

基于改进 VGG16 – UNet 的山区遥感影像地形阴影检测模型

王 学¹ 赵森佳¹ 王 涛²

(1. 河北工程大学数理科学与工程学院, 邯郸 056038; 2. 国家卫星气象中心业务管理处, 北京 100081)

摘要: 山区地形阴影在遥感卫星影像中普遍存在形态不规则与边界复杂性, 导致传统检测方法难以实现精准分割。为解决这一难题, 本文提出一种融合可变形卷积与坐标注意力机制的增强型 VGG16 – UNet 语义分割模型, 以提升阴影区域的识别与定位能力。模型以 VGG16 作为编码器主干网络, 通过引入可变形卷积动态调整采样位置, 有效捕捉阴影的不规则邻域特征; 同时嵌入坐标注意力模块, 强化空间位置信息与通道特征的协同表达, 优化细节恢复与结构一致性。利用自建数据集和国产高分七号卫星遥感影像开展验证实验, 结果表明: 本文方法平均交并比、平均召回率与总体精度分别达到 94.77%、97.28% 与 97.52%, 相较于 VGG16 – UNet 基准模型分别提高 0.62、0.41、0.30 个百分点。在多种山区场景下测试进一步证实了本文方法具备稳定且可靠的阴影检测能力, 具有良好的泛化性能与鲁棒性, 为高精度地形阴影自动提取提供了可靠技术路径。

关键词: 遥感影像; 地形阴影; 阴影检测; 语义分割; 可变形卷积; 坐标注意力机制

中图分类号: TP79

文献标识码: A

文章编号: 1000-1298(2026)10-0173-08

OSID:



Topographic Shadow Detection Model in Mountainous Remote Sensing Images Based on Improved VGG16 – UNet

WANG Xue¹ ZHAO Senjia¹ WANG Tao²

(1. School of Mathematics and Physics, Hebei University of Engineering, Handan 056038, China

2. Operations Management Office, National Satellite Meteorological Center, Beijing 100081, China)

Abstract: Mountainous terrain shadows in remote sensing satellite imagery typically exhibit irregular morphologies and complex boundaries, which pose significant challenges to accurate segmentation using conventional methods. To address this issue, an improved VGG16 – UNet semantic segmentation model that integrated deformable convolution and a coordinate attention mechanism was proposed, aiming to improve the recognition and localization of shadow regions. The model employed VGG16 as the backbone encoder, where deformable convolution was introduced to dynamically adjust sampling locations, thereby effectively capturing features within irregular shadow neighborhoods. Simultaneously, a coordinate attention mechanism was embedded to enhance the synergistic representation of spatial positional information and channel-wise features, optimizing detail recovery and structural consistency. Validation experiments conducted on a self-built dataset and domestic GaoFen – 7 satellite imagery showed that the proposed method achieved mean intersection over union (mIoU), mean recall (mRecall), and overall accuracy (OA) scores of 94.77%, 97.28%, and 97.52%, respectively. These results represented improvements of 0.62 percentage points, 0.41 percentage points, and 0.30 percentage points over the baseline VGG16 – UNet model. Furthermore, tests across diverse mountainous scenarios confirmed that the method possessed stable and reliable shadow detection capabilities, along with strong generalization performance and robustness. This work can provide a reliable technical pathway for the automated extraction of high-precision terrain shadows.

Key words: remote sensing images; terrain shadow; shadow detection; semantic segmentation; deformable convolution; coordinate attention mechanism

收稿日期: 2025 – 11 – 14 修回日期: 2025 – 12 – 23

基金项目: 国家自然科学基金项目(42401461)

作者简介: 王学(1976—), 男, 副教授, 博士, 主要从事计算机视觉与图像处理研究, E-mail: xue.wang@hebeu.edu.cn

通信作者: 王涛(1991—), 男, 高级工程师, 博士, 主要从事基于卫星影像的定量遥感和目标识别解译等研究, E-mail: taowang@cma.gov.cn

