^{k}$ 。

同时更新拉格朗日乘子项 *Υ*和惩罚项μ,表达式为

$$\begin{cases} \boldsymbol{\mathcal{Y}}_{1}^{k+1} = \boldsymbol{\mathcal{Y}}_{1}^{k} + \mu_{k} (\boldsymbol{\mathcal{X}} - \boldsymbol{\mathcal{D}}_{*} \boldsymbol{\mathcal{Z}}^{k+1} - \boldsymbol{\mathcal{T}}^{k+1} - \boldsymbol{\mathcal{N}}^{k+1}) \\ \mu_{k+1} = \min(\gamma \mu_{k}, \mu_{\max}) \end{cases}$$
(14)

式中: $\gamma$ 表示收敛项,r>1才能保证算法最终得到收敛,具体设置为1.1; $\mu_{max}$ 为最大迭代惩罚项,越大收 敛速度越慢,具体设置为1.31。

算法的更新终止条件为

$$\begin{cases} \max\left(\left\|\boldsymbol{\mathcal{Z}}_{k+1}-\boldsymbol{\mathcal{Z}}_{k}\right\|_{\infty},\left\|\boldsymbol{\mathcal{T}}_{k+1}-\boldsymbol{\mathcal{T}}_{k}\right\|_{\infty},\left\|\boldsymbol{\mathcal{N}}_{k+1}-\boldsymbol{\mathcal{N}}_{k}\right\|_{\infty}\right) \leq \epsilon \\ \max\left(\left\|\boldsymbol{\mathcal{X}}-\boldsymbol{\mathcal{D}}^{*}\boldsymbol{\mathcal{Z}}_{k+1}-\boldsymbol{\mathcal{T}}_{k+1}-\boldsymbol{\mathcal{N}}_{k+1}\right\|_{\infty}\right) \leq \epsilon \\ \operatorname{iter} \leq \operatorname{iter}_{\max} \end{cases}$$
(15)

式中: *ϵ*表示绝对误差,本文取值10e-6; iter表示迭代次数; iter<sub>max</sub>表示最大迭代次数,本文具体设置为200次。具体步骤在算法1中给出。

算法1 TMSL的ADMM求解器

输入:

红外序列图像模型  $\mathcal{X} \in \mathbb{R}^{n_1 \times n_2 \times n_3}$ ;

初始化张量分量  $\mathcal{D}^0 = \operatorname{zeros}(n_1, r, n_3), \mathcal{Z}^0 = \operatorname{zeros}(r, n_2, n_3), r = 50; \mathcal{T}^0 = \mathcal{N}^0 = \mathcal{Y}^0 = \operatorname{zeros}(n_1, n_2, n_3); //\operatorname{zeros}(\bullet) 表示 MATLAB 中的赋全零函数。$ 

初始化迭代参数  $t_0 = 1 < 200$ ,  $\mu_0 = 0.11 > 0$ ,  $\mu_{max} = 1.31$ ,  $\gamma = 1.1 > 1$ ,  $\epsilon = 10e - 6$ ;  $//\mu_0$  数值不宜 太小,否则会使多子空间字典  $\mathcal{D}^0$ 和系数  $\mathcal{Z}^0$ 的秩收缩至很小,这个收缩是不可逆的过程,因此取值 0.11。 输出:

(1)while 不收敛 do (2)如式(9)更新  $\mathcal{R}_{i}^{k}$ ; (3)如式(10)更新  $\mathcal{D}_{i}^{k+1}$ ; (4)如式(11)更新  $\mathcal{Z}_{i}^{k+1}$ ; (5)如式(12)更新  $\mathcal{T}^{k+1}$ ; (6)如式(13)更新  $\mathcal{N}^{k+1}$ ; (7)如式(14)更新  $\mathcal{Y}_{1}^{k+1}$ 和 $\mu_{k+1}$ ; (8)if 满足式(15) (9) break; (10)end if (11)  $t_{k+1} = t_{k} + 1$ ; (12) end while

