

引用格式: LIU Jun-ming, MENG Wei-hua. Infrared Small Target Detection Based on Fully Convolutional Neural Network and Visual Saliency[J]. *Acta Photonica Sinica*, 2020, 49(7):0710003

刘俊明,孟卫华.融合全卷积神经网络和视觉显著性的红外小目标检测[J].光子学报,2020,49(7):0710003

融合全卷积神经网络和视觉显著性的红外小目标检测

刘俊明¹,孟卫华^{1,2}

(1 中国空空导弹研究院,河南 洛阳 471009)

(2 航空制导武器航空科技重点实验室,河南 洛阳 471009)

摘要:为提高复杂背景和噪声干扰下红外小目标检测性能,提出了融合深度神经网络和视觉目标显著性的单阶段红外小目标检测算法.首先设计了基于编码器-解码器架构的轻量级全卷积神经网络对红外图像进行分割,实现背景抑制和目标增强;然后利用红外小目标的显著性特征进一步抑制虚警;最后采用自适应阈值法分离出小目标.网络结构中通过引入多个下采样层降低计算量并增大感受野;通过引入多尺度特征提升背景抑制能力;通过引入注意力机制提升模型训练效果.在真实红外图像上的测试表明,本文算法在检测率、虚警率和运算时间等方面都优于典型红外小目标检测算法,适合进行复杂背景下的红外小目标检测.

关键词:深度学习;目标检测;红外;全卷积神经网络;多尺度特征;显著性;小目标

中图分类号:TN216

文献标识码:A

doi:10.3788/gzxb20204907.0710003

Infrared Small Target Detection Based on Fully Convolutional Neural Network and Visual Saliency

LIU Jun-ming¹, MENG Wei-hua^{1,2}

(1 *China Airborne Missile Academy, Luoyang, Henan 471009, China*)

(2 *Aviation Key Laboratory of Science and Technology on Airborne Guided Weapons, Luoyang, Henan 471009, China*)

Abstract: To improve the infrared small targets detection performance under complex background and noise interference, a single-stage infrared small target detection algorithm combining fully convolutional neural network and visual saliency is proposed. First, a lightweight fully convolutional neural network based on encoder-decoder architecture is designed to segment infrared images. The network can suppress the background and enhance targets simultaneously. Then, the saliency features of infrared small targets are used to further suppress false alarms. Finally, an adaptive threshold method is used to extract small targets. In the network structure, multiple subsampling layers are introduced to reduce computation load and increase the receptive field; multiscale features are introduced to improve the background suppression ability; attention mechanism is introduced to improve the training result of the model. Experiments on real infrared images show that the proposed algorithm is superior to the typical infrared small target detection algorithm with respect to detection rate, false alarm rate and computation time, and is suitable for infrared small target detection under complex background.

Key words: Deep learning; Object detection; Infrared; Fully convolutional neural network; Multiscale

基金项目:航空科学基金(No.20160153001)

第一作者:刘俊明(1991-),男,博士研究生,主要研究方向为红外目标检测、深度学习.Email:ljmbuaa@126.com

导师:孟卫华(1969-),男,研究员,博士,主要研究方向为光电系统、模式识别、跟踪与控制等.Email:mengwh869@ustc.edu

收稿日期:2020-03-01;录用日期:2020-03-30

<http://www.photon.ac.cn>

feature; Saliency; Small target

OCIS Codes: 100.4996; 100.3008; 040.3060

0 引言

红外小目标检测是红外搜索与跟踪系统、红外成像制导系统和红外预警系统等现代军事作战系统的核心技术,对系统性能有重要影响^[1].当目标距离红外探测器较远时,其成像尺度较小,体现不出目标的结构和纹理信息;同时信号强度较弱,容易淹没在复杂背景干扰和探测系统噪声中^[2].因此红外小目标的检测具有一定的难度.

