

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

林两魁, 王少游, 唐忠兴
(上海卫星工程研究所, 上海 201109)

摘要:针对红外过采样扫描成像特点,提出一种基于深度卷积神经网络的红外点目标检测方法.首先,设计回归型深度卷积神经网络以抑制扫描图像杂波背景,该网络不含池化层,输出的背景抑制图像尺寸与输入图像一致;其次,对抑制后的图像进行门限检测,提取候选目标小区域原始数据;最后,将候选目标区域数据依次输入分类型深度卷积神经网络以进一步判别目标、剔除虚警.生成大量过采样训练数据有效训练两个深度网络.结果表明,在不同杂波背景下,该方法在目标信杂比增益、检测概率、虚警概率和运算时间等方面,均优于典型红外小目标检测方法,适用于红外过采样扫描系统的点目标检测.

关键词:模式识别与智能系统;点目标检测;卷积神经网络;红外过采样扫描;深度学习
中图分类号:TP753 **文献标识码:**A

Point target detection in infrared over-sampling scanning images using deep convolutional neural networks

LIN Liang-Kui, WANG Shao-You, TANG Zhong-Xing
(Shanghai Institute of Satellite Engineering, Shanghai 201109, China)

Abstract: Aiming at the characteristics of infrared over-sampling scanning imaging, an infrared point target detection method based on DCNN (Deep Convolution Neural Network) is proposed. Firstly, a regressive-type DCNN is designed to suppress the background clutter of the scanning image. The network does not contain any pooling layer, so can input the original image of any size, with the size of output image after clutter suppression in accordance with the input image. Subsequently, the post-suppression image is tested and the original data of candidate target region is extracted. Finally, the candidate target area raw data is input into the classification-type DCNN to further identify the target and remove the false alarm. Meanwhile, a large number of training data of infrared over-sampling scanning images are designed, and two networks are trained effectively. The experimental results show that the proposed method is superior to multiple typical infrared small target detection methods in the target clutter ratio gain, detection probability, false alarm probability and running time under different clutter backgrounds, and is applicable to the point target detection of the infrared oversampling scanning system.

Key words: pattern recognition and intelligent systems, point target detection; convolution neural network, infrared over-sampling scanning, deep learning

PACS: 84.40.Xb

引言

光学扫描相机成像视场大、覆盖范围广、空间分辨率高,是航空航天遥感系统的重要载荷.为进一步提高扫描相机空间分辨率,法国研究人员提出过采样扫描成像新体制,并成功应用于 SPOT-5 遥感卫星^[1].该体制不改变光学系统配置,只将常规采样体制的一排行列像元替换成两排,在线列方向错开半个像元间隔排列,在扫描方向每隔半个像元瞬时视场 (Instantaneous Field of View, IFOV) 采样 1 次,过采样数据经融合处理后图像分辨率优于常规采样.美国研究人员则将该体制应用于空间红外搜索与跟踪 (Infrared Search and Track,IRST) 系统,如 MSX 卫星 SPIRIT-III 载荷^[2]、新一代空间红外扫描传感器等^[3],实现对远距离高速运动目标的探测、捕获和跟踪.在红外过采样扫描图像中,远距离点目标呈现规则性像斑形态,与单点、线状等非规则虚警点区别明显,背景则因相邻像元的重叠采样被平滑,这些因素均有利于提高系统点目标检测性能^[4-7].

IRST 系统为适应动态变化场景、提高处理速度和降低通信数据量,一般采取先单帧检测候选目标、然后多帧关联捕获运动目标的处理策略^[5,8-9],因此单帧图像目标检测是 IRST 的关键技术.红外过采样扫描单帧图像点目标检测属于红外小目标检测领域.该领域已提出了大量检测方法,如基于图像滤波背景估计的 Max-Mean^[10]、Max-Median^[10]、Top-Hat^[11]、TDLMS^[12]、MRF 自适应正则化滤波^[13]等,以及基于压缩感知目标背景分离的低秩和稀疏矩阵分解方法 LRSMD^[9,14]、压缩域目标检测方法^[15]和稀疏表示目标检测方法^[16]等.这些方法一般基于人工构造特征数据,性能依赖于人工提取特征的鲁棒性和完整性.在机器视觉的目标检测(物品、动物、交通工具等)领域,受益于深度学习技术特别是深度卷积神经网络 (DCNN, Deep Convolution Neural Network) 的发展,近期提出的基于深度学习目标检测方法,如 R-CNN^[17]、Fast R-CNN^[18]、Faster R-CNN^[19]、YOLO^[20]等,在目标检测性能上取得了巨大突破,已成为目标检测主流发展方向.深度学习直接从大量训练数据中自动学习特征,相比于人工构造特征,更有利于描述数据本身丰富、特有信息.然而,红外小目标仅占图像中的有限几个像素且仅含灰度值,并不具备机器视觉应用中待检测目标的明显尺寸、纹理和色彩等判别特征,已有的机器视觉领

域深度学习目标检测方法并不适用于红外小目标检测.为此,针对红外过采样扫描成像特点和深度学习技术特点,提出一种基于 DCNN 的红外过采样扫描图像点目标检测方法,从红外小目标深度学习检测框架、面向红外小目标检测的 DCNN 网络设计及训练样本数据生成等三个方面展开探索研究,首次实现了基于深度学习的红外小目标检测方法.

