

基于深度学习算法的高分辨率遥感 飞机目标检测方法

李旻园

(西安思源学院 电子信息工程学院, 西安 710038)

摘要: 在高分辨率遥感飞机目标检测过程中, 大气中的散射、地表反射的不均匀性、以及其他非目标物体的辐射等, 都会在遥感影像中形成杂波, 降低检测效果; 为了提高检测精度, 基于深度学习算法对高分辨率遥感飞机的目标检测进行了研究; 采用双边滤波技术去除了图像中的椒盐噪声, 减少遥感影像中的杂波干扰, 保留飞机目标的几何轮廓信息; 引入滑动窗口权值, 根据图像像素间的空间距离和灰度差共同决定权值系数, 从而有效地保护了图像的边缘结构; 使用 split-fuse-select 机制调节感受野的大小, 结合动态选择卷积核与多层级残差连接改善网络性能, 采用自适应分类模块和注意力引导模块精确筛选少量杂波图像中的目标, 依据混合置信度排序实现目标检测; 经实验测试结果表明, 文章方法能够在杂波干扰情况下检测出 11 架飞机, 与实验指标一致, 且在杂波分布泊松分布参数值为 120 的情况下, 最大归一化目标回波值仅为 0.38, 能够精准检测高分辨率遥感飞机。

关键词: 深度学习算法; 高分辨率; 遥感飞机; 目标时序回波; split-fuse-select 机制; 双边滤波器

Target Detection Method for High Resolution Remote Sensing Aircraft Based on Deep Learning Algorithm

LI Yangyuan

(Xi'an Siyuan University School of Electronic Information Engineering, Xi'an 710038, China)

Abstract: There are the clutters of remote sensing images in the process of high-resolution remote sensing aircraft target detection, which are caused by atmospheric scattering, uneven surface reflection, and radiation from other non target objects, thus reducing detection effectiveness. In order to improve detection accuracy, this paper studies a target detection method for high-resolution remote sensing aircraft based on deep learning algorithms, uses the bilateral filtering technology to remove salt and pepper noise from images, reduces clutters in remote sensing images, and preserves the geometric contour information of aircraft targets. By introducing sliding window weights, the weight coefficients based on spatial distance and grayscale difference between image pixels are determined to effectively protect the edge structure of the image. The split fuse select mechanism is used to adjust the size of receptive field, and improve the network performance combined with dynamic selection of convolutional kernels and multi-level residual connections. Adaptive classification modules and attention guidance modules are used to accurately screen targets in a few cluttered images, and achieve object detection based on mixed confidence ranking. Experimental test results show that the proposed method can detect 11 aircraft under clutter interference, which is consistent with experimental indicators. Moreover, with a Poisson distribution parameter value of 120 for clutter distribution, the echo value of maximum normalized target is only 0.38, which can accurately detect high-resolution remote sensing aircraft.

Keywords: deep learning algorithms; high resolution; remote sensing aircraft; target timing echo; split fuse select mechanism; bilateral filter

收稿日期:2025-02-06; 修回日期:2025-03-24。

基金项目:西安思源学院校级重点项目(XASYZD-B2202)。

作者简介:李旻园(1980-),男,博士,副教授。

引用格式:李旻园. 基于深度学习算法的高分辨率遥感飞机目标检测方法[J]. 计算机测量与控制, 2025, 33(7): 123-129, 138.

0 引言

高分辨率遥感飞机目标检测是一项关键的计算机视觉任务,广泛应用于军事侦察、环境监测、城市规划以及灾害管理等领域,并且能够获取地面高分辨率图像,为目标识别和分析提供了丰富的数据源。然而,当前的研究在这一领域仍面临诸多挑战。复杂的背景干扰是亟待解决的问题。遥感图像包含多种自然景观和人造建筑,如陆地、水体、建筑物等,这些丰富的背景信息在很大程度上干扰了飞机目标的凸显^[1]。飞机目标在如此繁杂的背景下,其辨识度和可检测性大幅降低。且飞机目标的尺寸问题也是检测过程中的一大难题。遥感图像中,飞机目标可能以较小的尺寸出现,这些微小的目标极易被复杂背景所掩盖,形成杂波干扰,增加检测难度。此外,飞机目标的尺寸在图像中还表现出较大的变化,这进一步影响了其像素密度和纹理特征的稳定性,为检测工作带来了额外的挑战^[2]。再者,遮挡和阴影现象在遥感图像中同样不可忽视。飞机在飞行或停放过程中,可能会受到云雾或其他物体的遮挡,产生阴影,导致目标的一部分或全部被隐藏。这种情况不仅增加了检测的难度,还可能引起误检或漏检。

