

一种基于收缩-扩张网络的飞机变化检测方法

粘朋雷,张鹏,周璐

(中国人民解放军91550部队,辽宁大连116023)

摘要:随着遥感技术的快速发展,机场地面监控视频中的飞机变化检测已成为智能安防领域的重要研究方向.机场运营需要实时监测飞机、车辆和人员的地面活动,以保障运行安全和运行效率.然而,机场监控场景具有光照变化显著、气象条件复杂、目标尺度多样、运动速度差异大等特点,给变化检测带来巨大挑战.针对这一问题,基于卷积神经网络提出了一种基于收缩-扩张网络(CENet)的飞机变化检测方法.该方法通过收缩网络提取关键变化特征,利用扩张网络重建恢复特征细节,同时引入挤压激励注意力机制自适应调整特征通道间的关系以提升关键特征表达能力.通过在AGVS数据集上的实验结果表明,提出的方法取得了90.48%的Precision、96.51%的Recall和93.40%的F1-score,验证了其有效性.

关键词:遥感技术;飞机变化检测;收缩-扩张网络

中图分类号:TP751

文献标志码:A

文章编号:2095-4271(2025)05-0533-09

An aircraft change detection method based on contraction-expansion network

NIAN Penglei, ZHANG Peng, ZHOU Lu

(No. 91550 Troops of PLA, Dalian 116023, China)

Abstract: With the rapid development of remote sensing technology, aircraft change detection in airport ground surveillance videos has become an important research direction in the field of intelligent security. Airport operations require real-time monitoring of ground activities involving aircraft, vehicles, and personnel to ensure operational safety and efficiency. However, airport monitoring scenarios present significant challenges for change detection due to notable variations in lighting conditions, complex meteorological factors, diverse target scales, and differences in movement speeds. To address this issue, an aircraft change detection method based on contraction-expansion network (CENet) was proposed. The method extracted key change features and performed spatial compression through the contraction network, while reconstructing features and restoring details using the expansion network. Additionally, a squeeze-and-excitation attention mechanism was incorporated to adaptively adjust the relationships between feature channels, thereby enhancing the expressive capability of key features. Experimental results on the AGVS dataset demonstrated that the proposed method achieved 90.48% Precision, 96.51% Recall, and 93.40% F1-score, verifying its effectiveness.

Keywords: remote sensing technology; aircraft change detection; contraction-expansion network

机场是民航运输体系中重要的组成部分,机场地面变化检测技术的发展对于保障机场运行安全、提升运行效率具有重要意义.如何通过更加高效的变化检测技术来提高机场地面运行效率,已成为研究的热点

之一.虽然变化检测技术在基础研究中得到了广泛应用,但是在机场地面场景下,却存在着精度低、效率慢等问题.因此,需要开展更加深入的研究,提高机场地面变化检测技术的精度和效率.

收稿日期:2025-05-09

作者简介:粘朋雷(1986-),男,工程师,博士,研究方向:电子对抗,图像识别,效能评估.E-mail:nianpl@sina.com

图像的边缘特征对检测的精度起着关键作用.徐俊峰等^[1]提出了一种利用深度学习的方法,通过提取图像的边缘特征识别了飞机的图斑类型达到实验目的,根据实验结果能够准确判断飞机类型和变化检测.王鑫等^[2]提出了一种网络框架(EANet),此框架提取了图像边缘变化的特征,并将通道注意力模块进行融合,提高了检测的准度和精度.张海明等^[3]提出了一种基于领域知识的深度学习方法,通过提取图像的光谱和纹理特征,有效解决了检测精度的问题.傅绘锦^[4]提出了一种新颖的深度学习方法,此算法融合了HRNet和H-BIT的方法,在更复杂的环境有更高的精确率.张艺明等^[5]针对机场跑道提出了一种面向对象的方法,通过获取跑道变化信息检测出变化区域和变化属性,精准迅速地检测出飞机类别.Yuanxin Ye^[6]等提出了一种新颖的具有三维卷积的邻近级特征融合网络(称为AF3D-Net),可以同时提取和融合双时相图像的特征信息,并且引入了密集跳跃连接策略,以提高逐像素预测的能力和结果中变化对象的紧凑性.Maximilian Bernhard^[7]等利用地球表面特征的语义信息来改进双时相图像的变化检测,提出了一种名为MapFormer的新型架构,可以根据可用的语义信息进行特征处理.Xiaowen Ma^[8]等提出了一种基于空间和时间特征融合的RSCD网络,利用跨时序门控机制结合双时相特征,利用跨尺度注意机制捕捉细粒度信息,恢复变化表示的空间细节.Gong Chen^[9]等提出了Stockwell散射网络(Stockwell Scattering Network, SSN),提供了抗噪声的特征表示,并在SAR图像变化检测中取得了先进的性能,同时具有高计算效率.