后续内容组织如下:第 1 节分析红外过采样扫描成像特点;第 2 节给出基于 DCNN 的点目标检测框架,描述 CNN 基本组成模块,设计面向点目标检测的回归型 DCNN 和分类型 DCNN;第 3 节为实验结果与分析,对比了本文方法与典型红外小目标检测方法的检测性能;第 4 节为结论.

1 红外过采样扫描成像特点

扫描相机通过反射镜摆扫或平台运动将物空间光线依次聚焦到焦平面使行列像元感光成像^[6-7].如图 1,常规采样体制焦平面由单行列像元组成,扫描时物空间视场每间隔一个 IFOV 曝光成像一次,通过连续扫描获得二维图像.过采样体制则采用错开半个像元距离并列的两排行列像元焦平面结构,实现行列方向空间过采样,在扫描方向每扫过半个 IFOV 曝光成像一次,实现时间过采样.

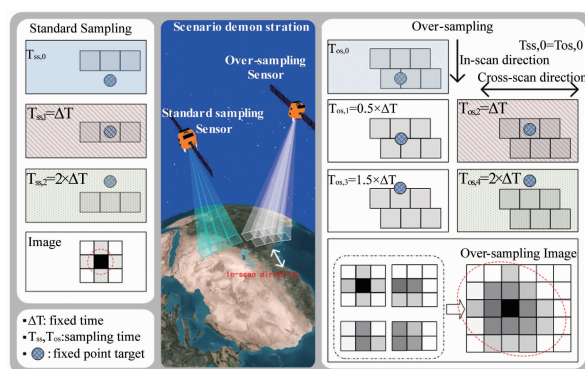


图 1 过采样与常规采样的扫描成像特点对比
Fig. 1 Imaging characteristic contrast between over-sampling and standard sampling

由图 1 可以看出,相比于常规采样,过采样能提高点目标落入像元中心的概率,从而提高系统对点目标的响应特性;通过时空双向过采样,多个邻近像元能探测到相同点目标的能量,使点目标在像平面上的成像呈现有别于常规采样的斑状特性.此外,由于邻近像元对相同背景进行了部分重叠采样,从而对背景杂波成像进行了平滑.

红外过采样扫描体制对背景的平滑成像及对点

目标规则性斑状成像特性,构成了扫描图像中点目标区别于背景杂波和单点、线状等虚警点的潜在结构性特征,是基于机器学习方法实现目标检测的物理基础。

2 红外过采样扫描点目标检测的深度学习框架与方法

传统红外小目标检测方法存在两个方面问题:一是人工设计的特征对于多样性变化场景鲁棒性不足;二是基于滑动窗口的候选目标区域选择策略没有针对性,窗口冗余且运算复杂。为此,本文基于深度学习方法,设计两个回归型和分类型 DCNN,综合回归型 DCNN 对原始图像进行一次性卷积运算、高灵敏度提取候选目标能力及分类型 DCNN 高精度目标识别能力,将两者统一到目标检测框架中,有效解决传统红外小目标检测问题。

2.1 目标检测框架

如图 2 所示,基于 DCNN 的红外过采样扫描图像点目标检测框架由三部分构成:回归型 DCNN、候选目标提取和分类型 DCNN。




图 2 基于 DCNN 的红外过采样扫描图像点目标检测框架
Fig. 2 DCNN-based framework of infrared over-sampling scanning point target detection

原始图像直接输入回归型 DCNN,该网络执行杂波背景抑制保留点目标斑状像,对输入图像无固定尺寸要求,且输出的杂波抑制后图像尺寸与输入图像一致。回归型 DCNN 将背景杂波抑制到极低水平,因此后续通过简单门限检测即可定位候选目标,进而提取候选目标区域原始数据。候选目标数据依次输入分类型 DCNN 进行目标高精度识别处理,进一步确认目标、剔除虚警。

回归型 DCNN 以端对端方式实现候选目标定位与提取,对整幅输入图像执行一次性卷积网络运算即可实现目标候选区域提取,以低运算量高敏获取候选目标的同时大幅降低后续分类型 DCNN 的输入数据量;分类型 DCNN 实现候选目标的高精度识别。该框架将两个执行不同任务的 DCNN 有效统一起来,综合两者优势实现高性能目标检测。

2.2 深度卷积神经网络

2.2.1 卷积神经网络基本模块

卷积神经网络是深度学习的一类重要技术,在图像识别、语音识别和自然语言处理等领域应用广泛^[21]。该网络基本模块包括卷积层(convolution)、池化层(pooling)和非线性激活函数等。