针对这些难点,国内外学者进行了深入研究。文献 [3] 提出了基于 DFECANet 的检测方法,该方法设计了可辨识特征提取模块,引入了自适应特征增强模块,利用特征融合上采样模块提升高层语义信息的准确性,检测遥感图像飞机目标。但面对内容复杂多变的遥感图像时,其泛化能力和鲁棒性较差。文献 [4] 提出了基于改进 YOLOv4 的检测方法,该方法通过优化 YOLOv4 的网络结构,引入中空卷积和子空间注意力机制,检测高分辨率遥感图像飞机。但该方法在复杂背景和遮挡情况下,仍存在误检和漏检的问题。文献 [5] 提出了通过增强 U-Net 的编码-解码结构的检测方法,融合多尺度特征,检测高分辨率遥感图像飞机。但该方法在处理极端光照或复杂纹理的遥感图像时,面临特征提取不充分和分割边界不准确的问题。文献 [6] 提出了基于改进 YOLOv7 的检测方法,该方法通过优化网络架构与损失函数,结合更高效的特征融合策略,提升对遥感图像中飞机目标的检测精度与速度。然而,在面临复杂多变的遥感背景时,容易出现目标遮挡或混淆导致的检测不准确。

近年来,以卷积神经网络为代表的深度学习方法在图像识别、物体检测等方面取得了长足的发展。深度学习通过构建深层的神经网络模型,能够自动从原始数据中提取高级抽象特征,进而实现分类、回归等任务,这一特性使得深度学习方法尤其适合处理复杂的遥感图像数据。为此,提出了基于深度学习算法的高分辨率遥感

飞机目标检测方法。该方法结合了局部和全局的特征提取能力,能够在保留局部细节的同时有效捕捉全局上下文信息,由此实现高分辨率遥感飞机目标检测。

1 基于深度学习算法的少杂波干扰图像数据点获取

由于高分辨率遥感飞机目标三维图像获取过程中,遥感数据包含大量杂波干扰,影响目标检测精度,为此,利用深度学习算法中的生成对抗网络,对遥感飞机目标的三维成像数据进行杂波抑制处理,以获得仅含有少量杂波干扰的高分辨率遥感飞机目标三维图像^[7]。高分辨率遥感飞机目标数据具有复杂的空间分辨率和时间间隔特性,且不均匀,因此采用傅里叶变换来分析图像数据的频谱特性。在某一空间分辨率单元内,目标的时序回波信号可以表示为:

$$\beta = [\exp(I2\pi kdt_1), \exp(I2\pi kdt_2), \dots, \exp(I2\pi kdt_n)] \quad (1)$$

式中, I 表示信号幅度和相位信息^[8]; k 表示遥感数据的频率采样间隔; t_1, t_2, \dots, t_n 表示采样时间间隔^[9]。目标与雷达间的相对运动会导致其反射回波信号的频率相对于发射信号产生偏移,该偏移即多普勒频移。通过积累目标的时序回波信号,可以得到目标的多普勒特性,表示为:

$$\alpha(\beta) = \sum_{i=1}^n \exp[I2\pi(\beta_d - \beta_z)dt_n] \quad (2)$$

式中, β_d, β_z 分别表示第 d, z 个多普勒域采样频点的回波信号^[10]。当 $\beta_d = \beta_z$ 时,积累增益达到最大,由此得到输出对应的高分辨率遥感飞机目标一维距离图像。

考虑到椒盐噪声在高分辨率影像中普遍存在,以及高斯滤波、均值滤波等方法在去噪的同时会使目标轮廓模糊的问题,采用双边滤波的方式去除噪声。通过引入滑动窗口权值,可得到双边滤波后的图像数据点,可以表示为如式 (3) 所示:

$$S'[\alpha(\beta)] = \sum_{(x,y) \in \mu} \left[\frac{\omega_r[\alpha(\beta)] \cdot S[\alpha(\beta)]}{\sum_{(x,y) \in \mu} \omega_r[\alpha(\beta)]} \right] \quad (3)$$

式中, $S[\alpha(\beta)]$ 表示经过初步处理但尚未去除椒盐噪声的图像数据点^[11]; $\omega_r[\alpha(\beta)]$ 表示该点在滑动窗口 μ 下的权值,这一权值系数并非随意设定,而是由两部分关键信息共同决定:一部分是图像像素间的空间距离,它反映了像素间的物理邻近性;另一部分是图像像素间的灰度差,它揭示了像素间的亮度或颜色相似性。双边滤波器的权值计算公式,可表示为:

$$\omega_r[\alpha(\beta)] = \omega_r^1[\alpha(\beta)] \cdot \omega_r^2[\alpha(\beta)] \quad (4)$$

$$\omega_r^1[\alpha(\beta)] = \exp\left[-\frac{(\beta_d - \beta_z)^2}{2\sigma^2}\right] \quad (5)$$

$$\omega_r^2[\alpha(\beta)] = \exp\left\{-\frac{|S_d[\alpha(\beta)] - S_{d-1}[\alpha(\beta)]|^2}{2\sigma^2}\right\} \quad (6)$$

