

文章编号: 1672-8785(2025)10-0001-22

红外弱小目标检测方法的研究进展

李 果^{1,2} 马昊杰^{2*} 李泽宇² 郭成飞^{2,3*}

(1. 西北工业大学自动化学院, 陕西 西安 710172;

2. 西安电子科技大学杭州研究院, 浙江 杭州 311231;

3. 西安电子科技大学光电工程学院, 陕西 西安 710071)

摘 要: 基于红外探测系统的目标检测技术在安防、预警等领域得到了广泛应用。然而, 由于红外弱小目标具有信号弱和特征尺度小的特点, 在面对复杂应用场景时容易出现漏检、误检、虚警等问题。目前, 基于传统图像处理方法以及基于深度学习算法在红外弱小目标检测方面取得了重大进展。主要讨论了红外弱小目标检测方法的最新研究进展, 涵盖了基于单帧检测方法、多帧检测方法以及深度学习方法, 分析了现有技术的优势和局限性, 总结讨论了未来红外弱小目标检测算法的发展方向。

关键词: 红外成像; 红外探测; 单帧目标检测; 多帧目标检测; 深度学习目标检测

中图分类号: TN215 **文献标志码:** A **DOI:** 10.3969/j.issn.1672-8785.2025.10.001

Infrared Dim and Small Target Detection Methods and Research Progress

LI Guo^{1,2}, MA Hao-jie^{2*}, LI Ze-yu², GUO Cheng-fei^{2,3*}

(1. School of Automation, Northwestern Polytechnical University, Xi'an 710172, China;

2. Hangzhou Institute of Technology, Xidian University, Hangzhou 311231, China;

3. School of Optoelectronic Engineering, Xidian University, Xi'an 710071, China)

Abstract: Target detection technology based on infrared detection systems has been widely used in security, early warning, and other fields. However, due to the weak signal and small feature scale of infrared dim and small targets, problems such as missed detection, false detection, and false alarms are prone to occur in complex application scenarios. Significant progress has been made in infrared dim and small target detection based on traditional image processing methods and deep learning algorithms. This paper discusses the latest research progress in infrared dim and small target detection methods, covering single-frame detection methods, multi-frame detection methods, and deep learning methods. It analyzes the advantages and limitations of existing technologies and summarizes the future development direction of infrared dim and small target detection algo-

收稿日期: 2025-08-22

基金项目: 航空科学基金项目(2024M037081001); 浙江省重点研发计划项目(2025C01197(SD2)); 国家自然科学基金项目(62305258)

作者简介: 李果(1993-), 女, 陕西西安人, 博士研究生, 主要研究方向为控制理论与工程。

***通讯作者:** E-mail: 23191214834@stu.xidian.edu.cn(马昊杰); guochengfei@xidian.edu.cn(郭成飞)

rithms.

Key words: infrared imaging; infrared detection; single-frame-based target detection; multi-frame-based target detection; deep-learning-based target detection

0 引言

红外目标检测技术通过红外成像系统采集目标的红外辐射,利用待检测目标与背景之间红外辐射的差异性实现目标检测与识别。该技术由于自身隐蔽性好、全天候适应性、抗干扰能力强等优势,可以有效弥补传统探测技术的不足甚至实现功能替代,已经成为预警、安防等领域的关键技术手段。

作为红外成像领域的关键挑战之一,红外弱小目标检测目前存在三大难点^[1-3]。首先,红外弱小目标通常具有信号弱和特征尺度小的特点。实际上,红外成像系统在多数应用场景下都需要远距离观测目标,而红外探测器只能在有限的像素和角度内记录目标信息,所以检测到的红外弱小目标具有亮度低、体积小、形状和纹理特征不明显等特点。其次,红外图像中往往存在复杂的背景,如树木、建筑、云层、海浪等。红外图像的复杂背景中具有大量的环境杂波,红外弱小目标信号容易被淹没。因此,红外图像的信噪比较低,在检测过程中容易出现漏检、误检、虚警等问题。最后,随着全球信息化的发展,红外弱小目标检测对实时性提出了更高的要求。

传统的红外弱小目标检测技术主要包括基于单帧图像的检测方法与基于多帧图像的检测方法两大类^[4]。其中,基于单帧图像的检测方法主要利用单帧图像的空间信息进行检测^[5-10],具有计算复杂度低、硬件要求低、实时性好等特点。而在序列图像中,红外弱小目标具有连续性,噪声分布具有随机性,基于多帧图像的检测方法利用序列图像之间的时空相关性^[11-14],通过分析目标与噪声的特征差异来实现红外弱小目标检测。该方法虽然牺牲了检测速度,但具有更好的稳定性和准确性。此

外,近年来,基于深度学习的红外弱小目标检测方法在检测性能上取得了优异的表现。深度学习方法基于数据驱动,通过提取图像深度特征,实现目标的识别与定位,具有良好的鲁棒性,而且可以通过集成注意力机制^[15-17]、特征融合^[18-19]、数据增强^[20]等先进的特征学习策略,将分割算法融入深度学习网络结构,进一步减少检测过程中的虚警以及漏检现象,尤其对于复杂背景下的红外弱小目标检测具有显著优势。然而,目前的深度学习方法存在泛化不足的局限性,训练完成的网络往往只适用于少数特定场景,需要根据工作场景进行优化调整。


本文系统总结了红外弱小目标检测方法的最新进展,包括单帧检测方法、多帧检测方法以及基于深度学习的检测方法,如图 1 所示。通过讨论不同的红外弱小目标检测方法,分析并总结其技术优势与局限性,展望了红外弱小目标检测技术的未来发展趋势,希望能够为相关领域从业人员和研究人员提供参考。

1 单帧检测方法

基于单帧图像的红外弱小目标检测方法主要利用单帧图像的空间信息进行检测,所以该类方法往往具有较低的计算复杂度,硬件要求低,实时性好。现有的基于单帧图像的弱小目标检测方法主要分为三种:基于滤波的方法、基于人类视觉系统(Human Visual System, HVS)的方法以及基于低秩稀疏矩阵分解的方法。

1.1 基于滤波的红外弱小目标检测方法

基于滤波的红外弱小目标检测方法是通过对估计和抑制红外图像的背景来实现弱小目标检测的。根据检测过程中采用的红外背景抑制策略的不同,可以划分为基于空域滤波的方法和基于变换域滤波的方法。

图 1 红外弱小目标检测方法总结^[21]

1.1.1 基于空域滤波的方法

基于空域滤波的方法主要利用小目标与红外图像背景灰度值的差异。这些方法直接对原始图像进行空域滤波来估计红外图像背景, 将原始图像与估计的背景进行差值运算来生成残差图像, 然后对残差图像进行阈值分割, 检测弱小目标。基于空域滤波的经典方法包括最大中值滤波(Max-Median Filters)、最大均值滤波(Max-Mean Filters)、二维最小均方(Two-Dimensional Least Mean Square, TDLMS)、数学形态学(Mathematical Morphology, MM)等。

最大中值滤波和最大均值滤波是在中值滤波和均值滤波的基础上对红外图像进行目标检测的非线性滤波方法^[5]。图 2 所示为检测过程中设置的滑动窗口。在窗口内要计算不同方向上(水平、垂直以及两个对角线方向)的中值和均值的最大值, 用于代替滑动窗口中心像素点(A33)的灰度值, 所以背景估计值近似于该像素点邻域内的平均灰度值。由于红外弱小目标的灰度值与其邻域的平均灰度值存在明显的灰度差异, 原始图像和背景估计在进行差分运算后, 目标区域会具有较大的响应值。显然, 窗




图 2 最大均值/最大中值法的滑动窗口

口尺寸的选择对滤波方法的有效性和检测效率影响较大, 因此窗口大小的选择需要在检测率与虚警率两者之间进行适当的权衡。

二维最小均方法是在最小均方(Least Mean Square, LMS)的基础上发展而来的^[22]。作为一种自适应迭代方法, TDLMS 可以通过滑动窗口并利用当前像元和当前像元邻域的灰度特性来预测背景图像。对于 TDLMS, 收敛步长和滑动窗口的选取直接影响着算法性能。研究人员尝试通过自适应参数更新收敛步长与