卷积层是 CNN 的核心组件,通过局部感知和参数共享机制自动提取数据隐含特征。卷积层将输入数据和不同卷积核进行卷积运算,输出多幅特征图(feature map)。记 h_i^l 为 l 层的第 i 个特征图,前一层的第 k 个特征图记为 h_k^{l-1} ,则第 l 层的前馈运算如下式,

$$h_i^l = \sigma \left(\sum_k h_k^{l-1} * W_{ki}^l + b_i^l \right) \quad (1)$$

式中, W_{ki}^l 和 b_i^l 分别为卷积核参数和截距项参数, $*$ 表示卷积操作, $\sigma(\cdot)$ 为逐元素操作的非线性激活函数,一般采用修正线性单元(ReLU),定义如下,

$$\text{ReLU}(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (2)$$

与传统的 S 型(sigmoid)和双曲正切(tanh)激活函数相比,ReLU 函数有效克服网络反向传播中的梯度弥散问题,加快网络训练收敛速度。

池化操作是一种有效降维方式,并能抑制网络过拟合,常见有最大池化和平均池化两种。但是池化降低了特征图分辨率,在过采样点目标或红外小目标检测应用中,目标本身尺寸小,若进行多层池化操作势必显著降低目标特征,影响目标检测性能。为此,本文在设计 CNN 中不考虑池化操作。

在卷积神经网络模型训练中,一般增加丢弃(dropout)操作,通过随机丢弃部分网络中间计算结果,使网络更为稳健,也是缓解过拟合的有效对策。

2.2.2 回归型深度卷积神经网络

设计回归型深度卷积神经网络,以端对端形式抑制图像杂波背景、凸显目标特征。如图 3 所示,该网络包含 5 层卷积层,卷积核尺寸 3×3 ,各卷积层的激活函数为 ReLU,输出层含 1 幅特征图,预测杂波抑制后的图像。由于不含池化层,输入图像和各网络层特征图分辨率保持不变,使得输出图像的尺寸与输入图像尺寸一致,这种分辨率不变的图像操作使得该网络可输入任意尺寸图像。因此,可采用小尺寸训练数据进行网络训练,训练后的网络可对任意尺寸图像进行前馈操作。

在网络训练中输出层外接均方误差损失函数,如下式,




图3 回归型深度卷积神经网络结构
Fig. 3 Regression-type DCNN structure

$$\ell_{MSE}(\mathbf{y}, \mathbf{y}') = \frac{1}{2N} \sum_{i=1}^N \|\mathbf{y}_i - \mathbf{y}'_i\|^2, \quad (3)$$

式中, \mathbf{y}'_i 为批训练数据中第 i 个数据真值, \mathbf{y}_i 则为网络预测值; $\mathbf{y}_i, \mathbf{y}'_i \in R^m$, m 为训练数据中图像尺寸.

2.2.3 分类型深度卷积神经网络

设计分类型深度卷积神经网络,如图4.该网络包含4层卷积层和1层全连接层,卷积核尺寸 3×3 ,各卷积层的激活函数 ReLU.该网络不含池化层,以避免降低小目标特征的显著性.全连接层后接输出层,输出两类信息,针对输入的候选目标区域判别背景和为目标类型.




图4 分类型深度卷积神经网络结构
Fig. 4 Classification-type DCNN structure

在输出层对全连接层输出进行 Softmax 回归计算,将预测值转化为背景和目标的类别概率,Softmax 计算式如下,

$$\text{softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^c e^{z_j}}, \quad (4)$$

式中, $\mathbf{z} = [z_1, z_2, \dots, z_c]^T$ 为全连接的输出, c 为网络判别的类型数量.

在网络训练中全连接层外接 Softmax 损失函数,如下式,

$$\ell(\mathbf{z}, c) = -\log \frac{e^{z_c}}{\sum_{k=1}^c e^{z_k}}. \quad (5)$$

2.3 门限检测及候选目标区域提取

原始图像经回归型 DCNN 抑制杂波后,目标信号增强,通过设置门限值进行过门限处理可提取候选目标,如下式,

$$Th = \mu_{img} + k \cdot \sigma_{img}, \quad (6)$$

$$T(x, y) = \begin{cases} I(x, y), & \text{if } I(x, y) \geq Th \\ 0, & \text{otherwise} \end{cases}, \quad (7)$$

式中, μ_{img} 、 σ_{img} 分别为抑制图像的均值和标准差, $k \geq 3$, $I(x, y)$ 、 $T(x, y)$ 分别为坐标 (x, y) 处抑制图像的灰度值和过门限图像取值.

对过门限图像 T 进行四邻域聚类提取候选目标,对每个候选目标聚类,以灰度值加权方式计算目标估计位置,最后以该位置为中心,提取候选目标邻域原始图像数据作为分类型 DCNN 的输入.

2.4 深度卷积神经网络的训练和参数设置

监督型深度学习技术需要大量训练数据求解网络参数.通过仿真试验获取不同背景和点目标过采样扫描图像^[6],生成大量训练数据.