0 引言

遥感卫星影像在资源调查、环境监测及国土规划等领域具有重要应用价值。然而,在山区复杂地形条件下,受太阳高度角、方位角及局部地形起伏共同影响,影像中普遍存在地形阴影^[1]。阴影严重制约了遥感影像在山区环境的深入应用^[2-3],并且高精度的阴影检测是后续阴影去除与影像复原前提^[4]。然而地形阴影与深色地物等低反射率地物的光谱响应高度相似^[5]且形态不规则、边界模糊,导致传统依赖固定特征提取算子的检测方法难以实现有效区分,导致细节丢失、误检率高^[6]。因此,开发能够适应复杂地形条件的自动化阴影检测方法,已成为提升山区遥感解译精度的重要研究。

目前主流阴影检测方法可归纳为三大类:基于物理模型的方法、基于阴影特征的方法以及基于深度学习的方法。基于物理模型的方法通过集成传感器参数、太阳方位角与数字高程模型构建光线追踪模型^[7-8],能够模拟阴影分布,但此类方法对输入数据精度极为敏感,在实际应用中存在显著局限性。基于阴影特征的方法通常分析影像中阴影区域和非阴影区域间的光谱、纹理、上下文信息、几何形状以及其他特征差异来提取阴影^[9-10],却常因忽略像素点间的空间关联,难以准确区分真实阴影区和黑色地物^[11],实际效果不尽理想。近年来,深度学习方法凭借复杂的网络结构学习影像中的阴影特征识别阴影区域^[12],取得了比传统方法更优的结果^[13-17]。然而,现有深度学习模型在应对山区地形阴影时仍存在明显不足:传统卷积神经网络的固定感受野难以适应阴影区域的不规则几何形态,且在特征提取过程对空间位置信息与通道特征的关联不够充分,导致阴影边界定位精度有限,特别是对碎片化分布的小尺度阴影存在误检和漏检现象^[18]。计算机视觉领域涌现的可变形卷积、坐标注意力机制,为解决该问题提供了有效技术。具体而言,可变形卷积通过学习偏移量突破固定采样约束^[19],提升对几何变形的建模能力,已成功应用于图像分割领域^[20]。坐标注意力机制通过方向分离编码强化空间位置感知,成功应用于遥感图像变化检测等领域^[21]。此外 VGG16-UNet 结合 VGG16 特征提取能力和 U-Net^[22] 分割架构为语义分割提供可靠框架^[23],但模型存在空间细节丢失,对阴影形态适配不足等局限。

基于以上研究,本文设计一种融合可变形卷积与坐标注意力机制的增强型 VGG16-UNet 语义分割模型。模型以 VGG16 网络^[24]为编码器主干,通过引入可变形卷积^[25]实现对不规则阴影邻域的自

适应特征提取;同时嵌入坐标注意力机制^[26],加强空间坐标与通道特征的关联,提升阴影边界的精确定位能力。采用自主构建的多场景山区阴影数据集进行模型训练与验证,并利用高分七号卫星影像评估算法的实际应用性能,系统分析改进模型在阴影细节保持、边界精度与抗干扰能力方面的优势,以期对山区复杂地形条件下遥感影像阴影检测提供新的技术解决方案。

1 数据集与预处理

使用数据包括自建数据集和国产高分七号卫星产品影像,其中自建数据集影像来源于 Maxar 公司提供的 WorldView 系列高分分辨率商业卫星,通过 Google Earth 平台获取,覆盖四川、甘肃等我国中西部地区近 6 年影像,涵盖不同时间、多种场景和不同视角高度的影像,背景包括土地、植被、岩石等多种地物,影像空间分辨率为 1.24~1.85 m。在数据预处理阶段,使用图像注释工具 Labelme 对阴影进行人工标注,生成二值阴影掩膜。为增强模型对阴影方向与形态变化的鲁棒性,对每组影像及其掩膜分别旋转 90°、180°、270°。自建数据集共包含 3 344 组尺寸为 256 像素×256 像素的阴影影像及其掩膜。为保障模型训练有效性与评估可靠性,将自建数据集按比例 7:3 随机划分为训练集和测试集,以保证训练集与测试集在阴影形态、背景类型等类别分布上的均衡性,其中测试集也作为模型训练的验证集,用于监控模型收敛情况与防止过拟合。图 1 为自建数据集的部分卫星影像及阴影掩膜。与此同时,选取以(39.0°N,74.1°E)为中心、近 4 年拍摄的多场景高分七号卫星影像开展测试,验证所提模型对国产高分分辨率卫星影像的泛化能力与实用性。