选取特定区域的特征提取来改进 TDLMS。Cao Y 等人^[23]采用邻域分析和数据融合,实现了定制化设计红外弱小目标检测的滤波器结构。Bae T W 等人^[24]利用小目标邻域图像块预测像素方差,能够计算出与自适应区域相关的非线性步长。2021 年, Li H 等人^[25]提出了一种基于张量最小均方的红外小目标检测技术。该方法从图像矩阵结构和采集方法出发,显著降低了计算复杂度。

数学形态学是一种建立在集合论和几何基础上的非线性滤波方法,通过采用合适的结构元素遍历图像,并执行膨胀、腐蚀、开运算和闭运算等基本操作,得到中心像素的灰度值。顶帽变换(Top-hat Transformation)是一种经典的数学形态学方法,通过基本运算预测图像背景,再由原始图像与预测背景作差提取目标。Bai X 等人^[6]引入了一种新型环形顶帽变换。如图 3 所示,该环形顶帽变换利用两个不同尺寸的同心圆作为结构元素,通过对比突出小目标信息。Deng L 等人^[26]考虑到结构元素对于顶帽变换的重要性,提出了一种基于量子遗传方法的自适应结构元素优化方法。在此基础上, Deng L 等人^[27]基于 M 估计器设计自适应环形结构元素,并采用局部熵捕获局部特征,在复杂背景下具有较强的目标检测能力。2024 年, Li Y 等人^[28]利用结构张量差分法(Difference of Structure Tensors, DoST)构造自适应环状结构元素,并采用两阶段滑动窗口滤波方法获得小目标的全局特征,显著提高了复杂背景下红外弱小目标检测算法的鲁棒性。




图 3 环形顶帽变换示意图

1.1.2 基于变换域滤波的方法

基于变换域滤波的方法采用适当的数学变换方法获取红外图像的变换域信息,在变换域中处理图像信息,最后通过逆变换在原空间完成差分运算等处理,最终获得检测结果。与基于空域滤波的方法相比,基于变换域滤波的方法计算复杂度更高,但其良好的背景抑制性能引起了人们的广泛关注。

频率滤波法作为经典的变换域滤波方法,通过傅里叶变换将原始图像的空域信息转换到频域中,在频域中通过低通滤波器估计背景,并与原始图像作差来提取目标;或通过高通滤波得到背景抑制的红外图像,再由自适应阈值分割提取目标。早在 21 世纪初,Comaniciu D 等人便已开展关于理想高通滤波^[7]、巴特沃斯高通滤波^[29]等弱小目标检测算法的研究;近年来, Ren X 等人^[30]通过傅里叶变换对单个图像进行二维傅里叶变换,对图像序列进行一维傅里叶变换,然后利用差分运算和阈值分割得到目标图像,并采用能量积累方法增强目标信号;2022 年, Ji H 等人^[31]首先使用高斯低通滤波器对图像进行平滑处理,将红外图像背景中密集而复杂的噪声连接成一个整体,通过该方法达到了消除孤立点噪声的目的。

除了频率滤波法之外,小波变换滤波方法^[32]、非局部均值滤波方法^[33]等变换域方法在红外弱小目标检测领域中都具有良好的表现。整体来说,基于变换域滤波的方法以提高计算复杂度为代价,获得更高的检测精度;与基于空域滤波的方式相同,都是以背景抑制实现目标检测,但当噪声、背景边缘等位置上存在目标时,可能会由于背景与目标难以分辨,出现虚警、漏检等问题。

1.2 基于人类视觉系统的方法

基于人类视觉系统的红外小目标检测方法借鉴人眼视觉对目标的检测能力,通过结合视觉注意机制、对比度机制等理论框架,从复杂背景下的低信噪比红外图像中提取目标信息。与人眼视觉系统一样,红外小目标的存在会在

背景上引起局部的显著性变化, 因此局部对比度检测方法在红外小目标检测任务中表现出优越的检测性能和更大的潜力。基于人类视觉系统的方法大致可以分为差分型和比率型两种。其中, 差分型包括高斯拉普拉斯(Laplacian of Gaussian, LoG)滤波、高斯差分(Difference of Gaussian, DoG)滤波等方法, 它们均以局部中心与局部周围的差值作为局部对比度, 虽然可以有效地消除高亮度背景, 但是不能有效地增强小目标; 而以局部对比度测量(Local Contrast Measure, LCM)方法为代表的比率型检测方法首先计算局部中心与局部周围的比值并将其作为增强因子, 然后再将增强因子与局部中心值的乘积作为局部对比度, 可以同时实现目标增强和背景抑制。

Chen C P 等人^[8]根据红外弱小目标图像中小目标的灰度值强于邻域灰度值的局部特征, 提出了一种局部对比度测量方法。该方法可以同时实现目标信号增强和背景杂波抑制, 进而提升图像信噪比。LCM 方法通过滑动窗口划分图像, 在划分的图像中局部对比度越大, 出现弱小目标的概率越大。该方法的原理示意图如图 4 所示, 其中目标区域用“0”表示。Han J 等人^[34]针对 Chen C P 等人提出的 LCM 中存在的检测速率慢、虚警率高的问题, 提出了改进的局部对比度测量(Improved Local Contrast Measure, ILCM)方法。他们采用尺寸自

适应过程和注意力转移机制, 有效地降低了强噪声, 但该方法容易把小目标当作噪声作平滑处理。2016 年, Qin Y 等人^[35]为了提高在复杂场景中的检测率, 提出了一种新的局部对比度测量(Novel Local Contrast Measure, NLCM)方法。他们采用尺寸大于小目标的局部区域作为滑动窗口, 更有利于在复杂场景中增强目标与背景的对比度。2016 年, Wei Y 等人^[36]提出用于抑制背景和增强目标的多尺度块对比度测量(Multiscale Patch-based Contrast Measure, MPCM)方法, 可以同时增强暗目标和亮目标。2018 年, Nie J 等人^[37]从局部同质性出发, 同时考虑块内均匀性和块间非均匀性, 将二者结合提出了用于检测红外弱小目标的多尺度局部同质测量(Multiscale Local Homogeneity Measure, MLHM)方法。2018 年, Han J 等人^[38]针对 LCM 无法有效消除高亮度背景的缺点, 提出了相对局部对比度测量(Relative Local Contrast Measure, RLCM)方法。他们利用中心块与邻域块的均值比值构建中心块增强因子, 降低了边缘敏感性, 有效消除了背景影响。2020 年, Han J 等人^[39]基于 RLCM 设计了三层滤波窗口, 提出了三层局部对比度测量(Tri-Layer Local Contrast Measure, TLLCM)方法。他们根据目标形状特意增强真实目标, 进一步提高了检测的鲁棒性。Han J 等人^[40]针对靠近高亮背景边缘的小目标容易被淹没的问题, 在




图 4 局部对比法的原理示意图

TLLCM的基础上进一步考虑背景杂波,选取最接近核心层的像素灰度值作为背景估计参数来设计三层窗口,提出了增强的最近邻均值背景估计(Enhanced Closest-Mean Background Estimation, ECMBE)方法。2022年, Kou R等人^[41]提出了将改进密度峰全局搜索方法(Improved Density Peak Global Search Method, IDPGSM)和双权重增强的局部对比测量(Double-Weights Enhanced Local Contrast Measure, DWELCM)方法相结合的检测思路,进一步提高了计算效率和检测精度。2023年, Xu Y等人^[42]提出了一种基于局部对比度加权多向导数(Local Contrast-Weighted Multidirectional Derivative, LCWMD)的红外小目标检测方法。他们通过对多向导数和双局部对比度融合模型的结果进行加权,实现了目标与背景的差异提取。

1.3 基于低秩稀疏矩阵分解的方法

如图5所示,基于低秩稀疏矩阵分解的红外弱小目标检测方法根据红外图像中目标的稀疏性以及背景的低秩性实现目标图像与背景图像的分离,从而达到检测红外弱小目标的目的。

在基于低秩稀疏矩阵分解的检测方法中, Gao C等人^[9]提出的红外图像块(Infrared Patch-Image, IPI)模型最为经典,其工作流程如图6所示。在IPI模型中,红外图像表示为