上述公式中, σ 表示方差, 即像素间空间距离的权重分布^[12]。方差越大, 表示灰度值差异对权重的影响越小, 即滤波器在考虑权重时会认为更广泛的灰度值范围是相似的。反之, 方差越小, 滤波器对灰度值差异的敏感性越高, 只关注与中心像素灰度值相近的像素; $S_a[\alpha(\beta)]$ 、 $S_{a-1}[\alpha(\beta)]$ 分别表示第 a 和 $a - 1$ 个点。在滤波过程中, 遵循一个核心原则: 离中心像素点空间距离越远的点, 其对中心像素点的影响就越小; 同样地, 像素间灰度差越大的点, 对中心像素点的影响也越小。在边缘附近, 由于像素间的灰度差较大, 因此周边的像素不会对边缘像素产生过大的影响, 从而有效地保护了图像的边缘结构。通过双边滤波处理, 成功地去除了图像中的椒盐噪声, 同时保留了飞机目标的几何轮廓信息。

在双边滤波后, 将处理后的高分辨率目标一维距离像与理想一维距离像同时输入深度学习生成模型。生成模型通过将实际距离像向理想距离像逼近, 生成包含杂波的目标距离像样本, 并传递给判别模型。判别模型分析生成样本与理想样本的差异, 并将结果反馈给生成模型。生成模型根据反馈调整策略, 逐步减少杂波干扰。这一对抗过程持续进行, 直到判别模型无法区分生成的距离像与理想距离像, 表明生成的一维距离像与理想像高度接近, 此时生成模型参数达到最优。将经过深度学习模型处理并优化后的一维距离图像转换为三维空间中目标图像的输入, 得到仅含有少量杂波干扰且边缘清晰的高分辨率遥感飞机目标图像数据点。通过双边滤波和深度学习模型的结合, 不仅去除了图像中的杂波和噪声, 还保留了飞机目标的几何轮廓信息。特别是通过空洞空间卷积/分层的金字塔模型和模块关注机制的引入, 以及对通道注意力机制的应用, 可以在高分辨率遥感飞机目标检测中更有效地捕捉高分辨率遥感图像中的飞机目标特征, 从而提高了目标检测的精度。

2 少杂波干扰图像数据点的高分辨率遥感飞机目标检测

深度卷积神经网络利用卷积层提取特征并转换维度, 再通过池化层压缩特征规模。然而网络深度增加和上采样操作会导致空间层级信息衰减, 影响检测精度。为此, 本研究设计了一种基于深度学习的目标检测框架。

1) 在检测阶段, 首先构建融合空洞卷积与层级金字塔结构的特征采样模型, 采用多膨胀率卷积核提取多尺度上下文特征, 同步扩大感受野。其次对双边滤波处理后的特征点进行跨模态融合, 构建联合特征表征。引入通道注意力增强模块, 通过动态学习特征通道权重实现关键特征强化与噪声抑制; 该架构采用全局平均池化压缩空间维度, 经全连接层降维与 ReLU 非线性变换后, 通过 Sigmoid 函数重构通道相关性权重, 有效提升

模型的特征分辨能力。

通过全局平均池化沿通道维度压缩空间信息, 生成归一化通道权重向量表征特征重要性:

$$D = \frac{1}{hw} \sum_{\omega=1}^h \sum_{\eta=1}^w u(\omega, \eta) \quad (7)$$

式中, h 为高度^[13], w 为宽度, $u(\omega, \eta)$ 为 (ω, η) 通道。

2) 通过可学习参数自适应生成通道注意力权重, 实施特征动态重标定。该机制对特征图实施逐通道乘积运算, 实现关键特征增强与噪声抑制, 其权重计算式如下:

$$\omega = \omega_a \cdot \text{ReLU}[D \cdot S(\alpha, \beta)] \quad (8)$$

式中, ω_a 为通道权重, $S(\alpha, \beta)$ 为参数函数^[14]。

3) 构建全连接特征采样网络, 对高分辨率遥感影像中的去噪飞机目标实施密集特征提取。通过编码层实现特征空间转换, 最终输出多尺度特征张量的级联融合。

4) 针对高分辨率遥感影像在复杂背景与低信噪比环境下的飞机检测特征退化问题, 本研究创新性耦合注意力机制与金字塔架构。通过构建双路协同特征学习网络, 提出 split-fuse-select 动态感知模块: 金字塔支路维持多尺度特征完整性, 注意力支路实施跨维度特征增强, 双流特征经门控选择机制自适应融合, 有效克服传统单路架构的跨尺度响应衰减缺陷。