#### 3 实验结果分析

#### 3.1 实验数据

本文使用Anti-UAV410红外图像数据集<sup>[20]</sup>。该数据集共包含410个已标注的视频序列,每条序列 长度为1500张图像,尺寸大小为640像素×512像素。本文测试了数据集中的6条红外序列,具体包括 大面积森林的场景1,建筑和天空的场景2,大面积森林和建筑的场景3,大面积天空和部分森林的场景 4,配有屏幕操作界面的场景5,以及部分杂草和天空背景的场景6。

#### 3.2 评价指标

红外弱小目标检测常用的评价指标有:ROC(Receiver operating characteristic)曲线,PR(Precision-recall)曲线,上述两种曲线与坐标轴所包围形成的面积,即AUC(Area under curve)值和AP(Average precision)值,以及检测速率FPS(Frames per second)。

ROC曲线是衡量目标漏检率的基本指标,其横纵坐标假阳率FPR和真阳率TPR,对混淆矩阵中漏

检FN和虚检FP的评价指标,具体表达式为

$$FPR = \frac{FP}{FP + TN}$$
(16)

$$TPR = \frac{TP}{TP + FN}$$
(17)

式中:TN表示背景;TP表示目标。

PR曲线是衡量目标漏检率和目标虚检率的基本评价指标,其横纵坐标的召回率Recall和精确率 Precision分别是对混淆矩阵中漏检FN和虚检FP的评价指标,表达式为

$$\operatorname{Recall} = \frac{\operatorname{TP}}{\operatorname{TP} + \operatorname{FN}}$$
(18)

$$Precision = \frac{1P}{TP + FP}$$
(19)

当混淆矩阵的检测阈值以固定的步长在区间[0,1]取值时,TP、FP、FN和TN则会相应地变化。 以假阳率FPR为横轴,真阳率TPR为纵轴作图,能够得到一个完整的ROC曲线。同理,以召回率Recall为横轴,精确率Precision为纵轴作图,能够得到一个完整的PR曲线。

AUC 值和 AP 值通常能更直观地表示目标检测算法的性能,定义为

$$AUC = \sum_{k=1}^{N} TPR(k) \cdot \Delta FPR(k)$$
(20)

$$AP = \sum_{k=1}^{N} P(k) \cdot \Delta R(k)$$
(21)

式中: TPR(k)为当前区间 TPR的平均值;  $\Delta$ FPR(k)表示由 FPR组成的当前区间; P(k)为当前区间 Precision 的平均值;  $\Delta R(k)$ 表示由 Recall组成的当前区间。在实际应用中,要求在召回率较高的基础 上,尽量使精确率越高越好。一般来说, AUC和 AP的值越高代表检测的准确性越高, 虚检率越低。

FPS表示的是目标检测算法每秒可以检测多少帧图像,相当于算法的刷新频率,与平均单帧检测时间*t*互为倒数关系,表达式为

$$FPS = \frac{1}{t}$$
(22)