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

式中, f_D 是原始图像, f_T 是目标图像, f_B 是背景图像, f_N 是噪声图像;相应的图像块矩阵分别表示为 D 、 B 、 T 、 N 。在IPI模型中,红外块图像表示为

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

IPI模型通过滑动窗口将输入红外图像分块,基于红外图像的非局部自相关特性,将红外弱小目标的检测问题转化为低秩矩阵和稀疏矩阵的优化问题:

$$\min_{B, T} \|B\|_* + \lambda \|T\|_1 + \frac{1}{2\mu} \|D - B - T\|_F^2 \quad (3)$$

式中, $\|\cdot\|_*$ 为核范数, $\|\cdot\|_1$ 为 L1 范数, $\|\cdot\|_F$ 为 Frobenius 范数, λ 与 μ 为正权重参数。作为一个凸优化问题, IPI模型采用加速近端梯度(Accelerated Proximal Gradient, APG)算法遍历图像,同时估计低秩背景图像块 B 与稀疏目标图像块 T 。

IPI模型可以较好地提取红外图像中的弱小目标,但由于权重设置、矩阵运算等问题,在边缘较强、背景复杂的红外图像中,该模型在收敛速度、准确率等方面仍存在提升空间。在IPI的基础上, Dai Y等人相继开发了加权红外图像块(Weighted Infrared Patch-Image, WIPI)模型^[43]、重加权红外图像块张量(Reweighted Infrared Patch-Tensor, RIPT)模型^[44]、非负红外图像块(Non-Negative Infrared Patch-Image, NIPPS)模型^[45]等技术。WIPI模型放弃全局权重,采用自适应权重实现强边缘的弱小目标检测。RIPT模型进一步引入结构张量和




图5 低秩背景图像和稀疏目标图像的分离:(a)原始图像;(b)稀疏目标图像;(c)低秩背景图像

重新加权的思想, 在图像结构张量的基础上设计局部结构权重代替全局权重, 减少强边缘和未充分利用先验信息对弱小目标检测的影响。NIPPS 模型将核范数替换为奇异值的部分和来描述背景图像块, 具有更强的背景抑制能力, 避免 IPI 模型在强边缘处检测失败的问题。2017 年, Wang X 等人^[46]采用全变分正则化和主成分追踪 (Total Variation Regularization and Principal Component Pursuit, TV-PCP) 检测复杂背景下的弱小目标, 在算法上采用交替方向乘法 (Alternating Direction Method of Multipliers, ADMM) 代替先前常用的拉格朗日乘法对 TV-PCP 进行优化求解, 并对矩阵运算过程进行了优化。近年来, 张量的概念以及 ADMM 在基于低秩稀疏矩阵分解的红外弱小目标检测方法中得到了广泛应用。2021 年, Zhao M 等人^[47]通过创建三阶张量来利用更多

的空间和结构信息, 并采用塔克分解从三个维度消除大部分背景, 进一步增强了复杂背景下的图像对比度。2021 年, Liu T 等人^[48]采用非凸张量低秩近似 (Nonconvex Tensor Low-Rank Approximation, NTLA) 为不同的奇异值分配不同的权重, 并采用非对称时空全变分 (Asymmetric Spatial-Temporal Total Variation, ASTTV) 方法保留图像时空细节, 提高了检测性能。2023 年, Liu T 等人^[49]通过引入塔克分解的先验因子和群稀疏正则化检测复杂环境中的红外弱小目标, 避免由于经验秩选择导致的性能下降。2023 年, Wu F 等人^[50]使用张量序列 (Tensor Train, TT) 及其扩展张量环 (Tensor Ring, TR) 技术将四维红外张量分解为低维张量, 并采用 ADMM 求解该低秩稀疏分解问题, 证明了其在红外弱小目标检测方面的优越性能。




图 6 红外图像块模型的工作流程^[9]




图 7 两种多帧检测方法的工作流程：(a) DBT 的工作流程；(b) TBD 的工作流程

2 多帧检测方法

基于多帧图像的红外弱小目标检测方法综合利用红外图像序列的时空信息检测弱小目标。在红外图像序列中，小目标在形状、灰度变化和运动轨迹上具有连续性，而噪声则是随机的，缺乏时空相干性。多帧检测方法基于这些目标和噪声之间的内在差异，利用更丰富的帧间相关信息，获得更稳定的检测性能。目前，根据目标检测和跟踪过程的先后顺序，多帧红外弱小目标检测方法可分为跟踪前跟踪（Detect-Before-Track，DBT）和检测前检测（Track-Before-Detect，TBD）两种，如图 7 所示。

2.1 DBT 方法

DBT 方法通常先采用单帧检测技术，在抑制序列背景的同时识别每帧中的潜在目标，从而提高图像的信噪比；然后利用目标运动轨迹的连续性，进一步提高整体检测性能，消除假目标。常用的 DBT 方法包括管道滤波法、能量积累法等。

如图 8 所示，基于管道滤波的红外弱小目标检测技术在第一帧图像中以被检测目标为中




图 8 管道滤波法的原理示意图

心，建立了一条沿时间延伸的管道。若管道内的目标检测次数超过阈值，则认为该目标为真。Wang B 等人^[11]使用区域匹配方法估计序列图像中的帧间振动，提出了一种抗振动管道滤波算法并以此来校正管道滤波输出；Dong L 等人^[51]将抗振动管道滤波器与视觉注意模型（Visual Attention Model，VAM）相结合，抑制海浪与海雾的干扰，提高了复杂海洋环境下的检测成功率；Ding L 等人^[52]设计了一种自适应管道滤波器（Adaptive Pipeline Filter，APF），

利用时间相关性和运动信息对检测结果进行调整,有效减少了误报率,提高了检测精度。

基于能量积累方法的红外小目标检测方法通过对假设运动轨迹上的信号进行积分来增强目标能量。若轨迹准确,则图像信噪比提高;反之,若轨迹错误,则信噪比降低。Ma T 等人^[53-54]利用辐射积累进行轨迹验证和极值分析来估计目标速度和位置,从而检测恒定或加速直线运动的弱小目标;Du J 等人^[55]通过引入帧间能量积累(Interframe Energy Accumulation, IFEA)增强机制来提取时空特征,抑制杂波,从而增强目标信号。

2.2 TBD 方法

DBT 方法可以理解为在单帧检测的基础上增加了后处理流程。但当单帧检测方法性能不足时,DBT 方法的检测结果不可避免地难以达到预期。例如,当弱小目标处于纹理较弱、边缘模糊、信噪比较低的复杂背景中时,DBT 方法可能会遗漏真实目标。相比之下,TBD 方法在复杂背景的弱小目标检测任务中具有更好的检测性能,可以利用灰度的时空相干性或帧间的能量积累估计目标轨迹,利用真实目标与环境杂波之间的差异来检测运动的小目标。常用的 TBD 方法包括匹配滤波法、动态规划法等。

匹配滤波器最初是为白噪声背景下的信号检测而设计的,它可以通过最大化输出信噪比将目标从杂波中分离出来。Reed I S 等人^[12]率先将三维匹配滤波器应用于小目标检测,将二维空间匹配滤波器与时间相干分析结合,增强弱小目标的可见性;Porat B 等人^[56]部署了一组三维方向匹配滤波器来检查频域中所有可能的目标轨迹,再加上决策逻辑来验证目标的存在。

基于动态规划的方法有助于减轻目标运动轨迹搜索带来的巨大计算负担,通过将复杂问题分解为多个子问题来简化多变量优化问题。Barniv Y 等人^[57-58]率先将动态规划引入红外小目标检测场景,将红外图像序列按时间顺序分