综上所述,虽然已有许多飞机变化检测算法被提出,但是由于机场环境的复杂性和变化性,这些算法在机场地面的实际应用中仍然存在一些问题和不足.因此,本文提出了一种基于收缩-扩张网络(Contraction-Expansion Network,简称CENet)的飞机变化检测方法,旨在提高机场地面变化检测的准确性和实用性.通过收缩-扩张网络的使用,将网络结构分为收缩块和扩展块,可以提取出图片中更高的特征信息;通过使用挤压激励注意力机制(Squeeze and Excitation Attention, SEAttention),对卷积层输出的不同通道分配不同的权重,使得神经网络能够专注于最相关的特

征,在较为复杂的天气条件下,对飞机变化检测效果更好,增强了方法的鲁棒性,同时抑制信息量较少的特征,在一定程度上简化了模型的结构,提高了方法的泛化性.

1 方法

1.1 收缩-扩张网络

为了更好地实现图像中前景与背景的分割,基于堆叠收缩和扩展块的思想提出了一种基于收缩-扩张网络的飞机变化检测方法(CENet),整体结构如图1所示.相比于FCN、UNet等算法,该架构在训练阶段使用了大量数据集对不同的场景和任务进行了训练,因此具有更好的鲁棒性和准确性.

收缩-扩张模块主要由收缩块和扩展块两部分组成.收缩块通过 7×7 的卷积层、批归一化层、ReLU激活函数和 2×2 的最大池化层逐步减小特征图的大小,提取图像的低级特征,同时通过挤压激励注意力机制,增强特征的表达能力;扩展块通过 2×2 的最大反池化、批归一化层、ReLU激活函数和 7×7 卷积核处理以及挤压激励注意力机制,逐步将特征图的大小还原到原始图像的大小,并提取更加高级的特征信息.同时,采用批归一化、ReLU激活函数、注意力机制模块技术优化网络的特征表示能力,提高网络的泛化能力.具体流程如下:

首先,图片输入到收缩-扩张模块中,该模型通过卷积核对输入图像进行特征提取,然后,对卷积层输出进行批归一化,同时采用标准的ReLU激活函数对卷积层输出进行非线性变换,以增强网络的表达能力.此外,收缩块通过 2×2 的最大池化层进行下采样,将每个空间维度减少2,同时提取图像的重要特征后通过挤压激励注意力机制,增强特征的表达能力.在收缩块处理完成后,将处理后的特征图输入进扩展块中,在扩展块中,首先通过反池化层将收缩块输出的特征图还原回原始图像的大小,恢复特征图的空间分辨率.接下来,将还原后的特征图送入卷积层提取更高级的特征,加强特征的抽象能力.随后,对卷积层的输出进行归一化处理,使得特征的分布更加稳定,有利于网络的训练和收敛.同时,引入激活函数ReLU以及挤压激励注意力机制增加网络的表达能力.最后,

收缩-扩张模块采用注意力机制模块来进一步优化网络的特征表示能力.通过上述操作的结合,收缩-扩张

模块能够有效地提取输入图像的特征,并进行高级特征抽象,从而达到更好的图像变化检测效果.