对回归型 DCNN,训练图像尺寸取 18×18 ,在大尺寸背景图像上以滑窗方式获取大量背景训练数据,从中提取部分背景数据,通过仿真在图像不同位置添加不同强度过采样点目标,最终生成了3万组训练图像,部分训练数据如图5.训练背景图像标签为全零值图像;含背景与目标的训练图像,标签则为仅含目标的相同尺寸图像.




图5 回归型 DCNN 的部分训练数据集
Fig. 5 Some training data for regression-type DCNN

分类型 DCNN 训练数据的生成与回归型 DCNN 类似,图像尺寸取 11×11 ,同样生成3万组训练图像;对含有目标和背景的训练图像,设置目标处于距离图像中心位置1.5像元的区域,以适应门限检测候选目标位置提取产生的误差.

对输入两个 DCNN 的图像数据进行预处理,以提高网络性能,采取输入图像归一化然后减去均值的预处理操作.

DCNN 训练的硬件设备采用 HASEE G8-KL7S2 笔记本,内置 Intel Core i7-6820HK 处理器, GPU 显卡为 NVIDIA GTX980M,内存 16G;软件采用 Matconvnet 卷积神经网络工具包^[22].训练中,mini batch

数量取 50, 采取自适应动态调整学习率 0.05 ~ 0.000 1, 最大迭代次数 3 000.

3 实验

为验证检测方法有效性, 利用原理样机收集不同杂波背景下的红外过采样扫描图像进行实验, 并与 Max-Median^[10]、Top-Hat^[11]、LRSMD^[14] 等典型红外小目标检测算法进行性能对比.

3.1 单次检测结果

下面给出 DCNN 方法对红外过采样扫描图像的点目标检测结果示例, 如图 6 所示. 图 6(a)、(b) 为原始扫描图像的二维、三维图, 图中含两个点目标; 图 6(c)、(d) 为回归型 DCNN 处理结果, 可以看出, 回归型 DCNN 很好抑制杂波背景、凸显目标; 通过门限检测提取出 3 个候选目标, 含 2 个真实目标和 1 个虚警点; 提取出的候选目标区域原始数据, 及分类型 DCNN 相应分类结果如图 6(e), 分类型 DCNN 最终确认了两个真实目标、剔除 1 个虚警点. 本文设定提取的候选目标区域图像尺寸为 11 × 11.

3.2 杂波背景抑制结果

图 7 为三幅仿真的红外过采样扫描测试图像, 具有不同的杂波背景强度、非均匀性和条纹噪声等, 每幅图像均包含 3 个点目标. 图 7(a)、(c)、(e) 分别为三幅原始图像及不同检测方法的杂波背景抑制结果 2 维图, 图 7(b)、(d)(f) 则分别为对应的 3 维图. 图 7 中第 1 列为原始扫描图像, 第 2 ~ 5 列分别为 Max-Median、Top-Hat、LRSMD 和本文 DCNN 的处理结果. 从结果可以直观看出, 对比的 3 种检测方法处理后图像均存在不同程度的背景残差, 而本文 DCNN 方法取得很好的杂波背景抑制效果, 抑制后的图像未见明显背景残差, 仅保留了点目标信息.

下面对各种检测方法的性能进行定量比较, 采用图像局部信杂比 (Local Signal-to-Clutter Ratio, LSCR) 和局部信杂比增益 (Local Signal-to-Clutter Ratio Gain, LSCRG) 两个指标对 4 种检测方法进行对比, LSCR 和 LSCRG 定义如下,

$$LSCR = \frac{I_{\text{target}}}{\sigma_{\text{chutter}}} \quad , \quad (8)$$

$$LSCRG = \frac{LSCR_{\text{out}}}{LSCR_{\text{in}}} \quad , \quad (9)$$

式中, I_{target} 为目标灰度值, σ_{chutter} 表示目标区域杂波背景标准差; $LSCR_{\text{in}}$ 和 $LSCR_{\text{out}}$ 分别为杂波背景抑制