割,然后将像素之间可能的定向轨迹段划分为若干状态,递归更新状态代价,以识别全局最优轨迹。

近年来,研究人员尝试将单帧算法的概念扩展到时域中去,开发利用序列图像信息进行目标检测的新型时空结合的方法,如图 9 所示。研究人员将单帧的局部对比度法扩展到时域,开展了基于局部对比度的时空方法研究。2016 年,Deng L 等人^[13]通过定义空间局部对比度(Spatial Local Contrast, SLC)和时间局部对比度(Temporal Local Contrast, TLC),提出了时空局部对比度滤波器(Spatial-Temporal Local Contrast Filter, STLCHF)来增强红外图像序列中的目标对比度,从而获得更好的目标检测性能。2019 年,Du P 等人^[59]提出时空局部差分测量法(Spatial-Temporal Local Difference Measure, STLDM),通过分析目标中心与周围环境之间的灰度值变化,可直接对三维时空中的红外小目标进行检测。2021 年,Pang D 等人^[60]利用目标像素与背景像素不同帧的方差和灰度特征,并结合目标运动信息来抑制背景杂波。2021 年,Sun Y 等人则尝试从张量的角度,开展基于张量的时空方法研究。2019 年,Sun Y 等人^[14]通过叠加图像序列构建时空张量,通过时空全变分正则化和加权张量核范数进行背景边缘分解,在非平滑和非均匀场景下具有更好的背景杂波抑制性能,实现了复杂场景下的红外小目标检测。2020 年,Liu H K 等人^[61]利用时空立方体构建时空张量,整合时空特征,不仅可以利用空间域信息来突出目标,还可以充分利用时间域的上下文信息准确区分目标。2020 年,Zhang P 等人^[62]设计了基于边角感知的时空张量模型,通过分析边角组合来突出红外小目标。2022 年,Deng L 等人^[63]将张量环分解与多尺度形态学顶帽变换用于红外小目标检测;2023 年,Yi H 等人^[64]引入了时空张量环形范数正则化,在复杂场景中近似张量背景秩的同时增强了维度间的相关性。时空结合的方法综合利用了序列图像的帧




图 9 两种典型的时空结合方法：(a)时空对比度模型；(b)时空张量模型^[60-61]

间信息，有效避免了单帧算法只利用空间域信息的缺点，对复杂背景下的运动目标具有较好的检测效果。

3 基于深度学习的方法

传统的红外弱小目标检测方法依赖于人工特征提取，在复杂背景下的检测效率有限。深度学习作为一种基于数据驱动的方法，消除了对人工特征提取的依赖。基于深度学习的方法通过模拟神经网络架构，从红外弱小目标数据集中学习和分析深度特征，可以有效地将目标从背景杂波中提取出来。

3.1 目标检测算法

根据目标检测原理的不同，我们将基于深度学习的目标检测算法大致分为 Two-stage 模型和 One-stage 模型两类。其中，Two-stage 模型分两步输出目标的类别和位置坐标，先由算

法生成候选区域，再与卷积神经网络结合对候选区域进行分类和回归，大大提高了算法的准确率。常用的 Two-stage 模型包括 RCNN 系列 (Fast-RCNN、Faster-RCNN、Mask-RCNN) 以及 R-FCN 等。

2013 年，Girshick R 等人^[65]将候选区域 (Region Proposals) 与 CNN 组合在一起，提出了 R-CNN 网络。该方法首次将 CNN 用于目标检测领域，以 CNN 提取到的特征图代替传统特征。R-CNN 显著提升了目标检测性能，但由于要对每张图像提取 2000 个候选区域的 CNN 特征，再由 SVM 分类，导致整体计算量大、效率低。为提高训练和测试速度，同时提高检测精度，Girshick R 等人^[66]在 2015 年提出了 Fast R-CNN。Fast R-CNN 同样采用选择性搜索生成 2000 个候选区域，但直接从特征

图中提取候选区域, 避免了候选区域的重叠, 大大降低了计算量。随后利用 RoI (Region of Interest) 池化层获得固定大小的特征框, 并利用结合分类预测 (Softmax Classification) 和边框回归 (Bounding-Box) 的多任务损失函数, 实现了选择性搜索后的端到端训练。尽管 Fast R-CNN 在计算效率上有所提高, 但在选择性搜索生成候选区域的效率上仍有不足。2015 年, Ren S 等人^[21]在 Fast-RCNN 的基础上, 引入候选区域网络 (Region Proposal Network, RPN) 取代选择性搜索生成候选区域, 通过引入 RPN 网络在整个目标检测流程中实现了端到端的训练。如图 10 所示, Faster R-CNN 作为 Two-stage 模型的典型代表, 为 Two-stage 模型提供了一个工作范式。首先使用 RPN 处理输入图像, 生成若干个 RoI, 再使用 RoI 池化层和若干全连接层实现对每一个 RoI 的分类回归。此外, 在 R-CNN 的基础上, R-FCN (Region-Based Fully Convolutional Networks)^[67]、FPN (Feature Pyramid Networks)^[68]等网络也相继被提出。Faster R-CNN 中每个候选框都要多层全连接层作分类回归, 计算量大。R-FCN 通过生成编码的目标位置敏感分数图, 让所有候选区域共享网络计算, 不再需要对每个候选框进行回归分类, 解决了目标检测的位置敏感性问题。FPN 针对小目标下采样过程中特征丢失的问题, 结合来自不同 CNN 层的多尺度特征, 减轻了下采样过程中的特征损失。

One-stage 模型是一种一步输出的目标检测方法。它将目标检测问题视为一个单一的回归问题, 一步输出目标的类别和位置坐标, 不生成候选区域, 算法速度快。常用的 One-stage 模型包括 YOLO 系列、SSD 系列 (R-SSD、DSSD、FSSD 等)、Retina-Net^[70]等。YOLO 系列是最常用的 One-stage 算法, 其采用一个单独的 CNN 模型实现端到端的目标检测。2016 年, Redmon J 等人^[71]最先提出了 YOLO 目标检测算法。该算法首次把目标检测





图 10 Faster R-CNN 的工作流程^[21]



视为单一的回归问题, 将输入图像划分网格 (每个网格检测目标中心点落在网格内的目标), 然后一次预测每个网格内的边界框及其对应的置信度和类别概率值, 大大提高了算法的实时性。Redmon J 等人后续在 YOLOv1 的基础上相继提出了 YOLOv2^[72]和 YOLOv3^[73]模型。YOLOv2 通过在网络中引入批量归一化 (Batch Normalization)、锚框 (Anchor Boxes)、维度聚类 (Dimension Clusters), 增强了 YOLO 网络的定位精度和泛化性。YOLOv3 则通过引入多尺度检测策略和 Darknet-53 特征提取网络, 显著提升了 YOLO 网络对弱小目标的检测能力。此外, 针对 YOLO 算法的速度、精度、轻量化的问题, Bochkovskiy A 等人相继发布了 YOLOv4^[74]和 YOLOv7^[75]模型, Ultralytics 公司发布了 YOLOv5 和 YOLOv8^[76]等模型。2023 年, Li R 等人^[69]在 YOLOv5 网络的基础上, 采用超分辨率与数据增强预处理输入图像, 在 SIRST 数据集上实现了 93.7% 的精度和 91% 的召回率, 其网络结构如图 11 所示。2024 年, Sun S 等人^[77]提出了一种基于 YOLOv8s 模型的高效多输入模型, 通过融合多个输入帧的信息来提高检测性能。2025 年, Tian Y 等人^[78]提出了 YOLOv12 网络模型, 通

图 11 YOLOS-R-IST 检测网络^[69]

过引入注意力机制，在保持实时目标检测的同时提高检测精度。虽然每代 YOLO 模型都有一定的局限性，但在目标检测的精度和效率方面均取得了显著进步。

SSD (Single Shot MultiBox Detector) 系列作为 One-stage 模型的另一个代表算法，也是采用一个 CNN 网络进行检测，但 SSD 创新性地采用多尺度的特征图检测不同大小的目标，如图 12 所示。2016 年，Liu W 等人^[79] 借鉴 Faster R-CNN 中的锚框思想，提出了 SSD 算法：采用多尺度的特征图检测不同大小的目标，利用浅层特征图检测位置信息来实现目标定位，并利用深层特征图检测语义信息来对目