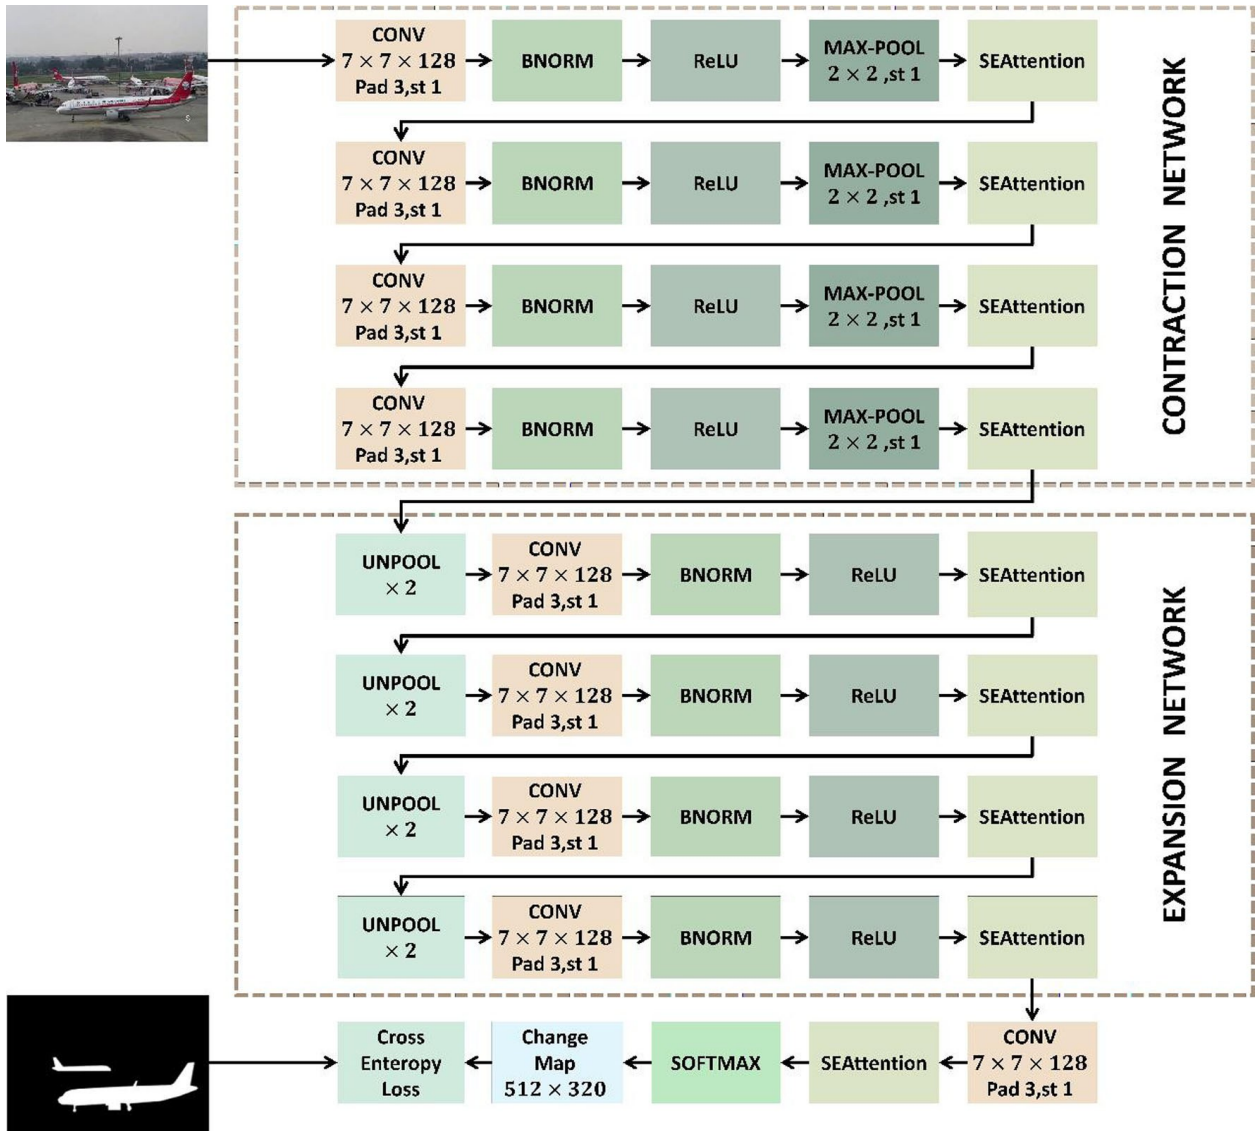


图 1 CENet 整体结构

Fig. 1 CENet overall structure

1.2 挤压激励注意力机制

挤压激励注意力机制是深度学习模型中用于增强卷积神经网络表征能力的模块(如图 2 所示).该模块旨在捕获由卷积神经网络生成的特征图中的通道依赖性,根据不同通道的重要性为它们分配不同的权重.这使得网络能够专注于最相关的特征,同时抑制信息量较少的特征.