目前,常用的单帧红外小目标检测算法可大致分为基于背景抑制的方法、基于人眼视觉系统的方法和基于低秩稀疏矩阵分解的方法.最大中值滤波^[3]和形态学 top-hat 滤波^[4]是典型的基于背景抑制的方法.此类方法较为简单,对于复杂背景下的小目标检测效果不够理想.基于人眼视觉系统的方法利用小目标和背景之间的对比度差异来区分二者,典型算法包括局部对比度算法^[5](Local Contrast Measure, LCM)、多尺度图像块对比度算法^[6](Multiscale Patch-based Contrast Measure, MPCM)、绝对方向均值差分算法^[7](Absolute Directional Mean Difference, ADMD)、基于局部强度和梯度的算法^[8](Local Intensity and Gradient, LIG)和多尺度局部均匀性度量算法^[9](Multiscale Local Homogeneity Measure, MLHM).此类方法的缺点在于难以消除背景中具有一定显著性的杂波.基于低秩稀疏矩阵分解的方法将红外图像视为稀疏目标图像和低秩背景图像的组合,然后利用矩阵分解算法得到目标图像,代表算法包括低秩稀疏矩阵分解法(Low-Rank and Sparse Matrix Decomposition, LRSMD)^[10]和基于图像块模型的算法(Infrared Patch-Image Model, IPIM)^[11].此类方法难以消除背景中的强边缘和尖锐噪声,并且矩阵分解过程需要迭代求解,占用计算资源较多,实时性较差.

2013年以来,深度学习技术推动视觉目标检测技术取得了突破式发展^[12-17].近年来,已经有学者开始利用深度学习技术进行红外目标检测^[18-21],但主要研究对象是中等尺度的红外目标,对红外小目标的研究较少.文献[22-23]利用两个神经网络分别进行红外图像背景抑制和兴趣区域分类,从而实现红外小目标检测,但存在重复计算图像特征的情况.文献[24]利用全连接神经网络和滑动窗方法对整张图像进行评分,然后使用恒虚警率算法提取红外小目标,虽然只使用了一个神经网络,但其感受野受到窗口大小的限制,在复杂背景下容易产生大量虚警.

本文构建了融合全卷积神经网络(Fully Convolutional Network, FCN)和视觉显著性(Saliency)特征的单阶段红外小目标检测算法S-FCN.首先,利用全卷积神经网络对红外图像进行分割,实现背景抑制和目标增强;然后引入显著性特征进一步抑制虚警;最后利用自适应阈值法得到小目标位置.为增强神经网络对复杂背景的抑制能力,并降低计算量,在网络结构中采用了如下设计:1)引入多个下采样层,以降低计算量并增大感受野;2)使用多尺度的特征进行预测,有助于提升模型的背景抑制能力;3)引入注意力机制对不同尺度特征的权重进行自动调节,提升模型训练效果.

1 本文算法

1.1 检测方案

对红外图像中小目标的检测方案如图1所示.首先利用一个全卷积神经网络FCN对输入的红外图像 I 进行背景抑制和目标增强,得到红外小目标的分割图 S_0 .同时通过计算红外图像的中心-邻域对比度得到显著性图 S_1 .将红外图像分割图 S_0 与显著性图 S_1 相乘得到结果图像 S ,即

$$S = S_0 S_1 \quad (1)$$

得到结果图像 S 之后,利用自适应阈值分割算法对其进行处理,可得到红外小目标的位置.自适应阈值法的阈值为

$$t = m + k\sigma \quad (2)$$

式中, m 和 σ 分别是图像 S 的均值和标准差, k 是控制参数,一般情况下 k 取[3, 10].

图2(a)展示了文献[22-23]中采用的红外小目标检测方案.该方案中,全卷积神经网络FCN对红外图像




图1 本文算法的检测方案
Fig. 1 Proposed detection scheme

的处理结果中包含大量虚警,必须依赖深度神经网络(Deep Neural Network, DNN)分类器剔除虚警.与该方案相比,本文检测方案利用单个神经网络和对比度特征共同抑制虚警,更加简洁高效.此外,本文方案为并行结构,相比图2(a)所示的串行结构更有利于算法加速.图2(b)展示了文献[24]所采用的检测方案.该方案使用全连接神经网络对输入图像中的各个滑动窗口进行处理,最后得到输入图像的评分图.该方案中神经网络的感受野受限于滑动窗口的尺寸,导致大量虚警的出现;而增大滑动窗口尺寸又会导致计算量显著增加.与该方案相比,本文方案可以通过卷积层和下采样层逐渐扩大神经网络的感受野,可以在较低计算量的条件下实现较好的背景抑制效果.