图 1 数据集部分影像

Fig.1 Sample images from dataset

2 研究方法

2.1 技术路线

技术路线如图 2 所示。首先,以覆盖山区的原

始卫星影像作为输入数据,然后对影像进行数据预处理,包括影像裁剪、阴影标注和数据增强。预处理后,将数据划分为用于学习的训练集和用于评估验证的测试集。经处理后的数据集被输入模型中进行多层训练。最后,将测试影像输入训练好的模型进行推理,得到精确的山区地形阴影二值化检测结果。




图 2 技术路线
Fig. 2 Technical methodology

2.2 模型架构

针对山区地形阴影区域形态多样、大小不一的特点,并且模型内的固定卷积核难以准确捕捉不同形态阴影的局部特征,在 VGG16 + UNet 模型编码器中引入可变形卷积模块 (Deformable convolutional moudle, DConv),使卷积核在采样时能通过学习到的 1 组偏置对初始采样点位置进行变换,从而使卷积核能根据阴影特征自适应地调整感受野形状。该设计使得模型能更好地捕捉阴影区域的不规则边界和局部细节特征,有效提升对复杂山区地形阴影的检测能力。

为增强模型对阴影空间分布信息的感知能力,在 VGG16 编码器的每个下采样层嵌入坐标注意力机制 (Coordinate attention, CA)。CA 机制首先对输入阴影特征图分别沿水平和垂直方向进行池化,生成具有方向性的特征表示;随后,这些特征经由全连接层和 Sigmoid 激活函数^[27]处理,转化为注意力权重;最终将生成的权重与原始特征图融合,使模型能精准聚焦于影像中关键区域^[28]。与压缩和激励网络模块 (Squeeze and excitation, SE)^[29]以及卷积注意力机制 (Convolutional block attention module, CBAM)^[30]相比,CA 机制在保留通道特征重要性的同时,还能精确捕捉由地形起伏导致的山区阴影所呈现的碎片化、不规则分布特性,其整体性能更契合复杂山区地形阴影检测的实际需求。

综合上述改进策略,构建增强型 VGG16 + UNet 语义分割模型。在基准模型 VGG16 编码器路径中,将部分标准卷积层替换为可变形卷积层,同时,在每个最大池化层后嵌入坐标注意力模块,改进 VGG16 编码器结构如图 3 所示。解码器保持原有结构,通过跳跃连接接收来自编码器的多尺度优化特征,实现精准的边界定位与细节恢复。图 4 为改进模型架构,模型通过学习自适应采样偏移量,使卷积感受野

灵活匹配山区地形阴影不规则的目标形态,解决传统固定卷积核对非标准形状特征提取不足的问题,有效强化目标区域特征响应并抑制背景干扰,使 VGG16 + UNet 模型在保持效率的同时,显著提升山区地形阴影的检测精度与鲁棒性。




图 3 改进 VGG16 模块结构
Fig. 3 Architecture of improved VGG16 module

2.3 精度评价指标

山区地形阴影检测可被定义为二值分割问题,即分离影像中的阴影像素与非阴影像素,因此,采用平均交并比 (mIoU)、平均召回率 (mRecall)、总体精度 (OA) 作为模型性能量化评价指标。基于混淆矩阵计算 mIoU、mRecall 和 OA。

3 实验结果与分析

实验在 PyTorch 2.10 框架和 Python 3.8 编程语言进行,将模型部署在计算机上,配置:处理器为 AMD Ryzen 9 3900X 12 - Core Processor 3.80 GHz,内存为 2.73 TB,显卡为 NVIDIA GeForce RTX 2080 Ti。融合可变形卷积和坐标注意力机制的 VGG16 + UNet 模型采用 Adam 优化器,初始学习率为 1×10^{-4} ,每次训练使用小批量 (batch size 为 4),优化器内部使用的 momentum 参数为 0.9,学习率下降方式为 cos。模型对训练集 (2 340 组影像) 进行 150 次迭代训练,在模型训练完成后,对 1 004 幅山区遥感影




图 4 改进 VGG16 - UNet 模型架构

Fig. 4 Architecture of improved VGG16 - UNet model

像测试集进行评估实验,并与传统方法(基于 CIELCh 颜色空间和超像素分割结合的阴影检测方法^[31]、基于 YCBCr 颜色空间的阴影检测方法^[32],及 PSPNet^[33]、Deeplabv3 +^[34]、VGG16 - UNet 深度学习语义分割模型)进行对比分析,以验证本文模型对山区复杂地形的阴影检测能力与鲁棒性。