#### 3.3 检测性能对比

在6条不同的红外序列图像上运行8种不同的典型算法(IPI<sup>[21]</sup>,MPCM<sup>[22]</sup>,NRAM<sup>[23]</sup>,PSTNN<sup>[24]</sup>, RIPT<sup>[25]</sup>,TMESNN<sup>[26]</sup>,LogTFNN<sup>[27]</sup>,DETR<sup>[28]</sup>)来与本文提出的TMSL算法比较目标检测效果。具体参数设置中,假设滑动窗口的尺寸为(X, Y, Z),滑动步长为( $\Delta x, \Delta y, \Delta z$ ),则 $X \pi Y$ 需要大于背景中虚警源的大小,Z需要小于虚警源的移动距离(即Z帧后,虚警源仍存在于滑动窗口中),本文中设置窗口尺寸X=Y=Z=15像素,通过统计先验匹配后发现,能覆盖Anti-UAV410数据集95%以上的虚警源的空间占位(8~16像素)和时序跨度距离(0~15像素)。 $\Delta x \pi \Delta y$ 需要大于检测目标的大小, $\Delta z$ 需要大于目标移动距离(即 $\Delta z$ 帧后,目标不存在于滑动窗口中),本文设置窗口步长 $\Delta x=\Delta y=\Delta z=8$ 像素,因为红外小目标成像尺寸不超过9像素×9像素,而且 $\Delta z$ 需要满足Nyquist采样定理,确保相邻窗口中目标重叠率,避免目标轨迹断裂(典型运动速度范围0.5~7像素/帧)。所有实验均在Windows 10下的MATLAB R2017a中实现,计算机配置为Intel Core i5-12600KF@3.70 GHz,显卡为NVIDIA GeForce RTX 4090,内存为32 GB。

图3展示了9种对比算法的目标检测显著图。其中,真实目标用红色方框标记,虚假检测用蓝色圆 圈标记。从图3可以看出,所提出的TMSL算法在误检率上有着较低的水平;而场景1、4、6的森林高亮 虚警源,场景2、3的建筑高亮虚警源,场景5的屏幕界面高亮虚警源对其他算法都难以判别,这意味着 所提出方法克服了单帧算法和单类子空间算法在复杂场景下虚警率过高的问题。



Fig.3 Target detection saliency maps for nine detection algorithms in six real scenes

图 4 展示了 9 种检测算法在 6 种真实场景中的目标检测 3D 结果图。从图 4 可以看出,所提出的 TMSL算法对不同场景下的误检率都较低,说明该方法适用场景广泛,对于不同异构场景的背景、不同 的加性噪声和不同运动方向的时间敏感目标都具有稳定而准确的检测结果。



图4 9种检测算法在6种真实场景中的目标检测3D结果图

Fig.4 Target detection 3D results for nine detection algorithms in six real scenes

图 5 展示了 9 种检测算法在 6 种真实场景中的 ROC 曲线图。从图 5 可以看出, IPI、MPCM、RIPT 以及所提出的 TMSL算法在 6 种场景中都能得到较高的检测率。不同检测算法的 AUC 和 AP 值对比 如表 1 所示,每列指标中最高值由红色标记,次高值由蓝色标记。从表 1 中看到 TMSL算法的 AP 值可 达 70% 以上, NRAM、PSTNN和 Log TFNN 在前 3 种场景中检测率很低。这说明前 3 种场景出现了大量辐射强度与目标相当甚至超过目标的虚警源,因此基于重叠块类的方法在复杂场景能较好地检测出目标。





图 6 展示了 9 种检测算法在 6 种真实场景中的 PR 曲线图。从图 6 可以看出,所提出的 TMSL算法 在较高的召回率下还能具有较高的精确率,而其他 8 种算法在这类曲线下的评价指标并不突出。这说 明实际数据中经常存在多个低秩子空间相互组合的情况,传统方法和单一子空间的算法难有发挥,而 TMSL 的空时信息约束也进一步降低了误检率。

不同检测算法的单帧平均耗时对比如表2所示。从表2中可以看出,所提出的TMSL算法的子空 间降维模块能显著减少计算复杂度,运行时间与LogTFNN相当,比IPI和RIPT方法的运行速率更快, 说明在计算效率上比一般的空时张量法更高效。虽然在堆叠方式上增加了一定的计算复杂性,但在堆 叠效率上比IPI和RIPT算法更加高效。

表3给出了8种检测算法的算法复杂度。现有的空时张量方法主要计算复杂度瓶颈在于如何逼近 或分解代表背景张量信号分量B的核范数,并迭代更新优化策略。对于IPI和NRAM算法,占主导地位 的因素是对核范数使用奇异值分解,复杂度为O(mn<sup>2</sup>);对于MPCM算法,主要耗时部分是逐个计算每