在深度学习的高分辨率遥感飞机检测中, split 操作将特征张量沿通道均匀分割, 进行不同处理后再组合, 以精细提取特征。Fuse 操作融合不同感受野信息, 通过全局池化和全连接层生成融合特征图。Select 操作自适应选择最具代表性的特征图供后续融合, 生成关键信息图。如图 1 所示。

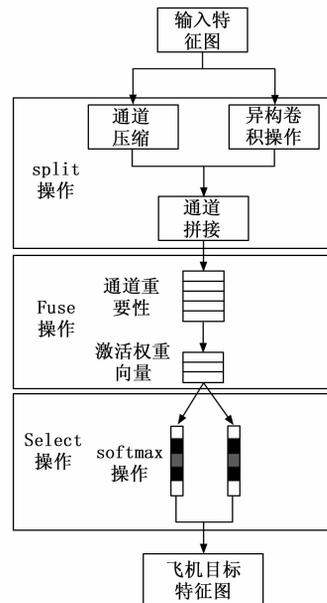


图 1 基于 split-fuse-select 机制的目标信息特征图获取

通过动态卷积核选择机制，自适应调整感受野，优选卷积核以提升特征表示^[15]。并行使用不同空洞率卷积，多尺度捕获上下文信息，增强模型性能。

5) 全连接层输入云编码层特征，生成候选框。结合非极大值抑制和混合置信度，确定最终检测框，如图 2 所示。

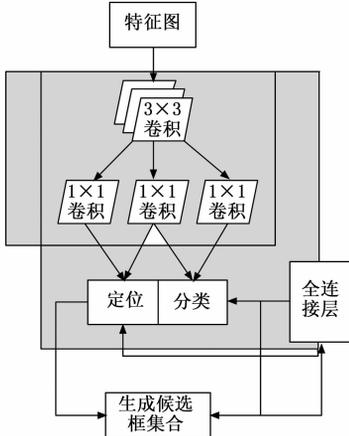


图 2 目标检测框

针对低光照视觉任务中多尺度弱特征提取问题，本文设计了改进卷积神经网络模块。模块内嵌多级残差连接，精确刻画图像特征。并提出新型滤波算法，用小滤波器替换 3×3 卷积核，通过层次残差方法整合滤波结果，确保特征尺度一致性。

在云编码层中引入候选框设计，在保持计算量前提下充分提取多尺度弱特征，增强网络的特征表达与整体性能^[16]。这些学习到的残差特征既支撑特征提取，又可辅助特征融合。为提升检测效率，嵌入自适应分类模块对目标候选锚框进行类别初筛。结合自适应分类模块的类别倾向性信息，可更精准引导区域候选网络完成锚框优选，从而优化整体目标检测性能。

6) 在深度学习过程中，每个通道的激活权重向量 ω 不仅反映了特征的重要性，还直接影响了目标检测的准确性。为了优化飞机目标检测任务，设定了特定检测类别与交并比 (IoU) 阈值^[17-18]。该阈值的设定，结合每个通道的激活权重向量 ω ，设计锚框选择的注意力引导模块，考虑飞机目标尺度和纵横比，计算引导概率，以此能够更精确地筛选和识别飞机目标。引导概率计算公式为：

$$P(\omega, F | G) = P(\omega, G)P(F, \omega | G) \quad (9)$$

式中， G 为输入图像； F 表示纵横比。通过该公式，能够剔除无效候选框和目标检测层选择的低于 IoU 阈值的候选框^[19]。

7) 依据混合置信度对候选框排序，选取置信度最高的框作为目标检测框。计算该检测框与其余候选框的

交并比 (IoU)，若超过阈值则判定为同一目标，剔除低置信度框^[20]。从剩余候选框中选取下一个最高置信度框作为新检测框，并重复 5) 直至处理全部候选框。

8) 依据混合置信度对目标候选框进行排序，选择最高置信度的候选框作为初始目标检测框，在引导概率支持下，构建判断候选框内是否包含飞机目标的判别式：

$$A = \sum_{m=1}^M - (1 - \nu)\lambda\pi(1 - P)\lg P \quad (10)$$

式中， M 表示目标检测个数， $M = 1, 2, \dots, m$ ； ν 表示平衡因子； λ 表示调节因子。当 $A = 0$ 时，说明候选框内无目标，反之则有目标，将所有检测框均用该判别式判别，实现高分辨率遥感飞机的目标检测。

3 实验与分析

3.1 实验数据集

针对当前遥感图像数据集中飞机目标稀缺、影响模型泛化能力的问题，自制专注于单类型飞机目标的遥感图像数据集 AD1。该数据集专注于单一飞机类别，搜集多种来源数据，涵盖众多小目标、复杂背景、密集排列及遮挡情况。构建此数据集首先筛选出仅含飞机目标的图像，并剔除质量不佳的样本。采用滑动窗口技术（重叠率设为 20%）对图像进行拼接，以适应深度学习模型的训练需求，拼接后的图像如图 3 所示。