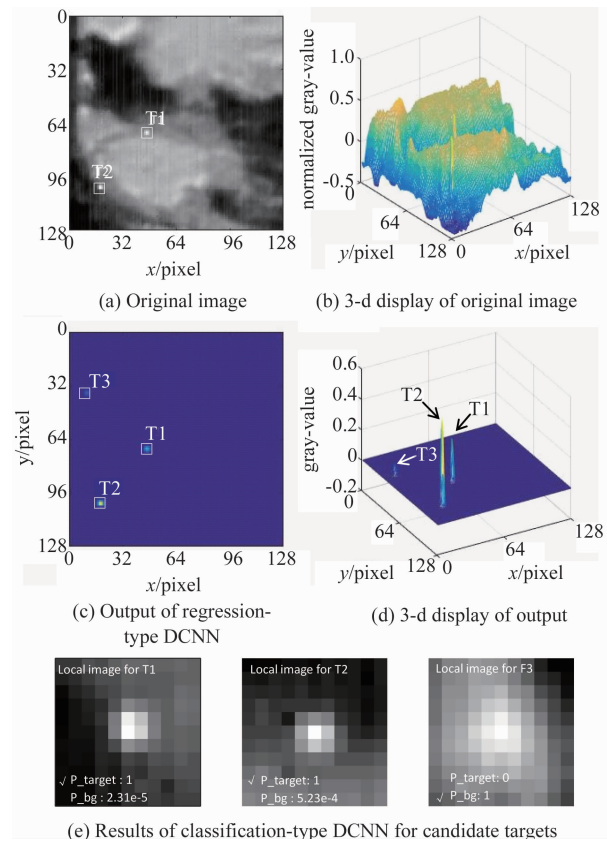


图 6 DCNN 的红外过采样点目标检测结果
Fig. 6 Results of DCNN for infrared over-sampling point target

前后目标区域的 LSCR. 较大的 LSCR 表示目标相对于杂波背景更为显著, 检测效果更好; 较大的 LSCRG 则表明目标检测方法对于 LSCR 提升更为明显, 检测性能更优.

表 1 给出不同检测方法对测试图像进行杂波背景抑制后的和结果比对.

从表 1 可以看出, 在各种检测方法中, 本文 DCNN 得到的 LSCR 和 LSCRG 均为最大且对比明显, 相比其他方法 LSCR 和 LSCRG 提升 1 ~ 2 个数量级.

3.3 ROC 曲线

进一步选择 ROC (Receiver Operating Characteristic) 曲线, 综合对比各种方法检测性能. ROC 是关于检测概率和虚警概率的函数曲线, 在多幅红外过采样扫描图像下进行仿真测试, 通过变化检测门限, 统计检测概率和虚警概率, 实验结果如图 8.

可以看出本文方法检测性能优于其他方法, 在虚警概率为 10^{-4} 和 10^{-5} 时检测概率分别优于 99% 和 96%, 当虚警概率接近 0 时, 本文方法仍能达到 90% 以上的检测概率, 而其他方法检测概率急剧下降, 均低于 60%.