图2 不同算法的检测方案
Fig. 2 Detection schemes of different algorithms

1.2 网络结构

全卷积神经网络最早于2015年被提出,用于解决图像语义分割问题^[25],后来逐渐在图像分类、目标检测等图像处理任务中占据主流地位.与包含全连接层的神经网络相比,全卷积神经网络的参数量和计算量更小,能够处理不同分辨率的输入图像,因此更加高效、灵活.红外小目标检测作为典型的图像处理任务,十分适合利用全卷积神经网络进行处理.但目前常用的全卷积神经网络一般规模较大,运行速度较慢,不适合应用于对实时性要求较高的红外小目标检测任务.

文献[22]和[23]中用于红外小目标检测的全卷积神经网络如图3所示.两个网络都是通过堆叠卷积层和反卷积层构造的,网络层数分别为5和4,最大特征通道数量分别为128和64.这两种网络能够在一定程度上抑制背景并增强目标,但也存在不足之处:1)网络对复杂红外背景的抑制能力不足,导致结果中存在大量虚警;2)网络规模仍有进一步下降的空间,以降低计算量提升算法运行速度;3)对于具有一定形状的红外小目标,这两个网络分割出的目标区域不够完整.

本文所采用的全卷积神经网络结构如图4所示.该网络借鉴了图像语义分割网络常用的编码-解码架构.网络中的编码器包含4个卷积层和2个最大池化层,形成了3种不同尺度的特征.解码器以编码器中多个尺度的特征图作为输入,经过上采样之后拼接到一起,然后经过卷积层和激活函数处理得到最终的输出图像.




图3 用于红外小目标检测的典型全卷积神经网络
Fig. 3 Typical fully convolutional neural networks for infrared small target detection.

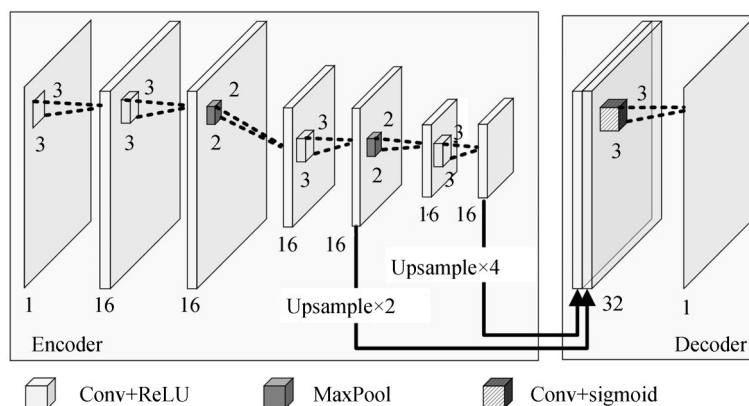


图4 本文全卷积神经网络结构
Fig. 4 Proposed fully convolutional neural network

与经典编解码架构的全卷积神经网络相比,本文网络中解码器的结构更加简单,并且仅采用了两种不同尺度的特征.这是因为网络前两个卷积层抽取的是低级几何特征,其中包含了大量背景杂波信息,如果将这些特征输入到解码器中则不利于对红外背景的抑制.此外,在网络最后一层之前引入了压缩激励(Squeeze and Excitation, SE)网络层^[26],这是一种注意力调节机制,能够在网络训练过程中不断学习,从而自适应调节各个通道特征所占权重,提升训练效果.

与图3中的网络相比,本文网络的卷积层数量与之相当,但额外引入了2个下采样层.不但扩大了网络的感受野,也同时降低了网络计算量.增大感受野能够扩大神经元的感知范围,更有利于网络对目标点和背景杂波进行区分.

1.3 视觉显著性

全卷积神经网络对红外图像的分割结果中存在一定数量的虚警.这些虚警主要来源于背景中的斑点状噪声和强边缘特征.为了抑制这些虚警,降低其对检测结果的影响,在检测算法中引入了视觉显著性特征.