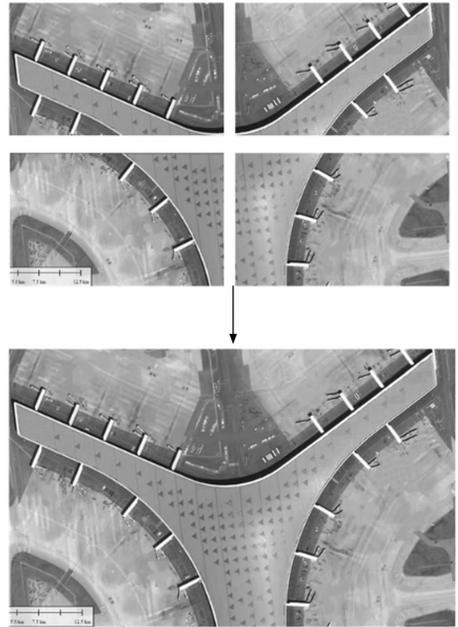


图 3 遥感图像拼接示意图

在飞机目标检测数据集的准备阶段，采用标注工具 labelGo 来执行飞机目标的精确标注工作：

从 GitHub 上获取 labelGo 项目，并按照官方指南配置环境，将图像组织在易于访问的文件夹中。启动 labelGo 应用程序，导入高分辨率遥感图像文件夹。使用已训练的 YOLOv5 PyTorch 模型进行自动标注，快

速生成初步的标注结果。根据需要手动调整边界框的位置和大小，以确保其能准确地包围目标。在确认标注结果准确无误后，保存并导出标注数据。

labelGo 软件提供了用户友好的界面和丰富的标注功能，方便高效地完成大量图像的标注任务。完成标注后，labelGo 软件能够导出标注文件，选择了广泛使用的 VOC 格式作为中间格式。VOC 格式是一种标准化的标注文件格式，它包含了目标的位置信息（边界框坐标）、类别标签以及其他可能的属性信息。这种格式不仅便于存储和传输，还易于被多种目标检测框架和算法所读取和处理。然而，为了满足实验中使用的 POLO 模型训练需求，需要将 VOC 格式的标注文件转换为特定的 txt 格式。这一转换过程涉及将 VOC 文件中的目标位置信息和类别标签提取出来，并按照 POLO 模型所要求的格式重新组织。

此数据集核心源自 Bing Maps，总计包含了 4 179 幅图像。在数据集的分配上，按照 3:1 的比例将其分割为训练验证集合与测试集合（训练集为 3 132 幅，验证集为 1 047 幅），并进一步以 3:1 的比例细分训练验证集。针对目标数据集 AD1，其整体包含 5 123 张图像，其中训练集、验证集及测试集的图像数目依次是 3 200 张、800 张及 1 123 张，总计涵盖 42 178 架飞机实例。

3.2 实验装置及参数设置

实验在搭载 Ubuntu 20.04 操作系统的计算机上执行，其步骤如下所示。

通过使用新虚拟机向导来启动 VMware Workstation 15.x。选择缺省值，单击下一步，确定工作区 15.x 版的使用。安装该操作系统，只需要选择一个 64 位的 ISO 镜像档案。在客户端的 OS 选项里，选择 64 位的 Linux。输入虚拟机的名字，然后将 4 个处理器和 8 G 的内存进行配置。网络设定会选取桥接网络，预设为 LSI 逻辑控制器与 SCSI 总线，使用至少 100 G（推荐最低 20 G）来创建新的虚拟盘，并将虚拟机拆分成多个档案，由此创建一个 Ubuntu 资料夹做为数据储存位置。设计生成对抗网络的网络层数为 5 层，包括输入层、两个隐藏层、一个上采样层和输出层。其中，输入层共有 256 个神经元；隐藏层第一层有 512 个神经元，第二层有 256 个神经元；采用 ReLU 函数作为隐藏层的激活函数，以引入非线性特性，学习率设置为 0.000 2，训练轮数为 200 轮。

双边滤波的主要参数包括卷积核大小（或滤波核直径）、空间域标准差（sigmaSpace）和灰度值域标准差，其中，卷积核大小决定了滤波器的范围。卷积核越大，滤波器覆盖的像素范围越广，平滑效果越明显，但计算量也会增加。在实际应用中，应根据图像特征和所需平滑程度来选择卷积核大小，对于需要平滑较大区域的情