3.1 算法性能综合评估

综合定量指标与定性分析结果,系统性地评估本文方法在山区地形阴影检测任务中的性能。表 1 为本文方法与 5 种方法评价结果。图 5 为本文方法与 5 种方法在自建数据集阴影检测效果,其中选取 3 种不同场景的遥感影像,分别为以裸露岩石作为背景(Ⅰ)、土地与少量植被作为背景(Ⅱ)、大量植被作为背景(Ⅲ)。

表 1 阴影检测评价结果

Tab.1 Evaluation of shadow detection results %			
方法	平均交并比	平均召回率	总体精度
CIELCh	48.97	70.52	58.67
YCBCr	52.37	84.91	75.95
PSPNet	91.60	95.52	95.95
Deeplabv3 +	92.86	96.30	96.57
VGG16 - UNet	94.15	96.87	97.22
本文方法	94.77	97.28	97.52

由表 1 可知,本文方法在所有评价指标上均领先于其他方法。具体而言,在 mIoU 指标上,本文方法相较基准 VGG16 - UNet 模型提升 0.62 个百分点,在视觉上直观表现为对细小阴影更为完整的捕捉能力。从图 5 场景Ⅰ检测结果可看出,传统方法无法捕捉全部阴影细节,其中 CIELCh 方法存在严重的漏检缺陷。PSPNet、Deeplabv3 +、VGG16 -

UNet 模型虽能识别大面积阴影,但对边缘细碎细节处理仍有不足。相比之下,本文方法借助可变形卷积的适应性感受野,实现了与不规则阴影边界的高度贴合。在 mRecall、OA 指标上,本文方法相较基准 VGG16 - UNet 模型分别提升 0.41、0.30 个百分点,在视觉上直观表现为模型能更好地区分真实阴影与干扰地物,对土地、植被等深色地物误检率降低。从图 5 场景Ⅱ检测结果可看出,传统方法识别阴影能力弱,其中 YCBCr 方法将部分深色土地与植被误检为阴影,CIELCh 方法、PSPNet、Deeplabv3 + 和 VGG16 - UNet 模型无法有效区分阴影与非阴影地物。而本文方法借助坐标注意力机制通过强化空间位置感知,精准区分阴影与深色土地、少量植被,有效降低了真实阴影与干扰地物的误检和漏检风险,同时维持了阴影区域的形态连续性。从图 5 场景Ⅲ检测结果可看出,CIELCh 方法无法完整捕捉阴影形态,YCBCr 方法将部分植被误检为阴影,无法有效区分阴影与非阴影地物。PSPNet、Deeplabv3 +、VGG16 - UNet 能识别阴影主体,但存在阴影区域漏检问题。而本文方法通过可变形卷积灵活适配阴影的不规则形态,并且通过坐标注意力机制强化阴影空间位置感知,边缘与真实掩膜的曲折细节高度匹配,在植被抗干扰上与其他方法相比优势显著。

3.2 多种场景性能分析

为进一步验证本文方法在遥感卫星影像山区地形阴影检测性能,选取国产高分七号卫星遥感影像的 3 种不同时间且不同场景影像,将本文方法与上述 5 种方法进行阴影检测,检测结果如图 6 所示。从图 6 可看出,CIELCh 方法整体对细碎阴影和复杂




图 5 自建数据集阴影检测效果

Fig. 5 Shadow detection results for self-built dataset

边界的捕捉能力不足,3 组场景均存在较多阴影区域漏检和误检问题。YCBCr 方法过度依赖颜色特征,3 组场景均存在将深色地物误检为阴影的缺陷。PSPNet 模型能识别阴影主体,但边缘细节丢失严重且存在漏检雪山极小阴影和将深色地物误检为阴影的缺陷。Deeplabv3 +、VGG16 - UNet 模型在 3 组场景中均存在不同程度漏检和误检、边缘细节丢失问题,对复杂阴影形态适配性有限。本文方法通过可变形卷积与坐标注意力的协同作用,在 3 组图像中均可以更好地捕捉多种场景中的细碎阴影,并且可以有效区分阴影与地物,边缘与阴影影像曲折细节高度匹配。