挤压激励注意力机制第一步是对输入的特征图进行自适应平均池化.具体来说,特征图被馈送到自适应平均池化层,将其空间尺寸减少到(1,1),同时保

留通道信息.该操作计算了每个通道的空间平均值,从而得到通道权重.

在自适应平均池化之后,通道权重通过一个称为“特征缩放器”的全连接神经网络传递.这个缩放器的目的是对每个通道的权重进行学习,捕捉每个通道的重要性.特征缩放器由两个线性层和两个激活函数组成.第一线性层降低了输入表示的维度,然后经过 ReLU 激活函数,第二线性层将其扩展回原始通道维度.最后,应用 Sigmoid 激活函数以确保重新校准的权重落在[0,1]的范围内.

将从特征缩放器获得的权重向量与原始输入特征图逐元素相乘,从而得到加权后的特征表示.该操作可以有效地为重要通道分配更高的权重,同时抑制

信息量较少的通道.通过这种差异化的权重分配,神经网络能够专注于最具判别力的特征,从而提高其检测性能.




图 2 挤压激励注意力机制

Fig. 2 Squeeze-and-excitation attention mechanism

1.3 损失函数

本文采用了 FOCAL 和 DICE 的混合损失函数来提高模型的性能.FOCAL 损失函数是一种用于解决类别不平衡问题的损失函数.公式如下:

$$L_{FOCAL} = FL(p_t) = -\alpha_t(1-p_t)^\gamma \log(p_t). \quad (1)$$

其中, p_t 是模型的预测概率, α_t 是每个类别的权重, γ 是一种可以调整的参数.

FOCAL 损失函数通过调整交叉熵损失函数中的权重,使得模型更加关注难以分类的样本,而且也可以通过实验调整 FOCAL 损失函数的参数值从而使模型更加适合不同的任务和数据集.但是,FOCAL 损失函数的效果受数据集中类别不平衡程度的影响较大,如果数据集中类别不平衡程度较轻,则 FOCAL 损失函数的效果可能会降低.

DICE (Sørensen-Dice) 损失函数是一种常用的用于图像分割任务的损失函数,它衡量了模型的预测结果与真实标签的相似程度,其公式如下:

$$L_{DICE} = 1 - \frac{2 \sum_{i=1}^N y_i \hat{y}_i}{\sum_{i=1}^N y_i + \sum_{i=1}^N \hat{y}_i}. \quad (2)$$

其中, y_i 与 \hat{y}_i 分别表示像素 i 的标签值与预测值, N 为像素点总个数.

DICE 损失函数对噪声有一定的鲁棒性,能够减少噪声对分割结果的影响损失,其范围为 $[0, 1]$, 直观易懂,也能够直接反映模型的性能.可是对于边界像素的处理会存在问题,因为 DICE 损失函数仅仅关注像素级别的相似度,而没有考虑区域的连通性.所以,文本采用了 FOCAL 和 DICE 的混合损失函数以提高模型的性能,采用混合损失函数最大的优点是 DICE

损失函数可以弥补 FOCAL 损失函数类别不平衡问题,并且,通过调整权重参数可以使得模型更加关注某些类型的错误,从而提高模型在特定任务和数据集上的表现,帮助模型更快地收敛并降低过拟合的风险,公式如下:

$$L = \lambda L_{FOCAL} + L_{DICE}. \quad (3)$$

2 分析与讨论

AGVS 是一种用于机场地面变化检测的机场地面视频监控数据集.每个视频均包含针对机场地面变化的多类挑战性场景,例如,雾霾,伪装,条形,阴影和照明变化.该数据集为开发面向应用的算法和评估基础研究算法在实际应用中的性能提供了宝贵的资源.

2.1 对比方法

为了更好地比较本文方法的性能,进行了如下对比实验,包括 UNet、PSPNet、EfficientFCN、FCN32、FastFCN、LUNet 共 6 种方法.以下是六种对比方法介绍:

UNet 方法^[10]是通过扩展和修改全卷积来获得网络.网络由两部分组成:获取上下文的收缩路径信息以及用于精确定位位置的对称扩展路径.

PSPNet 方法^[11]的核心功能是金字塔池,它聚集不同区域的上下文信息,以改善对全局信息的访问.