况，选择较大的卷积核。空间域标准差（sigmaSpace）决定了对像素间距离的惩罚程度。sigmaSpace 越小，滤波器对空间距离的敏感性越高，即只有距离较近的像素才会对中心像素产生较大影响。这有助于保留图像的边缘信息。反之，sigmaSpace 越大，更多距离较远的像素会参与到滤波中，导致边缘模糊。灰度值域标准差（sigmaColor）决定了对像素灰度值的惩罚程度。sigmaColor 越大，滤波器对灰度值差异的敏感性越低，即认为更广泛的灰度值范围是相似的，有助于平滑图像中的噪声。反之，sigmaColor 越小，滤波器对灰度值差异的敏感性越高，只关注与中心像素灰度值相近的像素。

配置 CD/DVD 驱动器，选择使用 Ubuntu 20.04 的 ISO 镜像文件进行安装。完成虚拟机配置，点击完成并启动虚拟机进行 Ubuntu 20.04 的安装。

实验参数如表 1 所示。

表 1 实验参数

序号	参数名称	参量
Ubuntu 20.04 操作系统		
1	显存	12 GB
2	CPU	Intel Xeon E5-2630 v3 2.4 Ghz
3	学习环境	Python 3.8
4	框架	PyTorch 1.8
飞机目标检测实验配置		
1	输入图像像素	10 000×10 000 pixel
2	初始学习率	0.05
3	训练轮次	200

在测试集上评估所研究方法的检测效果，根据检测结果进行后续处理和分析，记录实验结果。

鉴于检测环境的复杂性和杂波干扰的普遍性，选择了 EFT T6 型号的三相 6 kV 脉冲群发生器作为杂波检测的核心仪器。EFT T6 是一款专门设计用于模拟环境中快速瞬态脉冲干扰的设备，尤其适用于评估电子系统对杂波信号的抗干扰能力。该装置由三相高压电源、脉冲发生模块、控制单元及输出端口等关键部分组成，其型号中的 6 kV 表明了其能够产生高达 6 千伏的脉冲电压，而三相则意味着它能够模拟实际电力系统中复杂的相位关系。在应用原理上，EFT T6 通过精确控制高压电源产生一系列快速瞬态脉冲，这些脉冲群在时域上紧密排列，以模拟实际环境中可能遇到的杂波干扰情形。选择 EFT T6 型号的三相 6 kV 脉冲群发生器，不仅因为其能够生成高逼真度的杂波信号，还因为其具备高度的可配置性和稳定性，能够根据实际需求调整脉冲参数，从而更精确地评估目标检测系统在复杂环境下的性能表现。

3.3 实验环境及指标

为了对目标检测算法在复杂环境下的性能进行更为

全面且精确的评估，构建了一个杂波实验环境，旨在通过对比分析来深入探究其效能。该实验环境高度模拟了真实场景中的杂波分布特性，确保了实验条件与实际应用场景的紧密贴合。在检测区域内，杂波的分布被严格设定为遵循泊松分布规律，且将泊松分布的参数值设定为 120。这一设定意味着，在平均意义上每个像素点的周围都将分布有大约 120 个杂波点，增加了目标检测的难度，验证算法的鲁棒性能。

实验时间被设定为从早晨 5:00 至下午 13:00，这一时间段的选择旨在全面覆盖不同的光照条件以及可能的飞机起降活动，以便能够全方位地考察算法在不同情境下的表现。在此期间，统计停稳在图 3 所示机场区域内的飞机数量。在实验初步阶段，在没有杂波干扰的理想条件下进行了统计，并将所得结果以图 4 的形式进行展示。

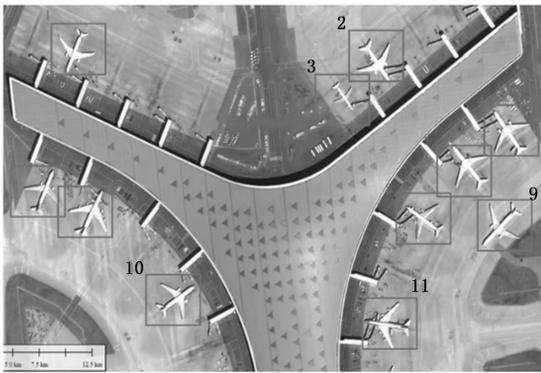


图 4 少杂波干扰影响情况下的实验指标

由图 4 可知，实际检测出的遥感飞机共有 11 架，将此作为实际检测指标为后续对比分析提供了基准线，还帮助初步掌握了机场在特定时间段内的飞机活动规律，为后续的实验分析奠定了坚实的基础。