由于具有较高的辐射强度,红外图像中的小目标与局部邻域之间具有较高的对比度,从而具备显著性.ADMD、MPCM、MLHM等算法都是基于红外小目标的显著性特征构建的.定义红外图像中像素 i 与局部邻域之间的对比度为

$$c_i = (I_i - m_i)^2 \quad (3)$$

式中, I_i 是红外图像 I 中第 i 个像素的灰度值, m_i 是该像素的邻域均值,邻域大小定义为 9×9 .

根据式(3)的定义,整张红外图像的对比度特征计算过程可以基于卷积运算实现.因此式(3)所表达的计算模型可以与全卷积神经网络模型结合在一起成为一个统一的计算模型.

2 实验与分析

2.1 数据集

红外探测技术由于其军事应用价值而具有一定敏感性,因此领域内尚无公开的大型红外小目标数据集.而红外小目标数据的采集成本也较高,当需要构建较大规模的红外小目标数据集时,利用合成数据来扩大数据集容量已经是一种较为常见的做法^[22].

当目标与红外探测器距离较远时,其辐射特性接近一个点源,因此其在图像平面的分布由光学系统的点扩散函数决定.通常采用二维高斯函数来模拟红外小目标的分布特性^[24],即

$$I(x, y) = a \exp \left\{ -\frac{1}{2} \left[\frac{(x-x_0)^2}{\sigma_x^2} + \frac{(y-y_0)^2}{\sigma_y^2} \right] \right\} \quad (4)$$

式中, $I(x, y)$ 表示目标图像中坐标 (x, y) 处的像素值, (x_0, y_0) 表示目标中心的坐标, a 是目标灰度最大值, σ_x 和 σ_y 分别是控制目标在水平和垂直方向散布程度的参数.根据国际光学工程学会的定义,小目标的尺寸一般不超过 9×9 ^[27],同时为避免出现单像素的目标,将 σ_x 和 σ_y 的变化范围设定为 $[0.5, 2.5]$.

根据式(4)构造了2000个目标图像.其中,目标图像的分辨率为 21×21 ; a 始终为1; σ_x 和 σ_y 分别在 $[0.5, 2.5]$ 之间随机取值.此外在构造目标图像过程中还为目标添加了旋转效果,旋转角度在 $[0, 2\pi)$ 之间随机取值.典型目标图像如图5所示.




图5 基于二维高斯函数模型的典型目标图像
Fig. 5 Typical target image based on 2D Gaussian model

选择1000张真实红外场景图片,其中包括天空背景和天地交接背景.然后在每张红外图像中随机添加噪声和40个红外小目标.每张图像中添加40个红外小目标是为了缓解正负样本即目标与背景之间的不平衡问题.如果每张图像中目标的数量过少则正负样本之间不平衡现象会趋于恶化,影响深度神经网络的训练和最终性能.典型的合成红外小目标图像如图6(a)和(b)所示.




图6 典型红外小目标图像
Fig. 6 Typical infrared images with small targets

对深度神经网络的训练都基于合成数据进行.为了对各类红外小目标检测算法进行测试和评估,数据集中还引入了443张真实红外小目标图像,每张图像中包含1~3个红外小目标.典型的真实红外图像如图6(c)和(d)所示.

与合成图像相比,真实图像中的背景和噪声更加复杂;红外小目标形态变化更加多样,后者可能不完全符合式(4)中定义的高斯分布模型.合成图像与真实图像之间存在的差别有利于对深度神经网络的泛化能力进行评估.

2.2 训练设置

利用构建的红外小目标数据集对网络模型进行训练,训练批大小为32,最大迭代步数设置为10 000,采用的优化算法是Adam算法.训练过程中,每1 000步评估一次.训练结束后,将评估结果最好的一次作为最终模型.

2.3 网络结构分析

首先以图4中的网络为基础,对不同形式的网络结构设计进行了对比,结果如表1所示.表中的计算量是指当输入图像分辨率为 256×256 时神经网络单次前向传播所需的浮点运算次数,检测率 P_d 和虚警率 F_a 用于评价算法的检测能力,二者定义为

$$P_d = \frac{N_d}{N_i} \quad (5)$$

$$F_a = \frac{N_a}{N} \quad (6)$$

式中, N_d 表示检测到的真实目标数量, N_i 表示所有真实目标的总数, N_a 表示检测到的虚警数量, N 表示所有图像的像素总数.