	140101 000	inputition of the c			erion angorithing	
检测算法	场景1	场景2	场景3	场景4	场景5	场景6
	AUC/AP	AUC/AP	AUC/AP	AUC/AP	AUC/AP	AUC/AP
$\operatorname{IPI}^{[21]}$	0.987 8/0.003 5	0.998 8/0.001 2	0.969 0/0.000 1	0.999 7/0.007 9	0.999 8/0.008 5	0.998 5/0.000 9
MPCM <sup>[22]</sup>	0.922 5/0.002 6	0.498 6/0.000 0	0.944 3/0.000 3	0.997 3/0.000 5	0.999 9/0.012 3	0.998 8/0.174 4
NRAM <sup>[23]</sup>	0.522 9/0.000 2	0.499 8/0.000 0	0.748 3/0.000 5	1.000 0/0.109 9	0.999 9/0.019 9	0.498 4/0.000 0
PSTNN <sup>[24]</sup>	0.508 7/0.000 0	0.500 2/0.000 0	0.494 9/0.000 0	0.999 4/0.002 3	0.999 6/0.003 8	0.999 0/0.056 4
$RIPT^{[25]}$	0.999 9/0.009 8	0.999 6/0.003 0	0.995 5/0.000 4	0.9997/0.0114	0.999 9/0.032 9	0.998 3/0.001 0
TMESNN <sup>[26]</sup>	0.499 9/0.000 0	0.499 9/0.000 0	0.568 9/0.000 0	0.778 2/0.000 0	0.685 4/0.000 0	0.565 0/0.000 0
LogTFNN <sup>[27]</sup>	0.517 3/0.000 0	0.495 0/0.000 0	0.493 5/0.000 0	0.997 2/0.000 5	0.994 8/0.200 7	0.999 0/0.004 7
$\mathrm{DETR}^{[28]}$	0.990 2/0.000 7	0.997 1/0.000 5	0.993 1/0.000 2	0.9997/0.0046	0.999 7/0.005 4	0.994 7/0.000 2
TMSL	0.999 9/0.890 6	1.000 0/0.996 9	1.000 0/0.714 9	1.000 0/0.976 1	1.000 0/0.964 0	0.999 9/0.892 6
$ \begin{array}{c} 1.0\\ 0.9\\ 0.8\\ 0.7\\ 0.6\\ 0.7\\ 0.6\\ 0.5\\ 0.4\\ 0.3\\ 0.7\\ 0.4\\ 0.7\\ 0.4\\ 0.7\\ 0.4\\ 0.7\\ 0.7\\ 0.7\\ 0.7\\ 0.7\\ 0.7\\ 0.7\\ 0.7$	PI IPCM RAM STNN IPT MESNN ogTFNN	1.0 0.9 0.8 0.7 0.6 0.5 0.4 0.3 0.3	IPI MPCM NRAM PSTNN RIPT TMESNN LogTFNN	1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0	.0 .9 .8 .7 .7	

表 1 不同检测算法的 AUC 值和 AP 值对比 Table 1 Comparison of AUC and AP values for different detection algorithms





个滑动窗口内中心像素的显著图,即在单个尺度中,计算成本是 $O(L^2 MN) \sim O(8L^2 MN)$ ,因此总成本 是 $O(L^3 MN)$ ;对于 RIPT、PSTNN、TMESNN和LogTFNN算法,主要计算复杂度来源于核范数的和 (Sum nuclear norm, SNN)的奇异值分解,复杂度为 $O(n_1n_2n_3(n_1n_2 + n_2n_3 + n_1n_3))$ 。特别地,对于