标进行分类。Fu C Y 等人^[80] 后续在 SSD 基础上加入 Residual-101 和反卷积层，提出具有沙漏模型的 DSSD，充分利用浅层特征提高小目标检测精度。2017 年，Li Z 等人^[81] 通过特征融合将多层次、多尺度的特征融合成一种新型金字塔特征图，提出了 FSSD 模型。2018 年，Zhang S 等人^[82] 提出 RefineDet 网络，通过 ARM (Anchor Refinement Module) 和 ODM (Object Detection Module) 两个模块模仿 Faster R-CNN 的两个阶段，在保证检测速度的前提下提高了检测精度。2019 年，Yang J 等人^[83] 提出 FFE-SSD 模型，采用特征融合和特征增强模块将来自不同层次、不同尺度的特征拼接

图 12 两种典型的 One-stage 网络框架: (a) SSD 网络框架; (b) YOLO 网络框架^[79]图 13 U-net 网络框架^[86]

融合用于目标检测, 避免了 SSD 特征信息不丰富的缺陷。此外, RFB-Net^[84]、Peele^[85]等 SSD 系列算法从不同角度针对 Liu W 提出的

SSD 网络进行优化, 在准确性、速度和轻量级方面显著提高了 SSD 系列的性能。RFB-Net 将 RFB (Receptive Field Block) 网络与 SSD 集成,

实现了快速、准确的小目标检测。Peele-SSD 则以 Peele 网络为骨干, 实现了网络轻量化, 适合进行移动部署。

3.2 目标分割算法

目前, 基于 Two-stage 模型和 One-stage 模型的红外小目标检测方法取得了很好的效果, 但这些方法通常用锚框进行特征提取和目标检测, 无法精细地提取目标轮廓信息。为了解决此问题, 目标分割算法被引入红外小目标检测领域。

Long J 等人^[86]用全卷积网络(Fully Convolutional Network, FCN)将 CNN 最后的全连接层转换成卷积层, 并采用反卷积层和跳跃架构融合多尺度特征。如图 13 所示, Ronneberger O 等人^[87]基于 FCN 设计了独特的编码器-解码器对称结构的 U-Net, 可用少量样本实现图像分割, 并利用跳跃连接将编码器中的深层特征与解码器中的浅层特征相结合, 弥补了在下采样过程中可能丢失的细节, 从而提高了图像分割的精度。Badrinarayanan V 等人^[88]提出了同样具有编码器-解码器结构的 SegNet。SegNet 存储了编码过程中最大池化的索引, 用于上采样过程和卷积过程, 在一定程度上解决了物体边界划分不清的问题。Lin G 等人^[89]依据编码器-解码器结构构建 RefineNet, 通过长程残差连接和多分辨率融合, 有效结合不同层次的特征, 生成高分辨率的特征图, 解决 CNN 在图像分割中分辨率降低的问题。

基于注意力机制的图像分割技术也是深度学习目标检测领域的一个重要进展。Transformer 最初是 Vaswani A 等人^[90]为自然语言处理任务设计的, 但研究者发现它在图像分割任务中同样表现出色, 其结构如图 14 所示。Transformer 通过引入自注意力机制(Self-Attention Mechanism)来同时捕捉图像中不同区域之间的关系, 无需像 CNN 一样逐步处理。因此, Transformer 能够更有效地处理图像中的远距离关系, 从而提高分割的精度。其次, Transformer 容易扩展到更大的模型尺寸, 处

理更复杂的图像分割任务。而且 Transformer 的强大并行能力非常适合处理大规模图像数据。在实际应用中, Transformer 可以和 CNN 结合使用。通过 CNN 提取图像局部特征, 再使用 Transformer 来整合全局信息, 实现图像精准分割。

截至目前, 基于 CNN 或 Transformer 结合的红外弱小目标检测技术快速发展。通过引入注意力机制^[15-17]、特征融合^[18-19]、数据增强^[20]等特征学习策略, 为实现网络轻量化、降低计算复杂度等方面提供了有力帮助(结果对比见表 1)。2019 年, Wang H 等人^[20]通过 GAN 网络合成红外小目标图像, 解决缺少训练集数据的问题。2021 年, Dai Y 等人^[15]提出用非对称上下文调制代替跨层数据融合, 解决红外弱小目标的尺度不匹配问题。同时, Dai Y 等人^[16]还尝试将注意力局部对比度和 CNN 的特征提取能力相结合, 解决单张红外图像中小目标固有特征稀疏的问题, 提出了 ALC-Net (Attentional Local Contrast Networks)。2022 年, Li B 等人^[19]开发了一种 DNA-Net (Dense Nested Attention Network), 通过重复的特征融合和增强, 充分整合和利用小目标的信息, 解决深层目标丢失的问题。2022 年, Wang K 等人^[17]提出了一种用于红外小目标检测的 IAA-Net (Interior Attention-Aware Network), 先用 RPN 过滤背景得到粗略的目标区域, 再由 Transformer 提供注意力机制得到精细的检测结果。2023 年, Wu X 等人^[18]专为红外小目标检测设计一种 UIU-Net (U-Net in U-Net) 的网络框架, 通过在一个较大的 U-Net 主干网络中嵌入一个小的 U-Net, 实现多层次和多尺度的学习, 有效地增强全局和局部对比度信息, 从而提高小目标检测的精度。

3.3 红外弱小目标数据集

毫无疑问, 公开的红外弱小目标数据集在基于深度学习的红外弱小目标检测应用中发挥了关键作用。深度学习的性能直接取决于数据集大小、目标多样性、背景复杂性以及标记精


图 14 Transformer 网络框架^[90]

表 1 图像分割网络的运行结果对比

参考文献	网络模型	数据集	检测率	虚警率 ($\times 10^{-6}$)	交并比	标准化 交并比	精确率	召回率
[20]	MDvsFA-cGAN	AllSeqs	0.79	—	—	—	0.17	0.59
		Single	0.92	—	—	—	0.66	0.54
[15]	ACM-Net	NUAA-SIRST	—	—	0.743	0.731	—	—
[16]	ALC-Net	NUAA-SIRST	—	—	0.757	0.728	—	—
[19]	DNA-Net	NUAA-SIRST	0.9848	2.353	0.7747	—	—	—
		NUDT-SIRST	0.9873	4.223	0.8709	—	—	—
[17]	IAA-Net	NUAA-SIRST	—	—	0.5398	0.6075	0.6925	0.8758
		Synthetic	—	—	0.5084	0.5040	0.6060	0.8178
[18]	UIU-Net	NUAA-SIRST	—	—	0.7825	0.7515	—	—
		Synthetic	—	—	0.4773	0.4721	—	—

度等因素。虽然目前很多学者开源了各自的红外小目标数据集,但由于标签注释、图像数量以及图像多样性等原因,现有的红外弱小目标检测开源数据集依旧十分有限。因此我们总结了几个公开的红外弱小目标数据集,如表 2 所示。

3.3.1 NUAA-SIRST

NUAA-SIRST 数据集由 Dai Y 等人^[15]提出,包含 427 张图像。他们从红外序列中抽取一张代表性图像,保证真实目标的存在。其中的图像目标以 5 种不同的形式进行手动标注,分别支持图像分类、实例分割、边界框回归、语义分割和实例识别任务。

3.3.2 NUDT-SIRST

NUDT-SIRST 数据集由 Li B 等人^[19]提出,包含 1327 张合成图像。这些图片由包括城市、平原、高光、海洋以及云层在内的五种真实背景合成而来,其中包含了真实目标以及具有多种信杂比和造型的点目标与拓展目标。

3.3.3 IRSTD-1k

IRSTD-1k 数据集由 Zhang M 等人^[91]提出,采用红外相机从远距离的不同位置上拍摄 1000 张红外图像,并在像素级别方面对目标进行手动注释。该数据集包含不同种类的小目标,例如无人机、生物、船只以及车辆,并且包含海洋、河流、田野、山区、城市以及云的

红外图像背景中存在很重的杂波和噪声,可以用于全面评价红外检测方法。

3.3.4 SIRST-V2

SIRST-V2 数据集由 Dai Y 等人^[92]提出,在 NUAA-SIRST 数据集的基础上进行更新,包含从不同场景的真实视频中提取的 1024 张红外小目标图像。该数据集由于杂波和噪声的存在,大多数红外小目标难以与背景区分开来,并且更加关注城市场景(新增的城市场景包含许多背景干扰元素)。