表1 本文网络的不同设计对比
Table 1 Comparison of different design choices of proposed network

Type	Description	P_d	F_a	GFLOPs
M1	Base network in Fig. 4	0.940 8	7.97×10^{-6}	0.235
M11	Without down-sampling layer	0.938 9	2.01×10^{-5}	0.494
M12	Without feature of 3rd conv layer	0.929 4	1.11×10^{-5}	0.226
M13	Without SE layer	0.938 9	1.42×10^{-5}	0.235

根据表1,网络M11的计算量达到了M1的两倍以上,但检测性能并没有提升,虚警率反而明显高于后者,表明网络M1中引入的下采样层能够在降低网络计算量的同时提升网络对背景的抑制能力.M12和M1相比,虽然计算量有一定降低,但检测率和虚警率指标出现了恶化,表明本文网络M1中利用多尺度特征进行预测的机制能够提升网络性能.由于SE网络层所需计算量较小,所以M13和M1计算量基本一致.但去掉SE网络层之后M13无法自适应调节不同特征的权重,从而损害了模型性能,其虚警率明显高于M1网络.

将本文网络与文献中的全卷积神经网络进行了对比,结果如表2所示.本文网络M1在计算量显著低于M2和M3的情况下实现了更高的检测率和更低的虚警率,表明其结构的高效.图7展示了表2中不同网络对

表2 不同网络的性能
Table 2 Performance of different networks

Type	Description	P_d	F_a	GFLOPs
M1	Network in Fig. 4	0.940 8	7.97×10^{-6}	0.235
M2	Network in Fig. 3(a)	0.931 3	1.06×10^{-5}	6.47
M3	Network in Fig. 3(b)	0.933 2	4.23×10^{-5}	1.54




图7 不同网络分割结果示例
Fig. 7 Segmentation results of different networks

复杂地物背景下红外小目标图像的分割结果.从图中可以看出,网络M3的分割结果最差,树木和房屋区域留下了大量虚警点;网络M2的分割结果明显更好,但仍有部分较强的虚警点残留;本文网络M1的分割结果最好,虚警的数量和强度都进一步降低.

2.4 有无视觉显著性分析

为了评估视觉显著性机制的作用,利用接收者操作特性(Receiver Operating Characterizing, ROC)曲线在有/无对比度特征的情况下对本文算法的检测性能进行了评估.ROC曲线是通过逐渐变换算法检测门限得到的检测率 P_d 随虚警率 F_a 的变化曲线,如图8所示.可以看出,当虚警率处于较低水平时,包含对比度特征的检测算法对红外小目标的检测率更高.这是由于深度卷积神经网络容易将背景中的虚弱斑点状特征和尖峰噪声等误识别为目标进而造成虚警,而对比度特征有利于对这些虚警进行抑制.

3 测试

为表明本文算法的先进性,基于测试数据集将本文算法与6种典型红外小目标检测算法进行了多方面对比.6种对比算法中包括4种传统红外小目标检测算法:ADMD、IPIM、LIG、MAX-MEDIAN;以及2种基于深度神经网络的方法FCN+CNN^[22]、FMDNN^[24].传统算法基于Matlab 2018a平台实现,神经网络算法基于PyTorch 1.1.0平台实现,实验所用计算机CPU为Core i5处理器,主频为2.9 GHz;GPU为GTX 1080;内存为16G;操作系统为Windows 10.其中GPU仅用于对神经网络模型的训练,对算法进行测试时统一使用CPU.

3.1 单张图像对比

首先选择了8幅具有代表性的红外图像对7种算法进行测试和对比.前4张测试图像为天空背景,第5、6张为天空和地物背景,最后两张为地物和海面背景.8张测试图像的原始图像及处理结果如图9所示.采用信杂比增益 G 评估算法对红外小目标的增强效果,其定义为