Table 2	Comparison of	average process	sing time per fra	me for different	t detection algor	ithms s
检测算法	场景1	场景2	场景3	场景4	场景5	场景6
$\mathrm{IPI}^{\scriptscriptstyle[21]}$	18.008 9	42.840 5	11.825 3	12.275 2	14.6727	12.651 9
MPCM <sup>[22]</sup>	0.253 0	0.263 7	0.257 6	0.260 3	0.255 4	0.256 9
NRAM <sup>[23]</sup>	0.347 9	0.418 3	0.450 4	0.442 7	0.389 2	0.444 7
PSTNN <sup>[24]</sup>	0.461 2	0.761 6	0.802 6	0.638 7	0.574 8	0.722 9
$\operatorname{RIPT}^{[25]}$	12.052 6	12.423 8	12.366 8	11.850 3	12.897 8	12.348 3
TMESNN <sup>[26]</sup>	0.353 9	0.368 1	0.348 6	0.359 8	0.351 0	0.350 5
$LogTFNN^{[27]}$	3.842 2	3.795 0	3.744 4	3.725 0	3.684 7	3.694 5
DETR <sup>[28]</sup>	0.157 3	0.198 1	0.140 6	0.144 6	0.144 7	0.141 7
TMSL	2.833 4	2.687 6	3.892 5	4.141 1	3.685 3	4.003 6

表2 不同检测算法的单帧平均耗时对比

表3 不同检测算法的复杂度对比

Table	Comparison of complexity for different detection algorithms
检测算法	复杂度
$\operatorname{IPI}^{[21]}$	$O(mn^2)$
MPCM <sup>[22]</sup>	$O(L^3MN)$
NRAM <sup>[23]</sup>	$O(mn^2)$
PSTNN <sup>[24]</sup>	$O(n_1n_2n_3\log(n_1n_2)+n_1n_2^2((n_3+1)/2))$
$\operatorname{RIPT}^{[25]}$	$O(n_1n_2n_3(n_1n_2+n_2n_3+n_1n_3))$
TMESNN <sup>[26]</sup>	$O\left(\prod_{i=1}^{l}n_{i}+\sum_{i=1}^{l-1}\left(\left(\prod_{k=1}^{i}n_{k}\cdot\prod_{k=i+1}^{l}n_{k}\right)\cdot\min\left(\prod_{k=1}^{i}n_{k},\prod_{k=i+1}^{l}n_{k}\right)\right)\right)$
LogTFNN <sup>[27]</sup>	$O\left(n_1n_2n_3\log(n_1n_2n_3) + \sum_{i=1}^{3}\min(n_i, n_{i+1})\right)$
TMSL	$O\left(rn_1n_2n_3 ight)$

TMESNN算法,两个子问题的复杂度分别为 $O\left(\prod_{i=1}^{l} n_i\right)$ 和 $O\left(\sum_{i=1}^{l-1} \min(p_i^2 q_i, p_i q_i^2)\right)$ ,其中 $p_i = \prod_{k=1}^{i} n_k, q_i =$ 

 $\prod_{k=i+1}^{l} n_k$ ;对于本文TMSL算法,由于避免使用奇异值分解,而是背景秩估计的方法。这显著降低了复杂度,具体由子空间维数r和张量块大小决定,即 $O(rn_1n_2n_3)$ 。上述中,(M,N)分别表示原始图像的高和宽;(m,n)分别表示图像块的高和宽;L表示滑动窗的边长尺寸。本文实验初始值设置为r=50,大多数场景的秩最终迭代至r=4左右。

#### 3.4 检测性能消融

典型的红外小目标成像尺寸特性为不超过9像素×9像素的斑点状目标,所以参数选择与目标尺寸 呈尺寸无关性。图7展示了目标及其局部区域图像分量**7**的超参数 $\lambda_1$ 在5个不同数量级下对3种不同 真实场景虚警源类型的算法检测性能。当超参数过小,比如 $\lambda_1$ =0.0001时,检测结果的虚警率很高,因 为此时场景中的高频边缘成分基本都保存了下来;而超参数过大,比如 $\lambda_1$ =0.1甚至更高时,无论多少 次迭代,都会导致检测结果无法保留任何高频和高亮信息,所以漏检率极高。值得注意的是,在大多数