EfficientFCN 方法^[12]采用未使用扩张卷积的 ImageNet 预训练网络作为系统的主干,利用编码器中的多尺度特征获得高分辨率、语义丰富的特征图.为了将解码任务转换为新的码本生成和码字汇编任务,编码器使用其高级和低级函数.

FCN32 方法^[13]是基于 VGG16 神经网络进行改

进,先移除 3 个全连接层,再添加 3 个卷积层作为输出层.为了防止过拟合,在前两个卷积层之后分别添加 dropout 层,最后用转置卷积层将结果放大 32 倍,以恢复输出图像的原始大小.

FastFCN 方法^[14]为了提高语义分割,采用一种新的联合上采样模块 JPU,将高分辨率特征图的提取转化为联合上采样问题.

LUNet 方法^[15]将全卷积 LSTM 模块集成在 UNet 类深度架构的每个编码层之上,计算不同分辨率的特征向量的时间关系,而不需要下采样或压平.

2.2 评价指标介绍

本文使用了四个评估指标,包括 Precision、Recall、F1-score、IOU.其中,Precision 是算法检测到的变化区域中,实际变化区域所占的比例;Recall 是实际变化区域中被正确检测出的数量与数据集中实际变化区域总数的比例;F1-score 是 Precision 和 Recall 的加权调和平均数,用于综合评估分类器的性能;IOU 为计算真实值和预测值两个集合的交集和并集之比.这些指标的评估结果可以综合评估算法的性能.指标表达式如下公式所示:


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

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

$$F1-score = \frac{2 \times Precision \times Recall}{(Precision+Recall)} . \quad (6)$$