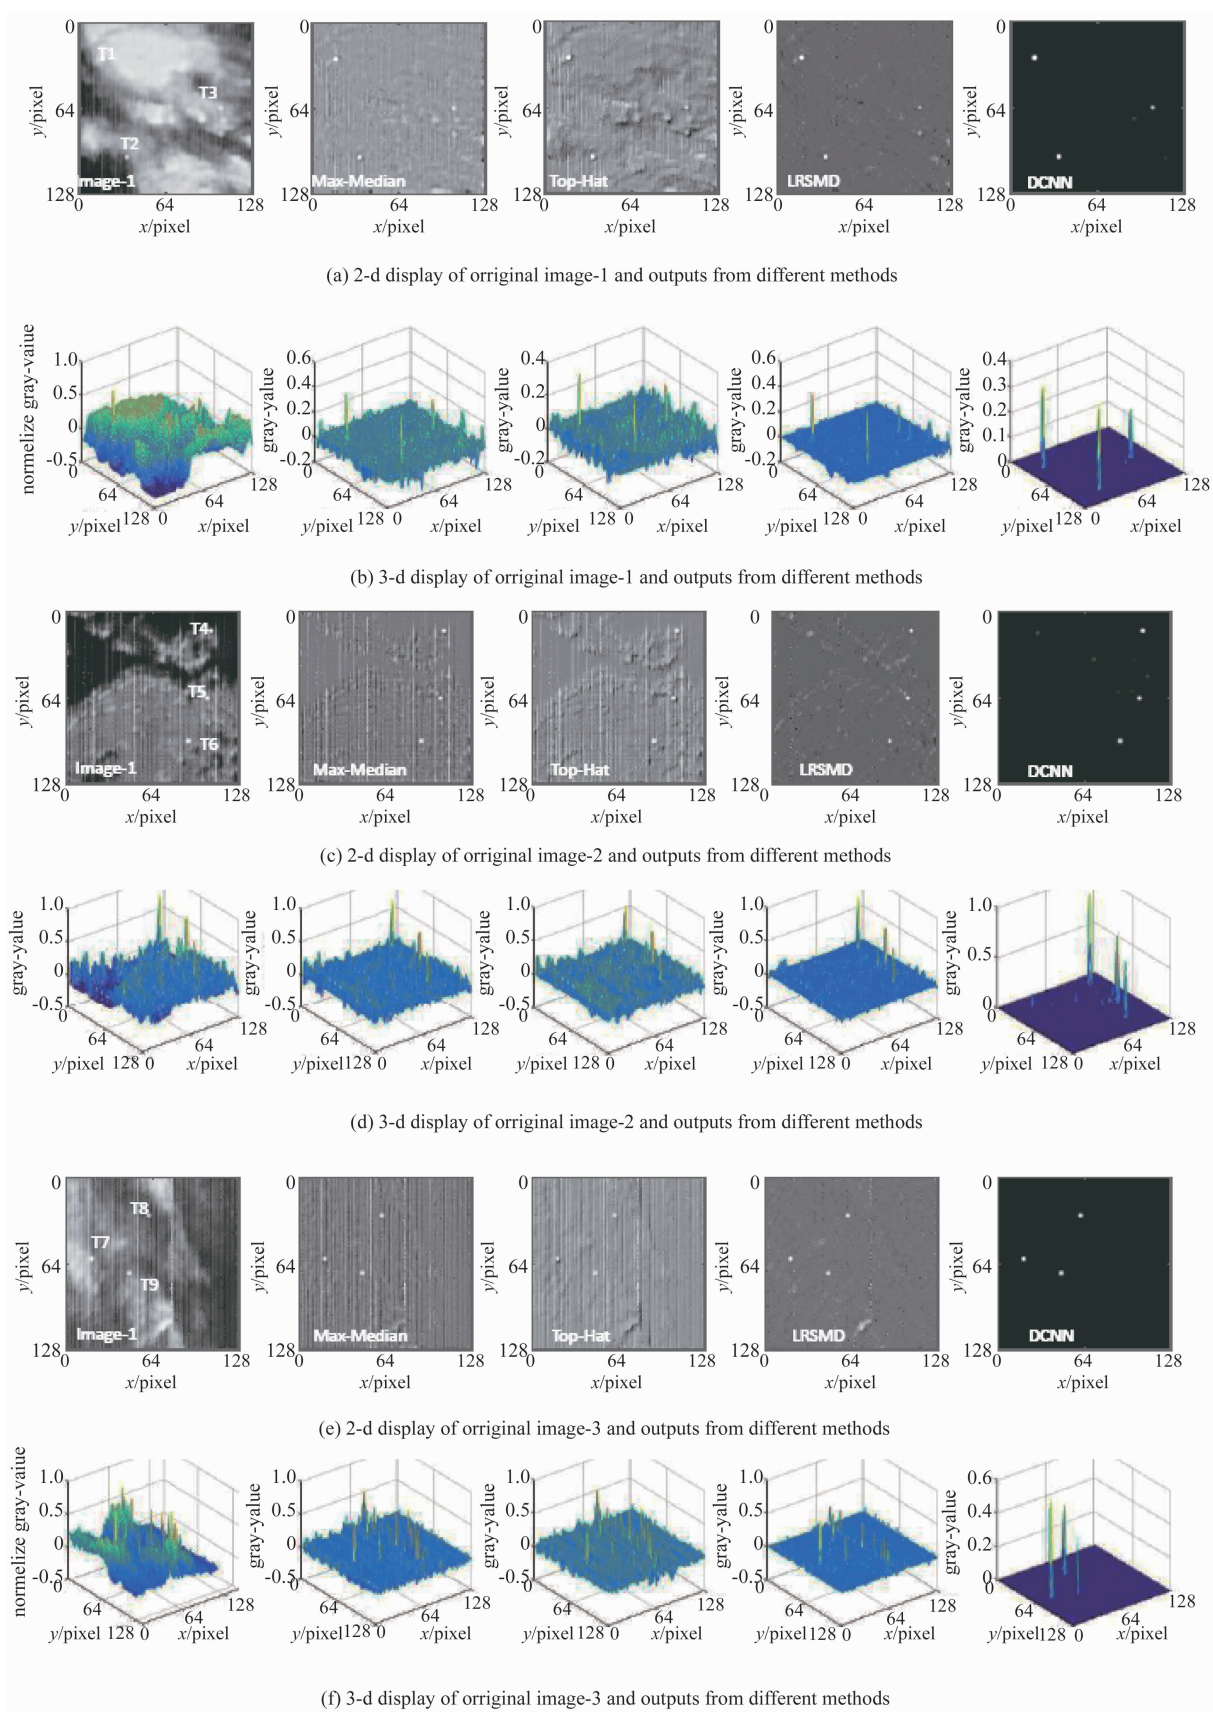


图7 不同检测方法的杂波背景抑制结果

Fig. 7 Results of different methods for infrared over-sampling point target

表 1 杂波背景抑制结果比对

Table 1 Comparison of clutter suppression

Target	LSCR				LSCRG			
	M-Med	Top-Hat	LRSMD	DCNN	M-Med	Top-Hat	LRSMD	DCNN
1	19.35	11.50	36.04	780.87	5.44	3.26	10.12	219.30
2	20.26	13.72	74.39	1976.33	5.60	3.98	20.56	546.19
3	13.87	9.03	47.10	319.54	3.41	2.45	11.56	78.43
4	15.33	12.93	68.21	795.16	1.41	1.43	6.26	73.02
5	9.02	7.87	25.69	123.21	1.22	1.13	3.48	16.70
6	10.56	7.91	47.37	814.10	0.97	0.83	4.37	75.02
7	13.48	8.06	56.41	440.06	2.89	2.04	12.09	94.30
8	7.77	4.86	39.07	1586.44	1.55	0.96	7.79	316.30
9	8.85	5.88	45.25	786.44	1.62	1.09	8.30	144.33