Fig.7 ROC and PR curves of the parameter  $\lambda_1$  for different values in three real scenes

场景中若将 $\lambda_1$ 设置在[10e<sup>-3</sup>, 10e<sup>-2</sup>]区间都会在保证较低漏检率(TPR  $\land$  、Recall  $\land$ )的情况下具有较低 虚警率(FPR  $\checkmark$ )和较高的检测性能(Precision  $\land$ ),即多子空间算法在面对森林、建筑、卷云等以及不同 组合虚警源场景中都具有一定的场景鲁棒性。本文最终设置 $\lambda_1 = 0.003$ 。

图8展示了噪声分布  $\mathcal{N}$ 的超参数 $\lambda_2$ 在5个不同数量级下3种不同真实场景虚警源类型的算法检测性能。与超参数 $\lambda_1$ 不同,为了尽量抑制噪声分量对目标分量的影响,实验中需要调低超参数 $\lambda_2$ 的占比, 其数量级区间基本与超参数 $\lambda_1$ 相同。同样地,多子空间算法依旧表现出了在面对多数复杂以及组合虚 警源场景中也能保证一定的场景鲁棒性,本文最终设置 $\lambda_2 = 0.001$ 。本文还分析了TMSL算法对超参 数的敏感性,发现对 $\lambda$ 参数偏离较大的扰动可能导致模型的正则化约束行为失效,不正确的参数设置甚 至会造成训练时间延长。然而,在图7,8多个场景中的验证显示, $\lambda$ 在最优参数区间中取值会有良好的 场景泛化性与检测鲁棒性。

图 9,10 展示了不同方差的高斯噪声干扰下,TMSL算法对各种极端模拟场景的检测鲁棒性表现。 目标函数中已假设噪声是高斯分布的(||*N*||<sub>2</sub>),故选择高斯噪声,其均值 mean 为 0,方差 val 取值为 0.000 1~0.01,对应信噪比为 46.33~15.16 dB。当高斯噪声的方差分布小于 0.001 时,算法都有较好的 检测性能。可以验证本文算法对高斯分别的噪声具有一定的鲁棒性。

在极端模拟场景下,如 val=0.01 时,若 $\lambda$ 仍然使用原始最优参数区间的数值,则检测图没有任何输出,即漏检率极高。此时可以适当降低 $\lambda$ 数值( $u\lambda_1 = 0.0008, \lambda_2 = 0.0003$ ),虽然背景图输出能保证干





净清晰,但检测图会输出包含目标在内的较多噪声图。这是由高斯噪声的特性造成的:在val<0.001 时,属于低频平滑噪声,呈磨砂玻璃状,频谱能量集中于低频;在0.001<val<0.01时,属于离散颗粒噪 声,呈椒盐状散点,频谱能量集中于高频;在val>0.01时,属于聚类化斑点噪声,呈小目标状伪影,频谱 能量集中于高频。所以TMSL算法会将极端情况的高斯噪声视为小目标输出至检测图,这是从参数选 择层面无法解决的。不过可以在预处理阶段通过式(4)中 *W*先验结构信息对背景进行优化,以解决极 端干扰场景下的低秩张量子空间学习红外小目标检测。





Fig.10 PR curves in six real scenes with different variance Gaussian noise interference

## 4 结束语

本文通过对背景张量秩在多个低秩张量子空间的改进,充分考虑空时序列图像帧间信息的连续一 致性,保证异构场景数据分布下相似背景内部结构的完整性和不同虚警源之间的正交性,提出了基于 低秩张量子空间学习的红外小目标检测算法TMSL。该方法主要包括对张量模型和多子空间学习的