与此同时,选取 1 幅高分七号卫星大范围遥感影像验证本文方法的检测性能,该遥感影像拍摄时间为 2023 年 11 月 22 日,影像中心坐标为




图 6 高分七号卫星影像阴影检测效果

Fig. 6 Shadow detection results for GF - 7 imagery

(39. 007 681°N, 74. 033 621°E), 影像覆盖范围约为 19 892. 2 m × 26 530. 0 m, 空间分辨率为 2. 6 m。图 7 为本文方法阴影检测结果,同时借助像素差值图方便验证本文方法检测效果,其中像素差值图中黑色区域代表检测结果与阴影掩膜差异。

从图 7 可直观看,针对阴影区域呈现大小不一、形态不规则的复杂分布特点,本文方法成功捕捉了从大块连续阴影到零散细碎阴影的各种尺度特征,阴影区域内部连续性和完整性保持良好,其边缘轮廓与真实阴影的曲折细节几乎完全重合,显示出模型对不同大小、不同对比度阴影的识别能力。通过像素差值图(图 7d)的细节验证可进一步发现:检测结果能紧密贴合阴影的真实边界,无连续黑色误检区域。这一结果说明,即使在大范围山区场景下,本文方法依然能够对阴影局部细节保持较高还原度,且可以有效区分阴影与深色低反射率地物,充分




图 7 高分七号卫星大范围影像阴影检测效果
Fig.7 GF-7 satellite large-scale image shadow
detection results

体现了本文方法在复杂山区地形阴影检测任务中的鲁棒性与高精度。

综上所述,提出的融合可变形卷积与坐标注意力机制的增强型 VGG16-UNet 语义分割模型,在高分七号遥感卫星影像的山区地形阴影检测中,不仅在小范围测试中能够精准捕捉阴影细节,有效抑制误检与漏检,在处理大范围、地形起伏剧烈的山区遥感影像时,同样具备稳定且可靠的阴影检测能力,为高精度山区阴影检测提供了新的技术路径。

3.3 消融实验

为分析可变形卷积与坐标注意力机制在模型中贡献,设计了消融实验。

表 2 为 VGG16-UNet 基准模型、引入可变形卷积的 VGG16-UNet + DConv 模型、引入坐标注意力机制的 VGG16-UNet + CA 模型以及本文方法评价指标。图 8 为 4 种模型阴影检测结果,并借助像素差值图突出各模型方法在视觉层面的阴影检测性能。从表 2 和图 8 中可得,单独引入可变形卷




图 8 消融实验检测结果对比

Fig.8 Comparison of model ablation experiment results

积的 VGG16-UNet + DConv 模型,mIoU、mRecall 和 OA 较基准模型分别提升 0.32、0.26、0.15 个百分点。从视觉角度表现为,较基准模型在山脊线等阴影形态突变处像素差值图的黑色不匹配条纹变淡,有效增强了模型对不规则阴影边界形态的拟合能力,证实了可变形卷积通过其自适应感受野特性,在提升边缘细节和边界贴合度方面的有效性。单独引入坐标注意力机制的 VGG16-UNet + CA 模型,mIoU、mRecall 和 OA 较基准模型分别提升 0.59、0.41、0.28 个百分点。从视觉角度表现为,较基准模型在阴影区域内部的黑色误检点明显减少,阴影检测结果的内部连续性更好,凸显了坐标注意力机制通过在通道维度嵌入精确的位置信息,强化了模型对阴影空间上下文关系的感知能力。本文方法 mIoU 和 OA 达到最优,mRecall 与 VGG16-UNet + CA 持平。从视觉角度表现为,检测结果与真实掩膜差异最小,阴影区域边界清晰且内部连续,成功捕捉了绝大部分阴影细节,同时有效避免较多误检区域。这表明,可变形卷积提供的局部几何变形感知与坐标注意力机制提供的全局上下文空间感知形成了有效互补。前者确保模型能紧密贴合阴影复杂的轮廓,后者则确保模型在复杂地形背景下能做出更准确的语义判断,两者协同工作,共同攻克了山区地形阴影检测中边界不规则与上下文干扰强的双重难题。

综上所述,在改进 VGG16-UNet 模型中可变形卷积模块与坐标注意力机制均是提升复杂山地阴影检测性能的关键设计,分别侧重于解决阴影局部几何适应和全局上下文理解问题。当两者协同集成于本文方法时,产生了显著的性能增益,最终使模型能