3.3.5 IRSTD

IRSTD 数据集由 Sun H 等人^[93]提出,其中包含复杂背景下的 40650 张真实图像和 102077 张合成图像,而且每张图像都有从精细到粗略的三种类型的标签。真实图像来自远距离采集的 1760 个序列的 40650 帧,而合成图像由真实背景、模拟目标以及仿真噪声组成。两种图像都涉及白天和黑夜的各种典型场景,如云层、平原、森林、湖泊、城市、山脉以及河流,为复杂背景下的红外小目标检测提供了大量数据。

3.4 评价指标

评价指标为全面分析不同算法的性能提供了定量参考。其中,检测率(Probability of detection, Pd)、虚警率(False alarm rate, Fa)、精确率(Precision)、召回率(Recall)、平均精度(mean Average Precision, mAP)、交并比(In-

表 2 几类公开的红外弱小目标数据集的参数对比

年份	参考文献	数据集	图像类型	图像数量	标签类型	背景类型
2022	[19]	NUDT-SIRST	合成图像	1327	基准真实值	城市/田野/ 海洋/云层/高光
2021	[15]	NUAA-SIRST	真实图像	427	手动粗标签	城市/海洋/云层
2022	[91]	IRSTD-1k	真实图像	1000	手动粗标签	海洋/河流/田野/ 山区/城市/云层
2023	[92]	SIRST-V2	真实图像	1024	手动粗标签	城市/海洋/云层/ 山脉/田野/建筑
2023	[93]	IRDST	真实图像/ 合成图像	40650(真实图像)/ 102077(合成图像)	手动粗标签/ 基准真实值	天空/云层/森林/湖泊/ 建筑/山脉/河流

tersection over Union, IoU)等都是常用于评估网络红外探测性能的指标。精确率和召回率的计算需要使用混淆矩阵。如表 3 所示, 横轴表示实际值, 纵轴表示预测值。混淆矩阵定义了四类预测事件: TP(True Positive Prediction)代表真阳性预测, FP(False Positive Prediction)代表假阳性预测, FN(False Negative Prediction)代表假阴性预测, TN(True Negative Prediction)代表真阴性预测。

		Actual values	
		Positive	Negative
Predict values	Positive	TP	FP
	Negative	FN	TN

表 3 混淆矩阵

Precision 是真阳性预测样本占阳性预测样本总数的比值。*Recall* 是真阳性预测样本占实际阳性样本总数的比值。*Precision* 和 *Recall* 的定义如下:

$$Precision = \frac{TP}{TP + FP} \quad (4)$$

$$Recall = \frac{TP}{TP + FN} \quad (5)$$

在实际训练中, 我们希望同时获得高的 *Precision* 和 *Recall*, 但事实上两者相互制约, 当其中一个高时, 另一个就会降低, 因此需要根据实际需求进行取舍。可以通过模型训练得到预测的 *PR* (Precision-Recall) 曲线, 并计算曲线下的面积得到 *AP* (Average Precision)。AP 用于评估模型中单个类的性能, 而 *mAP* (mean Average Precision) 则用于评估模型中所有类的性能, 要对数据集中所有类的 *AP* 求平均。AP 与 *mAP* 的定义如下:

$$AP = \int P(r) dr \quad (6)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (7)$$

Pd 与 *Fa* 是常用的两个目标水平的评估指标。其中, *Pd* 用于测量正确预测的目标数 $N_{correct}$ 占有目标数 N_{all} 的比例; *Fa* 用于测量错误预测的像素 P_{false} 占总的图像像素 P_{all} 的比例。*Pd* 与 *Fa* 的定义如下:

$$Pd = \frac{N_{correct}}{N_{all}} \quad (8)$$

$$Fa = \frac{P_{false}}{P_{all}} \quad (9)$$

IoU 是用于测量预测边界框与实际边界框之间重叠程度的评估指标, 是通过预测与标签之间的交集面积 (A_{inter}) 与并集面积 (A_{Union}) 的比值来计算的。*IoU* 的定义如下:

$$IoU = \frac{A_{inter}}{A_{Union}} \quad (10)$$

4 结束语

目前的红外弱小目标检测方法已经可以满足大多数场景的应用需求, 如海洋监测、红外预警等。但在更广泛的工作场景中, 红外弱小目标检测方法不可避免地会面对复杂外界干扰的影响, 例如复杂背景、恶劣气象条件等。因此, 开发计算量小、实时性好、鲁棒性强、适应复杂背景干扰的红外弱小目标检测方法仍需要科研人员的持续深入研究。综合来看, 现有的红外弱小目标检测方法仍面临着以下几个问题:

(1) 复杂的工作环境: 红外探测系统常在包含云层、海浪、森林等复杂背景的工作环境下工作。现有的红外弱小目标检测方法仅在背景均匀或对比度高的图像中表现良好, 而在这些复杂的工作环境下容易出现漏检、误检、虚警率高的问题。

(2) 依赖人工设计特征: 目前的红外弱小目标检测方法依赖于人工设计的特征, 存在适应性差的问题, 对真实场景下目标的大小、形状、信杂比都很敏感, 需要根据不同的工作场

景进行人工调参。

(3)深度学习方法存在局限性:大多数基于深度学习的方法只是在目标检测网络的基础上进行调整,容易忽略了红外弱小目标与一般检测目标之间的尺寸差异。此外,目前缺乏大规模、高质量的红外弱小目标数据集,无法满足深度学习方法的海量数据需求。

同时,未来红外弱小目标检测的研究可能具有以下发展趋势:

(1)多特征融合方法:对于红外弱小目标检测,采用单一特征很少能达到最佳的检测效果。目前,利用多特征融合实现红外弱小目标检测已经成为主流的研究趋势。科研人员将不同特征进行融合,期望获得更好的检测性能。例如,将低秩张量与顶帽变换结合,提高信杂比增益和背景抑制因子^[94],在更低的虚警率下完成红外弱小目标检测,或者通过计算原始图像梯度图的局部对比度检测方法^[95],可同时实现目标增强和背景抑制。

(2)时空结合方法:时空结合方法利用帧间信息克服了单帧算法对时域信息利用不足的缺点。无论是利用时空局部对比度^[13,59-60],还是利用时空张量^[14,61-62],都对复杂背景下的红外弱小目标具有良好的检测效果,即便在个别帧中存在目标遮挡的情况,也可以根据前后帧信息推测出目标位置。但也因为这类方法需要同时计算多帧信息,计算量比较大,其输出实时性不足。因此,通过算法优化或者硬件升级提高时空结合方法的处理能力,是未来投入实际生产部署的研究热点。

(3)深度学习方法:近年来,随着高性能GPU平台的快速发展,基于深度学习的红外弱小目标检测逐渐成为一个重要的前沿研究领域。与传统方法相比,基于深度学习的方法在复杂环境下的红外小目标检测中表现良好,在精度和实时性上具有相当优势。在未来,研究人员可以尝试通过新的网络架构以及理论创新来弥补现有红外弱小目标检测方法的不足。例如,利用生成对抗网络^[20,96-97]合成虚拟红外小

目标数据,实现扩大数据集,解决现有红外弱小目标数据集的稀缺性问题,提高深度神经网络网络的适应性。

参考文献

- [1] Cheng Y, Lai X, Xia Y, et al. Infrared dim small target detection networks: A review [J]. *Sensors*, 2024, **24**(12): 3885.
- [2] Kumar N, Singh P. Small and dim target detection in ir imagery: A review [J]. *arXiv*: 231116346, 2023.
- [3] 李俊宏,张萍,王晓玮,等. 红外弱小目标检测算法综述 [J]. *中国图象图形学报*, 2020, **25**(9): 1739-1753.
- [4] 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): 20210393.
- [5] Deshpande S D, Er M H, Venkateswarlu R, et al. Max-mean and max-median filters for detection of small targets [C]. Orlando: Signal and Data Processing of Small Targets 1999, 1999.
- [6] Bai X, Zhou F. Analysis of new top-hat transformation and the application for infrared dim small target detection [J]. *Pattern Recognition*, 2010, **43**(6): 2145-2156.
- [7] Comaniciu D. An algorithm for data-driven bandwidth selection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2003, **25**(2): 281-288.
- [8] Chen C P, Li H, Wei Y, et al. A local contrast method for small infrared target detection [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, **52**(1): 574-581.
- [9] 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.
- [10] Yang D G, Han T H, Hu L, et al. Research Status and Prospect of Single Frame Infrared Dim Small Target Detection Technology [J]. *Journal of Signal Processing*, 2024, **40**(5): 887-906.
- [11] Wang B, Xu W, Zhao M, et al. Antivibration