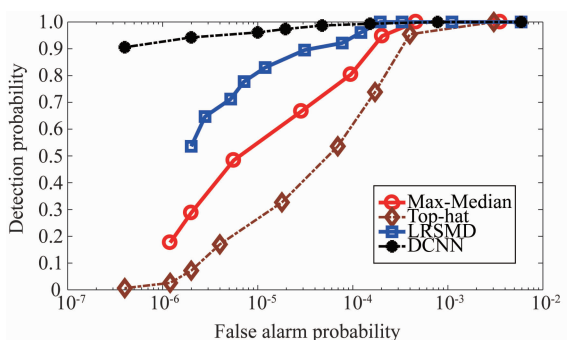


图 8 不同检测方法的 ROC 曲线
Fig. 8 ROC curves of different methods

表 2 不同方法的运算时间对比

Table 2 Comparison of running time for different methods

Index	Max-Median	Top-hat	LRSMD	DCNN
Time/s	0.062 1	0.129 6	0.138 4	0.048 3

可以看出,在相同条件下,本文方法运算时间低于其他检测方法,运算速度最快.

3.5 在常规采样成像图像的测试

依据第 1 节中分析结果,红外过采样扫描图像中点目标呈现规则性像斑状.而在常规红外采样(如凝视成像)图像中,小目标呈现类似的小尺寸形态,为此,将上述训练完毕的 DCNN 直接在红外凝视实拍图像进行测试,结果如图 9 所示.图 9(a)、(b)分别为海空背景和云层背景下的小目标检测场景,从左至右分别为原始图像 2 维和 3 维显示、杂波背景抑制结果的 2 维和 3 维图.

3.4 运算时间

在相同软硬件条件下,对 128 × 128 的扫描图像统计不同检测方法的平均运算时间,如表 2.

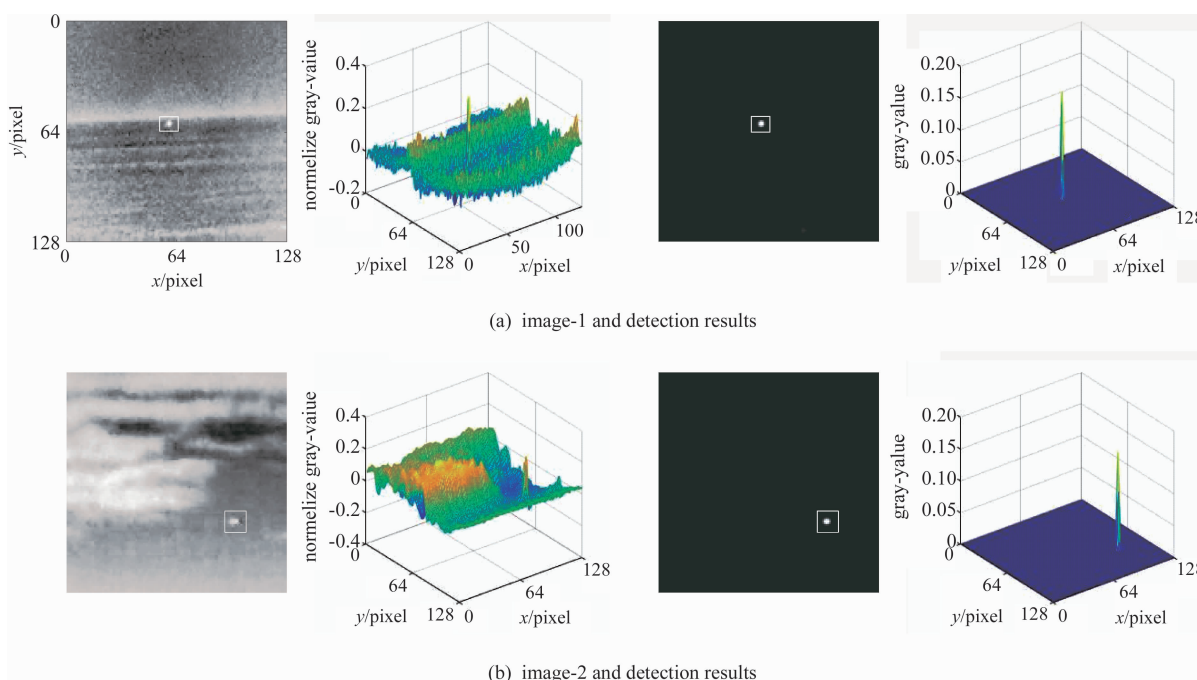


图 9 DCNN 方法对红外凝视图像小目标检测结果
Fig. 9 Results of infrared stare small target detection from DCNN

可以看出,本文 DCNN 方法正确检测出红外小目标,回归型 DCNN 抑制杂波背景后未见明显杂波残差且目标特征凸显,分类型 DCNN 也确认了真实目标,表明本文方法适用于常规采样的红外小目标检测。