表 2 消融实验评价指标

方法	平均交并比	平均召回率	总体精度
VGG16-UNet	94.15	96.87	97.22
VGG16-UNet + DConv	94.47	97.13	97.37
VGG16-UNet + CA	94.74	97.28	97.50
本文方法	94.77	97.28	97.52

够更加精确地完成对遥感卫星影像中山区复杂地形的阴影检测任务。

3.4 算法优势与局限性

通过对 VGG16 - UNet 模型引入可变形卷积模块与坐标注意力机制,在遥感卫星影像复杂山区场景的地形阴影检测中展现出显著优势。可变形卷积通过自适应调整采样位置,有效克服了固定卷积核在不规则形状捕捉阴影特征的局限;坐标注意力通过双向特征编码,强化了模型对空间关系的感知能力。二者结合使模型在保持高精度的同时,兼具良好的细节保持能力。然而,研究也发现模型在特定条件下,在阴影与深色物体共存区域,本文方法仍存在少量误检,未来研究需引入更多上下文语义信息,融合高程等多源信息更好地解决阴影与深色地物的混淆问题,并基于本文方法的阴影检测结果,进一步开展山区地形阴影去除研究。

4 结论

(1)整合了自建的 3 344 组 WorldView 高分辨率阴影数据集与国产高分七号卫星影像,通过人工标注与数据增强,为复杂山区地形阴影检测模型的训练与验证提供了数据基础。

(2)构建了融合可变形卷积模块与坐标注意力机制的 VGG16 - UNet 语义分割模型。其中,可变形卷积模块增强了模型对不规则阴影边界的几何适应性,坐标注意力机制强化了模型对阴影空间上下文关系的感知能力。

(3)在多场景山区阴影数据集上,本文方法平均交并比、平均召回率与总体精度分别达到 94.77%、97.28% 与 97.52%,较基准模型分别提高 0.62、0.41、0.30 个百分点,具备稳定可靠的阴影检测能力,同时具有良好的泛化性能与鲁棒性。

参 考 文 献

- [1] 刘健,许章华,余坤勇,等.山地丘陵区遥感影像阴影检测与去除方法[J].农业机械学报,2013,44(10):238-241,237. LIU Jian, XU Zhanghua, YU Kunyong, et al. Shadow detection and removal method for remote sensing images in mountainous and hilly area[J]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(10): 238-241,237. (in Chinese)
- [2] LUO H, WANG L, SHAO Z, et al. Development of a multi-scale object-based shadow detection method for high spatial resolution image[J]. Remote Sensing Letters, 2015, 6(1): 59-68.
- [3] ZHANG W, ZHAO X, MORVAN J M, et al. Improving shadow suppression for illumination robust face recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 41(3): 611-624.
- [4] XU H, ZHU J, WANG F, et al. A shadow detection method combining topography and spectra for remote sensing images in mountainous environments[J]. Applied Sciences, 2025, 15(9): 4899.
- [5] HAN H, HAN C, LAN T, et al. Automatic shadow detection for multispectral satellite remote sensing images in invariant color spaces[J]. Applied Sciences, 2020, 10(18): 6467.
- [6] ZHOU T, FU H, SUN C, et al. Shadow detection and compensation from remote sensing images under complex urban conditions[J]. Remote Sensing, 2021, 13(4): 699.
- [7] LUO S, SHEN H, LI H, et al. Shadow removal based on separated illumination correction for urban aerial remote sensing images[J]. Signal Processing, 2019, 165: 197-208.
- [8] LI Z, SHEN H, LI H, et al. Multi-feature combined cloud and cloud shadow detection in GaoFen-1 wide field of view imagery[J]. Remote Sensing of Environment, 2017, 191: 342-358.
- [9] SILVA G F, CARNEIRO G B, DOTH R, et al. Near real-time shadow detection and removal in aerial motion imagery application[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2018, 140: 104-121.
- [10] BESHEER M, ABDELHAFIZ A. Modified invariant colour model for shadow detection[J]. International Journal of Remote Sensing, 2015, 36(24): 6214-6223.
- [11] HE Z, ZHANG Z, GUO M, et al. Adaptive unsupervised-shadow-detection approach for remote-sensing image based on multichannel features[J]. Remote Sensing, 2022, 14(12): 2756.
- [12] LUO S, LI H, ZHU R, et al. ESPFNet: an edge-aware spatial pyramid fusion network for salient shadow detection in aerial remote sensing images[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021, 14: 4633-4646.
- [13] MORALES G, HUAMAN S G, TELLES J. Shadow removal in high-resolution satellite images using conditional generative adversarial networks[C]//Annual International Symposium on Information Management and Big Data, 2018: 328-340.
- [14] DONG G, HUANG W, SMITH W A P, et al. A shadow constrained conditional generative adversarial net for SRTM data restoration[J]. Remote Sensing of Environment, 2020, 237: 111602.
- [15] DING B, LONG C, ZHANG L, et al. Argan: attentive recurrent generative adversarial network for shadow detection and removal[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 10213-10222.
- [16] CHEN H, FENG D, CAO S, et al. Slice-to-slice context transfer and uncertain region calibration network for shadow detection