$$IOU = \frac{TP}{(TP+FP+FN)} . \quad (7)$$


2.3 视觉对比结果



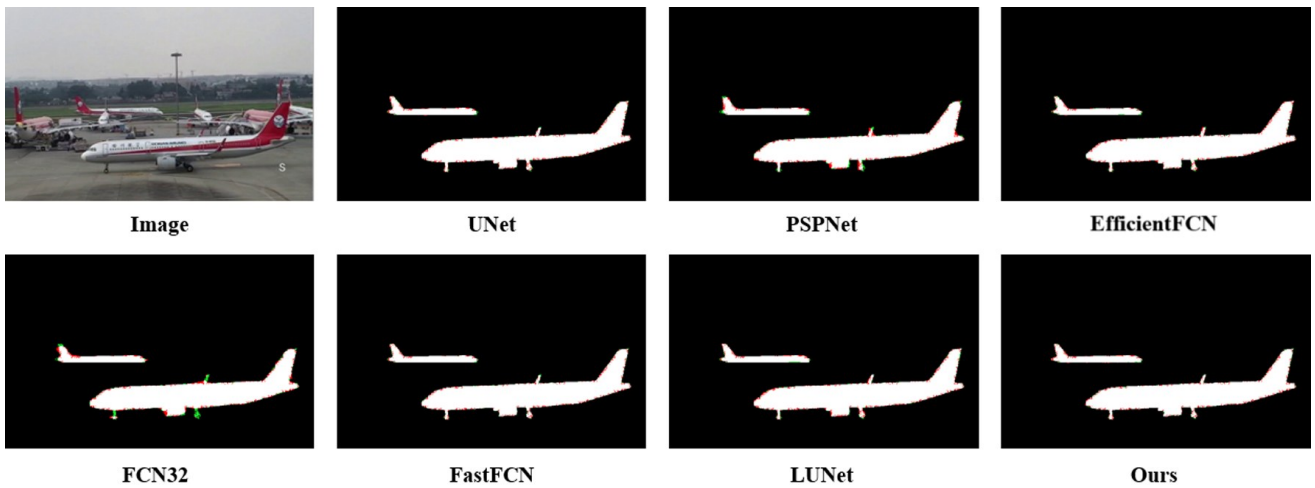
(a) 飞机数量少且天气晴朗时可视化结果

在 AGVS 数据集中不同模型的可视化结果如图 3 所示.FastFCN 方法虽然可以获取上下文的收缩路径信息以及用于精确定位位置的对称扩展路径,但是对于全局信息的提取依旧不完整,将一些没有出现变化的区域检测成了变化的区域,导致了误检.EfficientFCN 方法,虽然利用编码器中的多尺度特征获得高分辨率、语义丰富的特征图,但是通过图中对比可以看出,该方法对于雾霾或是雷电天气时的飞机变化检测有一定的漏洞,有较为明显的误检现象,对此本文中的方法通过使用交叉式自注意力模块在增强了鲁棒性的同时,还通过多层级特征融合模块将不同张量的特征图片集成到一起,增强了算法的泛化性,对影像中光谱亮度系数变化大的区域依旧有不错的识别效果.第三组实验对近处飞机变化检测时,六种对比方法都出现了漏检,而 PSPNet 和 FCN32 尤其的突出.这些方法都不能很好地描绘出近处的飞机变化区域.而本文所提出的方法较为完整的描绘出了近处的飞机变化的轮廓,较好地完成了飞机的变化检测.


综上所述,本文所提出的方法对有效特征的提取比较全面,性能较为高效,能够较为准确地识别飞机的变化.对于一些辨别系数高的变化也有不错的检测能力,检测结果比较完整.同时在雾霾、伪装、同时多尺度检测、阴影和光照变化不均匀、形状和颜色变化、条形、PTZ 相机等多种不利条件下也取得了不错的效果,再一次验证了本文中的方法在实际应用中有着较高的鲁棒性和不错的泛化性.




(b) 飞机数量较多且距离远时可视化结果




(c) 飞机主体占比大时可视化结果



(d) 下雨时可视化结果



(e) 雾霾时可视化结果



(f) 雾霾,飞机数量大时可视化结果

图 3 AGVS 数据集中不同模型的可视化结果

Fig. 3 Visualization results of different models in the AGVS dataset

2.4 定量分析结果

为了验证本文方法的有效性和稳定性,在 AGVS 数据集上进行了定量分析比较,结果如表 1 所示,评价指标曲线如图 4 所示.通过将网络分割成收缩和扩展两个模块,神经网络可以提取更高的特征向量,使得本文的方法在 Precision 和 Recall 中都有更好的表现,F1-score 指标的表现也有较为明显的提升.由此可

见,本文方法在飞机遥感变化检测的方法中使用收缩和扩张模块对于提升飞机遥感变化检测的鲁棒性有着一定的指导意义.除此之外,通过使用挤压激励注意力机制,对卷积层输出的不同的通道分配不同的权重,使得神经网络能够专注于最相关的特征,在 IOU 指标上相较于现有方法也有一定的提升.

表 1 不同方法在 AGVS 数据集的结果比较

Table 1 Comparison of the results of different methods on the AGVS dataset

单位:%

方法	Precision	Recall	F1-score	IOU
UNet	90.11	96.05	92.99	93.40
PSPNet	80.57	88.34	84.28	86.31
EfficientFCN	87.22	93.30	90.16	90.98
FCN32	84.06	89.60	86.74	88.21
FastFCN	89.81	95.65	92.64	93.10
LUNet	89.95	95.76	92.77	93.21
Ours	90.48	96.51	93.40	93.77