3.4 实验结果与分析

归一化目标回波值被确立为一个至关重要的评估指标，用以衡量杂波抑制技术的实际成效。这一指标源于对目标回波信号的归一化处理过程，其本质在于通过特定的数学变换，将原始回波信号转换为一个无量纲的相对强度值。这一过程不仅消除了不同测量条件下信号强度的差异，还使得归一化后的回波值在不同实验或观测条件下具有直接的可比性。归一化目标回波值展现出了对杂波干扰变化的高度敏感性，在遥感图像中，杂波以多种形式存在，如自然背景噪声、人为干扰以及多路径效应等，这些杂波成分会对目标信号产生显著的干扰，进而影响目标检测的准确性。而归一化目标回波值能够敏锐地捕捉到这些杂波干扰的变化，其数值的波动直接反映了杂波抑制技术的效果。当杂波得到有效抑制时，归一化目标回波值会呈现出更为稳定且清晰的信号特

征，从而极大地提高了目标检测的可靠性和准确性。为了对比分析增强 U-Net 的编码—解码结构的检测方法和基于深度学习算法的检测效果，对杂波干扰进行抑制，抑制结果如图 5 所示。

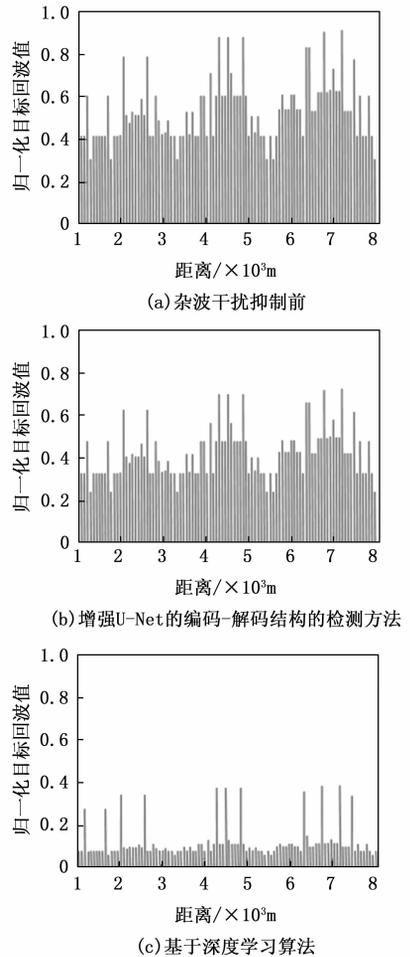


图 5 不同方法杂波干扰抑制结果

由图 5 可知，使用增强 U-Net 的编码—解码结构的检测方法抑制效果明显不如基于深度学习算法，其最大归一化目标回波值均在 0.4 以上，而使用基于深度学习算法最大归一化目标回波值为 0.38，由此可知使用所研究算法能够达到有效杂波干扰抑制效果。

基于杂波干扰抑制结果，将基于 DFECANet 的检测方法、基于改进 YOLOv4 的检测方法、增强 U-Net 的编码—解码结构的检测方法、基于改进 YOLOv7 的检测方法与基于深度学习算法的检测方法的检测结果对比分析，如图 6 所示。

由图 6 可知，使用基于 DFECANet 的检测方法、基于改进 YOLOv4 的检测方法、基于改进 YOLOv7 的检测方法检测的遥感飞机分别有 9 架、8 架、6 架，使用这 3 种方法受到杂波干扰，无法有效检测出飞机数量。使用增强 U-Net 的编码—解码结构的检测方法和基于深度学习算法的检测方法，检测的遥感飞机均有