- pipeline-filtering algorithm for maritime small target detection [J]. *Optical Engineering*, 2014, **53** (11): 113109–113109.
- [12] Reed I S, Gagliardi R M, Stotts L B. Optical moving target detection with 3-D matched filtering [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1988, **24**(4): 327–336.
- [13] Deng L, Zhu H, Tao C, et al. Infrared moving point target detection based on spatial-temporal local contrast filter [J]. *Infrared Physics & Technology*, 2016, **76**: 168–173.
- [14] 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.
- [15] Dai Y, Wu Y, Zhou F, et al. Asymmetric contextual modulation for infrared small target detection [C]. Waikoloa: 2021 IEEE/CVF Winter Conference on Applications of Computer Vision, 2021.
- [16] Dai Y, Wu Y, Zhou F, et al. Attentional local contrast networks for infrared small target detection [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, **59**: 9813–9824.
- [17] Wang K, Du S, Liu C, et al. Interior attention-aware network for infrared small target detection [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, **60**: 1–13.
- [18] Wu X, Hong D, Chanussot J. UIU-Net: U-Net in U-Net for infrared small object detection [J]. *IEEE Transactions on Image Processing*, 2022, **32**: 364–376.
- [19] Li B, Xiao C, Wang L, et al. Dense nested attention network for infrared small target detection [J]. *IEEE Transactions on Image Processing*, 2022, **32**: 1745–1758.
- [20] Wang H, Zhou L, Wang L. Miss detection vs. false alarm: Adversarial learning for small object segmentation in infrared images [C]. Seou: 2019 IEEE/CVF International Conference on Computer Vision, 2019.
- [21] Ren S, He K, Girshick R, et al. Faster r-cnn: Towards real-time object detection with region proposal networks [J]. *Advances in Neural Information Processing Systems*, 2015, **28**: 1137–1149.
- [22] Hadhoud M M, Thomas D W. The two-dimensional adaptive LMS (TDLMS) algorithm [J]. *IEEE Transactions on Circuits and Systems*, 1988, **35**(5): 485–494.
- [23] Cao Y, Liu R, Yang J. Small target detection using two-dimensional least mean square (TDLMS) filter based on neighborhood analysis [J]. *International Journal of Infrared and Millimeter Waves*, 2008, **29**: 188–200.
- [24] Bae T W, Zhang F, Kweon I S. Edge directional 2D LMS filter for infrared small target detection [J]. *Infrared Physics & Technology*, 2012, **55** (1): 137–145.
- [25] Li H, Wang Q, Wang H, et al. Infrared small target detection using tensor based least mean square [J]. *Computers & Electrical Engineering*, 2021, **91**: 106994.
- [26] Deng L, Zhu H, Zhou Q, et al. Adaptive top-hat filter based on quantum genetic algorithm for infrared small target detection [J]. *Multimedia Tools and Applications*, 2018, **77**: 10539–10551.
- [27] Deng L, Zhang J, Xu G, et al. Infrared small target detection via adaptive M-estimator ring top-hat transformation [J]. *Pattern Recognition*, 2021, **112**: 107729.
- [28] Li Y, Li Z, Li J, et al. Robust small infrared target detection using weighted adaptive ring top-hat transformation [J]. *Signal Processing*, 2024, **217**: 109339.
- [29] Yang L, Yang J, Yang K. Adaptive detection for infrared small target under sea-sky complex background [J]. *Electronics Letters*, 2004, **40**(17): 1083–1085.
- [30] Ren X, Wang J, Ma T, et al. Infrared dim and small target detection based on three-dimensional collaborative filtering and spatial inversion modeling [J]. *Infrared Physics & Technology*, 2019, **101**: 13–24.
- [31] Ji H, Cui Z. Infrared background suppression method based on low-pass adaptive morphological

- filtering [C]. Changchun; 2022 3rd International Conference on Computer Vision, Image and Deep Learning & International Conference on Computer Engineering and Applications (CVIDL & ICCEA 2022), 2022.
- [32] Sun Y Q, Tian J W, Liu J. Background suppression based-on wavelet transformation to detect infrared target [C]. Guangzhou; 2005 International Conference on Machine Learning and Cybernetics, 2005.
- [33] Buades A, Coll B, Morel J M. A non-local algorithm for image denoising [C]. San Diego; 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), 2005.
- [34] Han J, Ma Y, Zhou B, 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.
- [35] Qin Y, Li B. Effective infrared small target detection utilizing a novel local contrast method [J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, **13**(12): 1890–1894.
- [36] Wei Y, You X, Li H. Multiscale patch-based contrast measure for small infrared target detection [J]. *Pattern Recognition*, 2016, **58**: 216–226.
- [37] Nie J, Qu S, Wei Y, et al. An infrared small target detection method based on multiscale local homogeneity measure [J]. *Infrared Physics & Technology*, 2018, **90**: 186–194.
- [38] Han J, Liang K, Zhou B, 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.
- [39] Han J, Moradi S, Faramarzi I, et al. A local contrast method for infrared small-target detection utilizing a tri-layer window [J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, **16** (10): 1822–1826.
- [40] Han J, Liu C, Liu Y, et al. Infrared small target detection utilizing the enhanced closest-mean background estimation [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, **13**: 645–662.
- [41] Kou R, Wang C, Fu Q, et al. Infrared small target detection based on the improved density peak global search and human visual local contrast mechanism [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, **15**: 6144–6157.
- [42] Xu Y, Wan M, Zhang X, et al. Infrared small target detection based on local contrast-weighted multidirectional derivative [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, **61**: 1–16.
- [43] Dai Y, Wu Y, Song Y. Infrared small target and background separation via column-wise weighted robust principal component analysis [J]. *Infrared Physics & Technology*, 2016, **77**: 421–430.
- [44] 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**: 3752–3767.
- [45] Dai Y, Wu Y, Song Y, et al. Non-negative infrared patch-image model: Robust target-background separation via partial sum minimization of singular values [J]. *Infrared Physics & Technology*, 2017, **81**: 182–194.
- [46] Wang X, Peng Z, Kong D, et al. Infrared dim target detection based on total variation regularization and principal component pursuit [J]. *Image and Vision Computing*, 2017, **63**: 1–9.
- [47] Zhao M, Li W, Li L, et al. Three-order tensor creation and tucker decomposition for infrared small-target detection [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, **60**: 1–16.
- [48] Liu T, Yang J, Li B, et al. Nonconvex tensor low-rank approximation for infrared small target detection [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, **60**: 1–18.
- [49] Liu T, Yang J, Li B, et al. Infrared small target detection via nonconvex tensor tucker decomposition with factor prior [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, **61**: 1–17.
- [50] Wu F, Yu H, Liu A, et al. Infrared small target detection using spatiotemporal 4-D tensor train and