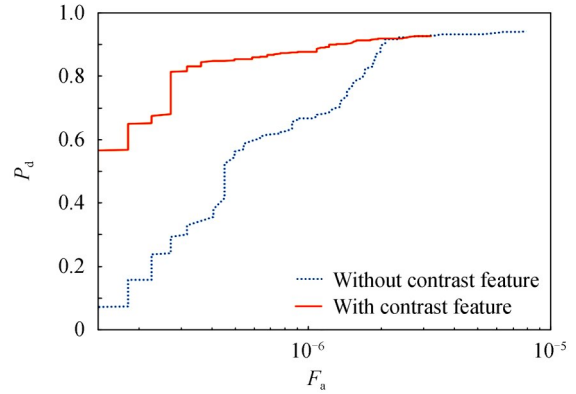



图8 有无对比特征时本文算法的ROC曲线
Fig. 8 ROC curve of proposed algorithms with and without contrast feature




图9 测试图像及7种算法处理结果
Fig. 9 Test images and results of seven algorithms

$$G = \frac{S_{out}}{S_{in}} \quad (7)$$

式中, S_{in} 和 S_{out} 分别表示在原始图像和算法处理结果中红外小目标的信杂比. 信杂比定义为

$$S = \frac{|p_t - \mu_b|}{\sigma_b} \quad (8)$$

式中, p_t 表示目标区域最大灰度值, μ_b 和 σ_b 分别表示背景区域灰度均值和标准差. 采用背景抑制因子 B 评估算法对红外背景的抑制能力, 其定义为

$$B = \frac{\sigma_{in}}{\sigma_{out}} \quad (9)$$

式中, σ_{in} 和 σ_{out} 分别为原始红外图像和算法处理后图像的标准差.

7种算法在8张测试图像上的信杂比增益和背景抑制因子如表3和4所示. 表4中的“-”表示该算法未能检测到红外图像中的小目标, 因此不统计其背景抑制因子.

除IPIM和LIG算法外, 其余算法都能检测出8张测试图像中的所有红外小目标, 但各个算法对红外小目标的增强效果以及对红外背景的抑制能力相差较大.

表3 不同算法对8张测试图像的信杂比增益
Table 3 G of different algorithms on 8 test images

Index	ADMD	IPIM	LIG	MaxMedian	FMDNN	FCN+ CNN	S-FCN
1	20.3	78.9	31.0	12.0	25.1	63.6	118.0
2	17.9	0	0.1	4.8	15.2	21.0	28.9
3	10.1	38.9	6.4	12.7	5.3	17.1	55.9
4	16.9	17.9	20.5	15.9	19.0	25.9	25.3
5	8.2	12.5	9.6	1.8	5.9	6.9	12.6
6	56.1	0.0	1.9	50.3	33.5	310.8	520.7
7	5.2	24.2	3.8	19.5	7.2	9.9	29.8
8	12.5	37.0	35.2	14.5	4.4	19.7	51.3

表4 不同算法对8张测试图像的背景抑制因子
Table 4 B of different algorithms on 8 test images

Index	ADMD	IPIM	LIG	MaxMedian	FMDNN	FCN+ CNN	S-FCN
1	4.2	19.9	6.3	2.5	5.1	12.8	23.7
2	5.3	-	-	1.4	4.5	6.2	8.5
3	4.1	19.6	5.0	5.1	2.1	6.8	22.3
4	6.1	8.2	7.4	5.8	6.9	9.4	9.2
5	2.2	3.4	2.6	0.9	1.6	1.9	3.4
6	3.7	-	-	3.0	1.9	17.9	29.3
7	2.3	13.6	3.1	8.3	3.1	4.3	12.7
8	6.6	27.7	18.4	7.6	2.4	10.3	26.8

对于第1~3张测试图像,本文算法能够在抑制图像中的云杂波和尖峰噪声的同时实现目标增强,其信杂比增益和背景抑制因子最优.对于第4张测试图像,本文算法高效抑制了背景,并较完整地分割出了目标所在区域,但背景抑制因子反而低于FCN+CNN算法.这是因为FCN+CNN算法仅检测到了目标的头部和尾部,没有检测到目标的机身区域.对于第5张图像,本文算法对目标的增强效果以及对背景的抑制效果与IPIM算法相当,并优于其他算法.对于第6张图像,由于背景较复杂,IPIM和LIG算法未能检测到目标.本文算法不但检测到了目标,并且对背景中建筑物和树木的抑制效果最好.对于第7~8张图像,本文算法能够有效抑制背景中的噪声和强边缘,相比FMDNN和FCN+CNN算法优势明显.虽然本文算法的背景抑制因子略低于IPIM,但目标信杂比增益明显更高.