相互结合,以及利用传统优化算法来求解。通过6种场景的对比实验结果表明,本文算法在遭遇建筑的 灯光、森林和卷云环境等多类型高反虚警及组合场景干扰时,在低虚警率和低漏检率条件下,提高了目 标的检测精度,能满足实时性要求。但是TMSL算法在空时语义信息挖掘方面有待完善,以应对高机 动目标的高精度实时检测。在面对高速变化以及光照变化的场景时,本文算法不能完全检测到所有目 标,仍然会检测出一些虚警分量;在少量场景中会出现无人机被建筑或树林遮挡的情况,本文算法还无 法预测出被遮挡时的目标轨迹,待目标再次出现后将视为不同目标分别检测;此外,还需与目前主流的 深度学习结合,进一步提升算法的场景域适应和可持续学习能力。

#### 参考文献:

- [1] 毛宏霞,刘忠领,田岩.红外辐射与目标识别[M].北京:科学出版社,2022:158.
   MAO Hongxia, LIU Zhongling, TIAN Yan. Infrared radiation and target recognition[M]. Beijing: Science Press, 2022:158.
- [2] 高子航,刘兆英,张婷,等.基于对抗域适应的红外舰船目标分割[J].数据采集与处理,2023,38(3):598-607.
   GAO Zihang, LIU Zhaoying, ZHANG Ting, et al. Infrared ship target segmentation based on adversarial domain adaptation
   [J]. Journal of Data Acquisition and Processing, 2023, 38(3): 598-607.
- [3] 寇人可,王春平,罗迎,等.单帧红外图像多尺度小目标检测技术综述[J].中国图象图形学报,2024,29(9):2625-2649.
   KOU Renke, WANG Chunping, LUO Ying, et al. Multiscale small-target detection techniques in single-frame infrared images: A review[J]. Journal of Image and Graphics, 2024, 29(9): 2625-2649.
- [4] 曹思颖,张弦,蒲恬,等.基于距离加权色偏估计的低质图像增强[J].数据采集与处理,2023,38(1):141-149.
   CAO Siying, ZHANG Xian, PU Tian, et al. Low-quality image enhancement based on distance weighted color cast estimation
   [J]. Journal of Data Acquisition and Processing, 2023, 38(1): 141-149.
- [5] 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, 27(9): 91005.
   WANG Xiaoyang, PENG Zhenming, ZHANG Ping, et al. Infrared small dim target detection based on local contrast combined with region saliency[J]. High Power Laser and Particle Beams, 2015, 27(9): 91005.
- [6] 韩金辉,魏艳涛,彭真明,等.红外弱小目标检测方法综述[J].红外与激光工程,2022,51(4):438-461.
   HAN Jinhui, WEI Yantao, PENG Zhenming, et al. Infrared dim and small target detection: A review[J]. Infrared and Laser Engineering, 2022, 51(4):438-461.
- [7] LIU H K, ZHANG L, HUANG H. Small target detection in infrared videos based on spatio-temporal tensor model[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(12): 8689-8700.
- [8] 栗博,何红艳,王钰,等.面向弱纹理空间目标的特征点匹配方法[J]. 航天返回与遥感, 2024, 45(1): 99-110.
   LI Bo, HE Hongyan, WANG Yu, et al. Feature point matching method for weakly textured spatial objects[J]. Spacecraft Recovery & Remote Sensing, 2024, 45(1): 99-110.
- [9] 骆源, 厉小润, 陈淑涵, 等. 基于四维空时张量的红外小目标检测[J]. 航天返回与遥感, 2024, 45(3): 28-40. LUO Yuan, LI Xiaorun, CHEN Shuhan, et al. Infrared small target detection based on four-dimensional spatial-temporal tensor[J]. Spacecraft Recovery & Remote Sensing, 2024, 45(3): 28-40.
- [10] GAO C, WANG L, XIAO Y, et al. Infrared small-dim target detection based on Markov random field guided noise modeling
   [J]. Pattern Recognition, 2018, 76: 463-475.
- [11] SUN Y, YANG J, LI M, et al. Infrared small target detection via spatial-temporal infrared patch-tensor model and weighted Schatten p-norm minimization[J]. Infrared Physics & Technology, 2019, 102: 103050.
- [12] SUN Y, YANG J, LONG Y, et al. Infrared small target detection via spatial-temporal total variation regularization and weighted tensor nuclear norm[J]. IEEE Access, 2019, 7: 56667-56682.
- [13] SUN Y, YANG J, AN W. Infrared dim and small target detection via multiple subspace learning and spatial-temporal patchtensor model[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(5): 3737-3752.
- [14] ZHANG P, ZHANG L, WANG X, et al. Edge and corner awareness-based spatial-temporal tensor model for infrared smalltarget detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(12): 10708-10724.
- [15] PANG D, MA P, SHAN T, et al. STTM-SFR: Spatial-temporal tensor modeling with saliency filter regularization for