- ring unfolding [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, **61**: 1–22.
- [51] Dong L, Wang B, Zhao M, et al. Robust infrared maritime target detection based on visual attention and spatiotemporal filtering [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, **55**(5): 3037–3050.
- [52] Ding L, Xu X, Cao Y, et al. Detection and tracking of infrared small target by jointly using SSD and pipeline filter [J]. *Digital Signal Processing*, 2021, **110**: 102949.
- [53] Tianlei M, Zelin S, Jian Y, et al. Dim air target detection based on radiation accumulation and space inversion [J]. *Infrared and Laser Engineering*, 2015, **44**(11): 3500–3506.
- [54] Ma T, Shi Z, Yin J, et al. Rectilinear-motion space inversion-based detection approach for infrared dim air targets with variable velocities [J]. *Optical Engineering*, 2016, **55**(3): 033102–033102.
- [55] Du J, Lu H, Zhang L, et al. A spatial-temporal feature-based detection framework for infrared dim small target [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, **60**: 1–12.
- [56] Porat B, Friedlander B. A frequency domain algorithm for multiframe detection and estimation of dim targets [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1990, **12**(4): 398–401.
- [57] Barniv Y. Dynamic programming solution for detecting dim moving targets [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1985, **AES-21**(1): 144–156.
- [58] Barniv Y, Kella O. Dynamic programming solution for detecting dim moving targets part II: Analysis [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1987, **AES-23**(6): 776–788.
- [59] Du P, Hamdulla A. Infrared moving small-target detection using spatial-temporal local difference measure [J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, **17**(10): 1817–1821.
- [60] Pang D, Shan T, Ma P, et al. A novel spatiotemporal saliency method for low-altitude slow small infrared target detection [J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, **19**: 1–5.
- [61] 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.
- [62] Zhang P, Zhang L, Wang X, et al. Edge and corner awareness-based spatial-temporal tensor model for infrared small-target detection [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, **59**(12): 10708–10724.
- [63] Deng L, Song J, Xu G, et al. When infrared small target detection meets tensor ring decomposition: A multiscale morphological framework [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2022, **58**(4): 3162–3176.
- [64] Yi H, Yang C, Qie R, et al. Spatial-temporal tensor ring norm regularization for infrared small target detection [J]. *IEEE Geoscience and Remote Sensing Letters*, 2023, **20**: 1–5.
- [65] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]. Portland: 2013 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2013.
- [66] Girshick R. Fast r-cnn [C]. Santiago: 2015 IEEE International Conference on Computer Vision (ICCV), 2015.
- [67] Dai J, Li Y, He K, et al. R-fcn: Object detection via region-based fully convolutional networks [J]. *Advances in Neural Information Processing Systems*, 2016, **29**: 1–11.
- [68] Lin T Y, Dollar P, Girshick R, et al. Feature pyramid networks for object detection [C]. Honolulu: 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017.
- [69] Li R, Shen Y. YOLOSRT: A deep learning method for small target detection in infrared remote sensing images based on super-resolution and YOLO [J]. *Signal Processing*, 2023, **208**: 108962.
- [70] Lin T Y, Goyal P, Girshick R, et al. Focal loss

- for dense object detection [C]. Venice: 2017 IEEE International Conference on Computer Vision (ICCV), 2017.
- [71] Redmon J, Divvala S, Girshick R, et al. You only look once: Unified, real-time object detection [C]. Las Vegas: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016.
- [72] Redmon J, Farhadi A. YOLO9000: better, faster, stronger [C]. Honolulu: 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017.
- [73] Redmon J, Farhadi A. Yolov3: An incremental improvement [J]. *arXiv*: 1804.02767, 2018.
- [74] Bochkovskiy A, Wang C-Y, Liao H-Y M. Yolov4: Optimal speed and accuracy of object detection [J]. *arXiv*: 2004.10934, 2020.
- [75] Wang C Y, Bochkovskiy A, Liao H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]. Vancouver: 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023.
- [76] Yaseen M. What is YOLOv8: An in-depth exploration of the internal features of the next-generation object detector [J]. *arXiv*: 2408.15857, 2024.
- [77] Sun S, Mo B, Xu J, et al. Multi-YOLOv8: An infrared moving small object detection model based on YOLOv8 for air vehicle [J]. *Neurocomputing*, 2024, **588**: 127685.
- [78] Tian Y, Ye Q, Doermann D. Yolov12: Attention-centric real-time object detectors [J]. *arXiv*: 2502.12524, 2025.
- [79] Liu W, Anguelov D, Erhan D, et al. Ssd: Single shot multibox detector [C]. Amsterdam: 14th European Conference on Computer Vision, 2016.
- [80] Fu C Y, Liu W, Ranga A, et al. Dssd: Deconvolutional single shot detector [J]. *arXiv*: 1701.06659, 2017.
- [81] Li Z, Yang L, Zhou F. FSSD: feature fusion single shot multibox detector [J]. *arXiv*: 1712.00960, 2017.
- [82] Zhang S, Wen L, Bian X, et al. Single-shot refinement neural network for object detection [C]. Salt Lake City: 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2018.
- [83] Yang J, Wang L. Feature fusion and enhancement for single shot multibox detector [C]. Hangzhou: 2019 Chinese automation congress (CAC), 2019.
- [84] Liu S, Huang D. Receptive field block net for accurate and fast object detection [C]. Munich: 15th European Conference on Computer Vision, 2018.
- [85] Wang R J, Li X, Ling C X. Pelee: A real-time object detection system on mobile devices [J]. *Advances in Neural Information Processing Systems*, 2018, **31**: 1–10.
- [86] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation [C]. Boston: 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015.
- [87] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation [C]. Munich: 18th International Conference on Medical Image Computing and Computer-Assisted Intervention, 2015.
- [88] Badrinarayanan V, Kendall A, Cipolla R. Segnet: A deep convolutional encoder-decoder architecture for image segmentation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, **39**(12): 2481–2495.
- [89] Lin G, Milan A, Shen C, et al. Refinenet: Multi-path refinement networks for high-resolution semantic segmentation [C]. Honolulu: 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017.
- [90] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need [J]. *Advances in Neural Information Processing Systems*, 2017, **30**: 1–15.
- [91] Zhang M, Zhang R, Yang Y, et al. ISNet: Shape matters for infrared small target detection [C]. New Orleans: 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2022.

(下转第 68 页)

- 2025, **25**(8): 12703–12710.
- [15] Lu K, Wang X, Wang B, et al. A high-precision online compensation method for random errors of optical gyroscope [J]. *Measurement*, 2023, **222**: 113616.
- [16] Bai Y, Wang X, Jin X, et al. Adaptive filtering for MEMS gyroscope with dynamic noise model [J]. *ISA Transactions*, 2020, **101**: 430–441.
- [17] Sun S, Wu Y, Pang K, et al. A High-Precision 3-D Vibration Acceleration Sensor Based on FBGs [J]. *IEEE Sensors Journal*, 2025, **25**(2): 2321–2330.
- [18] Zhou R, Chen F, Li S, et al. Three-Dimensional Vector Accelerometer Using a Multicore Fiber Inscribed With Three FBGs [J]. *Journal of Light-wave Technology*, 2021, **39**(10): 3244–3250.
- [19] Qiu Z, Zhang Y. Three-Dimensional Low-Frequency Earthquake Monitoring Vibration Sensor Based on FBG [J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, **73**: 1–9.
- [20] Wang H, Yan B, Liang L. A 3D FBG Accelerometer Based on Two Pairs of Flexible Hinges [J]. *IEEE Sensors Journal*, 2021, **21**(19): 21586–21593.
- [21] 刘钦朋, 惠君尧, 乔学光, 等. FBG 加速度传感系统随机误差模型及实验研究 [J]. *光电子·激光*, 2016, **27**(5): 468–472.
- (上接第 22 页)
- [92] Dai Y, Li X, Zhou F, et al. One-stage cascade refinement networks for infrared small target detection [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, **61**: 1–17.
- [93] Sun H, Bai J, Yang F, et al. Receptive-field and direction induced attention network for infrared dim small target detection with a large-scale dataset IRDST [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, **61**: 1–13.
- [94] Zhu H, Liu S, Deng L, et al. Infrared small target detection via low-rank tensor completion with top-hat regularization [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, **58**(2): 1004–1016.
- [95] Lu R, Yang X, Li W, et al. Robust infrared small target detection via multidirectional derivative-based weighted contrast measure [J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, **19**: 1–5.
- [96] Zhao B, Wang C, Fu Q, et al. A novel pattern for infrared small target detection with generative adversarial network [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, **59**(5): 4481–4492.
- [97] Kim J H, Hwang Y. GAN-based synthetic data augmentation for infrared small target detection [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, **60**: 1–12.