综合8张测试图像上的结果来看,本文算法的处理效果最好,在增强目标的同时能够有效抑制复杂背景和噪声.

3.2 数据集

在测试数据集上对7种算法进行了测试,利用ROC曲线来对比各种算法的检测性能,结果如图10所示.本文算法的ROC曲线位于其他算法的左上方,表明其检测性能优于其他算法.

当虚警率为 3.2×10^{-6} 时,本文算法的检测率已经超过了92%,此时其他算法的检测率不高于84%.随着检测门限降低,各种算法的虚警率和检测率逐渐增大.其中,ADMD、MaxMedian、和FMDNN算法的检测率增长趋势明显,但当其检测率超过本文算法时,虚警率已经大于 6.9×10^{-5} ,是本文算法21倍以上.

在测试集中选定了50张 128×128 的红外图像,然后对本文算法和6种对比算法进行了多轮速度测试,最后得到各个算法处理单张图像的平均用时,如表5所示.可以看出,本文算法的运算时间最短.

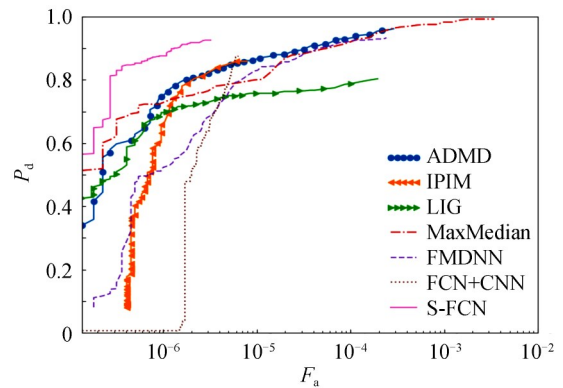


图10 不同算法的ROC曲线
Fig. 10 ROC curves of different algorithms

表5 不同算法的平均运算时间
Table 5 Average run time of different algorithms

Method	ADMD	IPIM	LIG	MaxMedian	FMDNN	FCN+CNN	S-FCN
Time/s	0.996	0.866	0.284	0.219	0.066	0.164	0.033

4 结论

本文设计了基于编码器-解码器架构的轻量级全卷积神经网络对红外图像进行分割,并引入了中心-邻域对比度特征抑制分割结果中可能存在的虚警,最终得到了一个用于红外小目标检测的整体计算模型.在合成图像上的训练以及在真实图像上的测试表明,本文所提出的方法在检测率、背景抑制能力、检测速度上优于典型红外小目标检测算法,且本文网络模型的泛化能力,能够从仿真数据中学得有效的特征并应用于对真实数据的处理中.未来可以对神经网络的结构进行优化设计,以实现更高效的目标检测,并可以就深度神经网络与传统检测算法的结合展开研究.