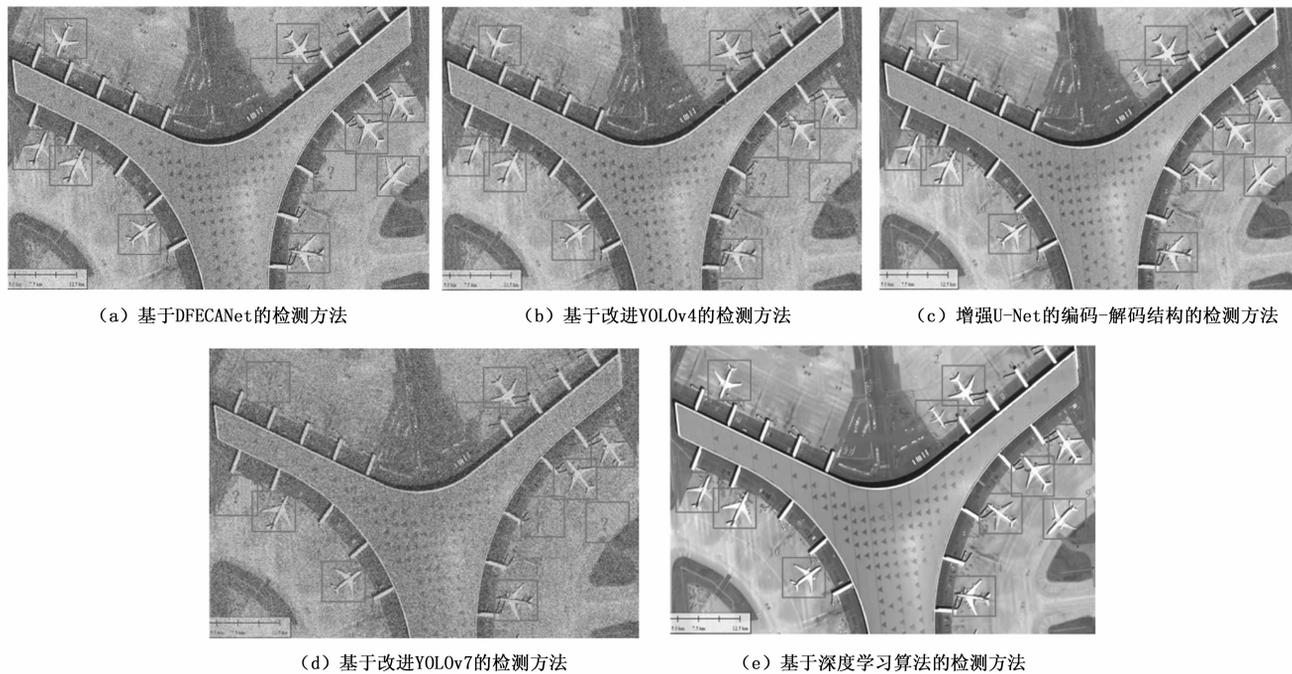


图 6 不同方法检测结果对比分析

11 架，与实验指标一致。这是因为本文方法中 U-Net 网络具有简单的结构，其采用编码器-解码器结构，通过下采样和上采样模块，分别对输入图像特征进行压缩和恢复，从而能够输出与原图相同大小的分割图像。

不同方法的检测准确率分析结果如图 7 所示。

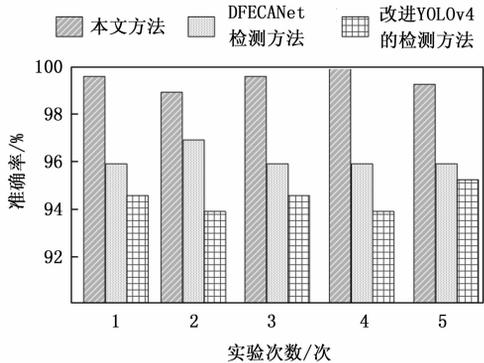


图 7 不同方法的检测准确率分析

由图 7 可以看出，本文方法的高分辨率遥感飞机目标检测准确率始终在 98% 以上，高于两种对比方法。这是因为本文方法在云编码层中设计的候选框，能够在维持计算量的同时充分提取多尺度弱特征，进一步提升了目标检测的准确性。

4 结束语

当前方法在处理高分辨率遥感图像时，面临着特征提取困难、目标检测准确性较低的问题。该问题限制了方法在实际应用中的效果，尤其是在复杂多变的遥感场景中。而所研究的基于深度学习算法的目标检测方法，

结合 split-fuse-select 机制，能够自动地从高分辨率遥感图像中提取出丰富的特征信息，有效解决了当前方法中特征提取困难的问题。同时，深度学习算法强大学习能力使得目标识别的准确性得到了显著提升，即使在杂波干扰情况下也能准确识别出飞机目标。因此，基于深度学习算法的高分辨率遥感飞机目标检测方法不仅克服了当前研究的局限，还在特征提取、目标检测准确性等方面展现出了明显的优势，为高分辨率遥感图像的目标检测提供了新的思路和技术手段，具有重要的理论意义和实际应用价值。

参考文献：

- [1] 董志鹏. 基于卷积神经网络的高分辨率遥感影像目标检测方法研究 [J]. 测绘学报, 2023, 52 (9): 1613-1613.
- [2] 杜艳玲, 徐鑫, 王丽丽, 等. 改进无锚点的彩色遥感图像任意方向飞机目标检测算法 [J]. 液晶与显示, 2023, 38 (3): 409-417.
- [3] 单慧琳, 吕宗奎, 付相为, 等. 基于 DFECANet 的遥感图像飞机目标检测方法 [J]. 电子测量与仪器学报, 2024, 38 (2): 19-29.
- [4] 史瑞鹏, 蒋丹妮, 杨帆, 等. 基于改进 YOLOv4 的大范围遥感影像飞机目标检测 [J]. 计算机仿真, 2023, 40 (10): 49-55.
- [5] SHAFIQUE A, SEYDI S T, CAO G. BCD-Net: building change detection based on fully scale connected U-Net and subpixel convolution [J]. International Journal of Remote Sensing, 2023, 44 (23/24): 7416-7438.

(下转第 138 页)