- in remote sensing imagery[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2023, 203: 166 – 182.
- [17] LIU D, ZHANG J, WU Y, et al. A shadow detection algorithm based on multiscale spatial attention mechanism for aerial remote sensing images[J]. IEEE Geoscience and Remote Sensing Letters, 2021, 19: 1 – 5.
- [18] KANG X, HUANG Y, LI S, et al. Extended random walker for shadow detection in very high resolution remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 56(2): 867 – 876.
- [19] ZHU X, HU H, LIN S, et al. Deformable convnets v2: more deformable, better results[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 9308 – 9316.
- [20] 夏天,谢纯,李琳一,等. 基于改进 YOLO v8 的复杂温室环境黄瓜果实分割方法[J]. 农业机械学报,2025,56(5):433 – 442.
- XIA Tian, XIE Chun, LI Linyi, et al. Improved YOLO v8 method for cucumber fruit segmentation in complex greenhouse environments[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(5): 433 – 442. (in Chinese)
- [21] HUANG Y, LI X, DU Z, et al. Spatiotemporal enhancement and interlevel fusion network for remote sensing images change detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 1 – 14.
- [22] RONNEBERGER O, FISCHER P, BROX T. U – net: convolutional networks for biomedical image segmentation[C]//International Conference on Medical Image Computing and Computer-assisted Intervention, 2015: 234 – 241.
- [23] CHOUDHARY R R, PALIWAL S, MEENA G. Image forgery detection system using VGG16 UNET model[J]. Procedia Computer Science, 2024, 235: 735 – 744.
- [24] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv Preprint arXiv: 1409.1556, 2014.
- [25] DAI J, QI H, XIONG Y, et al. Deformable convolutional networks[C]//Proceedings of the IEEE International Conference on Computer Vision, 2017: 764 – 773.
- [26] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13713 – 13722.
- [27] 火元莲,张乔森,张金石,等. 一种用 Sigmoid 函数进行加权融合的图像去雾算法[J]. 计算机工程与科学,2023,45(9): 1621 – 1628.
- HUO Yuanlian, ZHANG Qiaosen, ZHANG Jinshi, et al. An image dehazing algorithm using weighted fusion for Sigmoid function[J]. Computer Engineering and Science, 2023, 45(9): 1621 – 1628. (in Chinese)
- [28] 成嘉伟,郭荣佐,吴建成,等. 双分支特征融合的遥感建筑物检测模型[J]. 计算机工程与应用,2024,60(22):145 – 153.
- CHENG Jiawei, GUO Rongzuo, WU Jiancheng, et al. Dual-branch feature fusion remote sensing building detection model[J]. Computer Engineering and Applications, 2024, 60(22): 145 – 153. (in Chinese)
- [29] 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.
- [30] WOO S, PARK J, LEE J Y, et al. Cbam: convolutional block attention module[C]//Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3 – 19.
- [31] WANG Z, ZHOU Y, WANG F, et al. Shadow detection and reconstruction of high-resolution remote sensing images in mountainous and hilly environments[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2023, 17: 1233 – 1243.
- [32] DEB K, SUNY A H. Shadow detection and removal based on YCbCr color space[J]. SmartCR, 2014, 4(1): 23 – 33.
- [33] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2881 – 2890.
- [34] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]//Proceedings of the European Conference on Computer Vision (ECCV), 2018: 801 – 818.