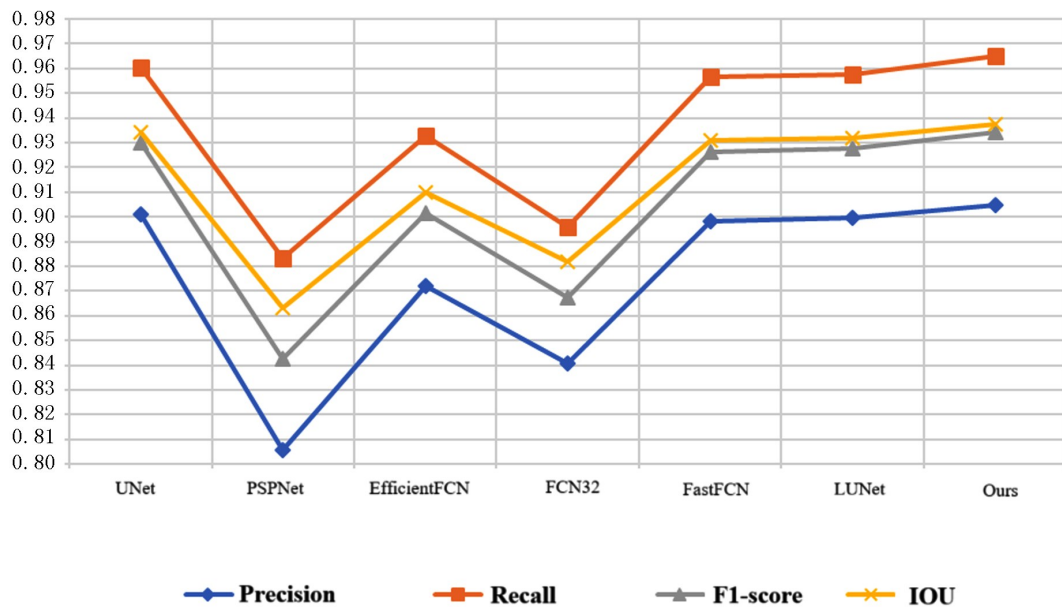


图 4 评价指标曲线图

Fig. 4 Evaluation Index Curve

3 结论

综上所述,基于收缩-扩张网络的飞机变化检测方法,采用了堆叠多个收缩块和扩展块来提取图像的特征信息,收缩块逐步减小特征图的大小,提取低级特征,同时使用挤压激励注意力机制增强特征表达能力,扩展块逐步将特征图的大小还原到原始图像的大小,并提取更高级的特征信息,同时优化网络的特征表示能力.该架构在训练阶段使用大量数据集进行训练,在 Precision 和 Recall 指标上分别达到了 90.48% 和 96.51%, F1-score 指标达到 93.40%, 具有较好的鲁棒性和准确性.在应对更加复杂的环境时,本文方

法模型表现出不稳定的趋势,后续将针对该方法模型进行优化,为更深层次的研究提供参考.

参考文献

- [1] 徐俊峰,张保明,余东行,等.多特征融合的高分辨率遥感影像飞机目标变化检测[J].遥感学报,2020,24(1):37-52.
- [2] 王鑫,张香梁,吕国芳.基于融合边缘变化信息全卷积神经网络的遥感图像变化检测[J].电子与信息学报,2022,44(5):1694-1703.
- [3] 张海明,王明常,陈学业,等.领域知识优化深度置信网络的遥感变化检测[J].武汉大学学报(信息科学版),2022,47(5):762-768+788.
- [4] 傅绘锦.一种新的基于深度学习的遥感影像变化检测算法——H-BIT 方法的提出与应用[J].地理空间信息,2023,21(1):53-57.

- [5] 张艺明,肖文.一种面向对象的机场跑道变化检测方法[J].航天返回与遥感,2019,40(1):102-111.
- [6] YE Y X, WANG M M, ZHOU L, et al. Adjacent-level feature cross-fusion with 3-D CNN for remote sensing image change detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61:1-14.
- [7] BERNHARD M, STRAUB N, SCHUBERT M. MapFormer: Boosting change detection by using pre-change information[C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV). Paris, France: IEEE, 2023:16791-16800.
- [8] MA X W, YANG J W, HONG T F, et al. STNet: Spatial and Temporal feature fusion network for change detection in remote sensing images[C]//2023 IEEE International Conference on Multimedia and Expo (ICME). Brisbane, Australia: IEEE, 2023:2195-2200.
- [9] CHEN G, ZHAO Y N, WANG Y, et al. SSN: Stockwell scattering network for SAR image change detection[J]. IEEE Geoscience and Remote Sensing Letters, 2023, 20:1-5.
- [10] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[C]//Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015. Cham: Springer International Publishing, 2015:234-241.
- [11] ZHAO H S, SHI J P, QI X J, et al. Pyramid scene parsing network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI: IEEE, 2017:6230-6239.
- [12] LIU J B, HE J J, ZHANG J W, et al. EfficientFCN: Holistically-guided decoding for semantic segmentation[C]//Computer Vision – ECCV 2020. Cham: Springer International Publishing, 2020:1-17.
- [13] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston: IEEE, 2015:3431-3440.
- [14] WU H K, ZHANG J G, HUANG K Q, et al. FastFCN: Rethinking dilated convolution in the backbone for semantic segmentation[EB/OL]. [2023-03-28]. <https://doi.org/10.48550/arXiv.1903.11816>.
- [15] PAPADOMANOLAKI M, VAKALOPOULOU M, KARANTZALOS K. A deep multitask learning framework coupling semantic segmentation and fully convolutional LSTM networks for urban change detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(9):7651-7668.

(责任编辑:张阳,殷锋,付强,和力新,肖丽;英文编辑:周序林,郑玉才)