参考文献

- [1] DONG Wei-ke. Research on new methods of detection of infrared dim small target in cluttered sky background[D]. Xi'an: Xidian University, 2013
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.
- [2] XU Hang, ZHANG Xi-tao, ZHANG Jun-peng. Background suppression algorithm for infrared small target image based on local mean difference[J]. *Acta Aeronautica et Astronautica Sinica*, 2015, **36**(9): 2869-2873.
徐航, 张喜涛, 张军鹏. 基于局部均值差分的红外小目标图像背景抑制算法[J]. 航空学报, 2015, **36**(9): 2869-2873.
- [3] XU Y, ZHANG J. Real-time detection algorithm for small space targets based on max-median filter[J]. *Journal of Information & Computational Science*, 2014, **11**(4): 1047-1055.
- [4] WU Wei, PENG Jia-xiong, WANG Hai-hui. Characteristics analysis and detection of small target in infrared image sequences[J]. *Infrared and Laser Engineering*, 2002, **31**(2): 146-149.
吴巍, 彭嘉雄, 王海晖. 红外图像序列小目标的特性分析与检测[J]. 红外与激光工程, 2002, **31**(2): 146-149.
- [5] CHEN C L P, LI H, WEI Y T, *et al.* A local contrast method for small infrared target detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, **52**(1): 574-581.
- [6] WEI Y T, YOU X G, LI H. Multiscale patch-based contrast measure for small infrared target detection[J]. *Pattern Recognition*, 2016, 58: 216-226.
- [7] MORADI S, MOALLEM P, SABAH M F. Fast and robust small infrared target detection using absolute directional mean difference algorithm[J]. *arXiv preprint arXiv:1810.03173*, 2018.
- [8] ZHANG H, ZHANG L, YUAN D, *et al.* Infrared small target detection based on local intensity and gradient properties[J]. *Infrared Physics & Technology*, 2018, 89: 88-96.
- [9] 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.
- [10] ZHENG C Y, LI H. Small infrared target detection based on low-rank and sparse matrix decomposition[J]. *Applied Mechanics and Materials*, 2013, **239-240**(6): 214-218.
- [11] 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.
- [12] REDMON J, DIVVALA S, GIRSHICK R, *et al.* You only look once: unified, real-time object detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [13] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 7263-7271.
- [14] LIU W, ANGUELOV D, ERHAN D, *et al.* SSD: Single shot multibox detector[C]. European Conference on Computer Vision, 2016: 21-37.
- [15] GIRSHICK R, DONAHUE J, DARRELL T, *et al.* Rich feature hierarchies for accurate object detection and semantic segmentation[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [16] GIRSHICK R. Fast R-CNN[C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [17] REN S, HE K, GIRSHICK R, *et al.* Faster R-CNN: towards real-time object detection with region proposal networks[C]. Advances in Neural Information Processing Systems, 2015: 91-99.
- [18] XIE Jiang-rong, LI Fan-ming, WEI Hong, *et al.* Enhancement of SSD for aerial infrared target detection[J]. *Acta Optica Sinica*, 2019, **39**(6): 0615001.
谢江荣, 李范鸣, 卫红, 等. 用于空中红外目标检测的增强单发多框检测器方法[J]. 光学学报, 2019, **39**(6): 0615001.
- [19] CHEN Tie-ming, FU Guang-yuan, LI Shi-yi, *et al.* Research on typical target detection for infrared homing guidance[J]. *Laser & Optoelectronics Progress*, 2019, **56**(16): 161502.
陈铁明, 付光远, 李诗怡, 等. 基于YOLO v3的红外末制导典型目标检测[J]. 激光与光电子学进展, 2019, **56**(16): 161502.

- [20] WANG Wen-xiu, FU Yu-tian, DONG Feng, *et al.* Infrared ship target detection method based on deep convolution neural network[J]. *Acta Optica Sinica*, 2018, **38**(7): 0712006.
王文秀,傅雨田,董峰,等.基于深度卷积神经网络的红外船只目标检测方法[J].光学学报,2018,**38**(7): 0712006.
- [21] ZHOU M, JING M, LIU D, *et al.* Multi-resolution networks for ship detection in infrared remote sensing images[J]. *Infrared Physics & Technology*, 2018, **92**: 183-189.
- [22] LIN Liang-kui, WANG Shao-you, TANG Zhong-xing. Point target detection in infrared over-sampling scanning images using deep neural networks[J]. *Journal of Infrared and Millimeter Waves*, 2018, **37**(2): 219-226.
林两魁,王少游,唐忠兴.基于深度卷积神经网络的红外过采样扫描图像点目标检测方法[J].红外与毫米波学报,2018,**37**(2): 219-226.
- [23] WU Shuang-zhen, ZUO Zheng-rong. Small target detection in infrared images using deep convolutional neural networks [J]. *Journal of Infrared and Millimeter Waves*, 2019, **38**(3): 371-380
吴双忱,左峥嵘.基于深度卷积神经网络的红外小目标检测[J].红外与毫米波学报,2019,**38**(3): 371-380.
- [24] GAO Z, DAI J, XIE C. Dim and small target detection based on feature mapping neural networks[J]. *Journal of Visual Communication and Image Representation*, 2019, **62**: 206-216.
- [25] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C].Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3431-3440.
- [26] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C].Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [27] ZHANG W, CONG M, WANG L. Algorithms for optical weak small targets detection and tracking [C].International Conference on Neural Networks and Signal Processing, 2003, **1**: 643-647.