4 结论

针对红外扫描过采样成像特点,提出一种基于深度卷积神经网络的红外点目标检测方法. 构建红外小目标深度学习检测框架,设计两个面向红外小目标检测的回归型和分类型 DCNN 网络,生成大量样本数据有效训练 DCNN,首次实现了基于深度学习的红外小目标检测方法. 开展了大量性能测试实验,结果表明,在不同杂波背景下,该方法在目标信杂比增益、检测概率、虚警概率和运算时间等方面,均优于典型红外小目标检测方法,适用于红外过采样扫描系统的点目标检测;并可直接应用于常规成像体制的红外小目标检测. 后续工作将加大 DCNN 的层数,并相应生成更大规模、覆盖更全面的训练数据,以进一步提升 DCNN 的目标检测性能。

References

- [1] Latry C, Rouge B. In-flight commissioning of SPOT5 the quincunx sampling mode[C]. *Proceedings of SPIE*, 2003, **4881**:189-199.
- [2] Larsen M F, Tansock Jr J J., Sorenson G, et al. Impact of the SPIRIT III sensor design on algorithm for background removal, object detection, and point source extraction[J]. *Proceedings of SPIE*, 1996, **2759**:194-204.
- [3] Lomheim T S, Milne E L, Kwok Lt J D, et al. Performance/sizing relationships for a short-wave/mid-wave infrared scanning point-source detection space sensor[C]. *Proceedings of IEEE Aerospace Conference*, 1999:113-138.
- [4] Lawrie D G, Lomheim T S. Advanced electro-optical space-based systems for missile surveillance[R]. *Aerospace Report*, TR-2001(8556)-1,2011.
- [5] WANG Shi-Tao, ZHANG Wei, JIN Li-Hua, et al. Point target detection based on temporal-spatial over-sampling system[J]. *J. Infrared Millim. Waves*(王世涛,张伟,金丽花,等. 基于时-空过采样系统的点目标检测性能分析. *红外与毫米波学报*), 2013, **32**(1):68-72.
- [6] LIN Liang-Kui, WANG Shao-You, WANG Tie-Bing. Simulation and analysis of point target detection performance for infrared scanning over-sampling system[J]. *Acta Optica Sinica*(林两魁,王少游,王铁兵. 红外扫描过采样系统点目标检测性能分析与仿真. *光学学报*), 2016, **36**(5):0528001.
- [7] WANG Tie-Bing, LI Miao, LIN Zai-Ping, et al. Comparative performance analysis of over-sampling scanning[J]. *J. Infrared Millim. Waves*(王铁兵,李淼,林再平,等. 过采样扫描探测性能对比分析. *红外与毫米波学报*), 2015, **34**(1):87-91.
- [8] Tartakovsky A G, Brown J. Adaptive spatial-temporal filtering methods for clutter removal and target tracking[J]. *IEEE Transactions on aerospace and electronic systems*, 2008, **44**(4):1522-1537.
- [9] Gao C Q, Meng D Y, 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] Deshpande. Max-mean and max-median filters for detection of small targets[J]. *Proc. SPIE*, 1999, **3809**:74-83.
- [11] Tom V T, Peli T, Leung M, et al. Morphology-based algorithm for point target detection in infrared backgrounds[J]. *Proc. SPIE*, 1993, **1954**:25-32.
- [12] Gao Y, Liu R M, 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**(2):188-200.
- [13] WANG Da-Bao, LIU Shang-Qian, KOU Xiao-Ming, et al. Infrared background clutter suppression algorithm of adaptive regularization based on MRF[J]. *J. Infrared Millim. Waves*(汪大宝,刘上乾,寇小明,等. 基于 MRF 的自适应正则化红外背景杂波抑制算法. *红外与毫米波学报*), 2009, **28**(6):440-444.
- [14] 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**:214-218.
- [15] Li L, Li H, Li T, et al. Infrared small target detection in compressive domain[J]. *Electronics Letters*, 2014, **50**(7):510-512.
- [16] ZHAO Jia-Jia, TANG Zheng-Yuan, YANG Jie, et al. Infrared small target detection based on image sparse representation[J]. *J. Infrared Millim. Waves*, (赵佳佳,唐峥远,杨杰,等. 基于图像稀疏表示的红外小目标检测算法. *红外与毫米波学报*), 2011, **30**(2):156-166.
- [17] Girshick R, Donahue J, Darrell T, et al. Region-based convolutional networks for accurate object detection and segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, **38**(1):142-158.
- [18] Girshick R. Fast R-CNN[C]. *Computer vision and pattern recognition*, 2015.
- [19] Ren S, He K, Girshick R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, **39**(6):1137-1149.
- [20] Redmon J, Divvala S, Girshick R, et al. You only look once: Unified, real-time object detection[C]. *CVPR*, 2016.
- [21] Goodfellow I, Bengio Y, Courville A. *Deep Learning*[M]. The MIT Press, 2016.
- [22] Vedaldi A, Lenc K, Gupta A. MatConvNet convolutional neural networks[EB/OL]. <http://www.vlfeat.org/matconvnet/matconvnet-manual.pdf>, 2017.