infrared small target detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5623418.

- [16] 彭真明,陈颖频,蒲恬,等.基于稀疏表示及正则约束的图像去噪方法综述[J].数据采集与处理,2018,33(1):1-11. PENG Zhenming, CHEN Yingpin, PU Tian, et al. Image denoising based on sparse representation and regularization constraint: A review[J]. Journal of Data Acquisition and Processing, 2018, 33(1):1-11.
- [17] CANDÈS E J, LI X, MA Y, et al. Robust principal component analysis?[J]. Journal of the ACM, 2011, 58(3): 1-37.
- [18] CANDES E J, PLAN Y. Matrix completion with noise[J]. Proceedings of the IEEE, 2010, 98(6): 925-936.
- [19] SHU X, PORIKLI F, AHUJA N. Robust orthonormal subspace learning: Efficient recovery of corrupted low-rank matrices [C]//Proceedings of 2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus, OH, USA: IEEE, 2014: 3874-3881.
- [20] HUANG B, LI J, CHEN J, et al. Anti-UAV410: A thermal infrared benchmark and customized scheme for tracking drones in the wild[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(5): 2852-2865.
- [21] GAO C, MENG D, YANG Y, et al. Infrared patch-image model for small target detection in a single image[J]. IEEE Transactions on Image Processing, 2013, 22(12): 4996-5009.
- [22] WEI Y, YOU X, LI H. Multiscale patch-based contrast measure for small infrared target detection[J]. Pattern Recognition, 2016, 58: 216-226.
- [23] ZHANG L, PENG L, ZHANG T, et al. Infrared small target detection via non-convex rank approximation minimization joint 12, 1 norm[J]. Remote Sensing, 2018, 10(11): 1821.
- [24] ZHANG L, PENG Z. Infrared small target detection based on partial sum of the tensor nuclear norm[J]. Remote Sensing, 2019, 11(4): 382.
- [25] DAI Y, WU Y. Reweighted infrared patch-tensor model with both nonlocal and local priors for single-frame small target detection[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 10(8): 3752-3767.
- [26] YANG C, KONG X, CAO Z, et al. Cirrus detection based on tensor multi-mode expansion sum nuclear norm in infrared imagery[J]. IEEE Access, 2020, 8: 149963-149983.
- [27] KONG X, YANG C, CAO S, et al. Infrared small target detection via nonconvex tensor fibered rank approximation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 60: 5000321.
- [28] 宋宇轩.面向海洋监测的红外成像舰船目标检测技术研究[D].成都:电子科技大学,2024. SONG Yuxuan. Research on infrared imaging ship target detection technology for ocean monitoring[D]. Chengdu: University of Electronic Science and Technology of China, 2024.

作者简介:



**王衍**(1982-),男,博士,高级 工程师,研究方向:视频电 子学和图像处理技术, E-mail:wyshaonian@aliyun. com。



胡宏博(1999-),通信作者, 男,博士研究生,研究方 向:视频图像处理、机器视 觉及人工智能,E-mail: 1255836405@qq.com。



**彭真明**(1966-),男,博士, 教授,研究方向:遥感图像 处理、机器视觉及人工智 能。

(编辑:张黄群)