

深度学习光伏电站识别及对植被空间聚集度的影响研究

乔佳佳^{1,2,3}, 闫敏^{2,3}, 刘永强^{1,4}, 张丽^{2,3}, 吴音⁵, 陈一仰^{2,3}, 邵伟^{2,3}

1. 新疆大学 地理与遥感科学学院, 乌鲁木齐 830046;

2. 可持续发展大数据国际研究中心, 北京 100094;

3. 中国科学院空天信息创新研究院数字地球重点实验室, 北京 100094;

4. 新疆绿洲生态重点实验室, 乌鲁木齐 830046;

5. 新疆维吾尔自治区自然资源规划研究院(新疆维吾尔自治区不动产登记中心), 乌鲁木齐 830046

摘要: 新疆维吾尔自治区拥有丰富的土地和光热资源, 随着对可再生能源的需求增加及光伏技术的发展, 新疆光伏电站装机容量位居全国前列。实时、准确识别光伏电站分布及其对周围植被空间聚集度的量化结果可为新疆太阳能光伏选址提供数据及决策支持。本研究基于3种架构(UNet、PSPNet、DeepLabV3+)和4种骨干网络(ResNet-34、ResNet-50、ResNet-101、ResNet-152)相结合、DeepLabV3+骨干网络替换为MobileNetV2、DarkNet53、VGG16、Dense121不同组合的深度学习语义分割模型, 筛选最优光伏电站识别模型, 以提取新疆地区光伏电站的空间分布。同时, 为探究光伏电站建设对所在地区植被空间聚集度的影响, 计算光伏电站周边从30—600 m等间隔分段的缓冲区内时间序列植被全局莫兰指数。结果表明:(1)基于UNet-ResNet50模型的光伏电站识别效果最优, 准确率(Accuracy)为98.64%(>0.09%)、F1分数(F1-score)为95%(>0.4%)以及交并比(IOUS)为90.47%(>0.57%), 该模型优异的识别效果主要源于高质量的光伏样本集以及模型在特征提取和深度平衡方面的卓越表现。(2)利用Sentinel-2遥感影像和UNet-ResNet50模型提取了2020年新疆光伏电站, 并将其划分为植被光伏和裸地光伏2类, 发现其面积占比分别为30%和70%。(3)距离光伏电站30—210 m不同等间距缓冲区, 植被全局莫兰指数在2012—2020年均呈显著下降趋势; 距离光伏电站210—600 m缓冲区, 植被全局莫兰指数下降趋势明显减缓。距离光伏电站越近, 植被空间聚集度受光伏电站影响越大, 时间序列的下降趋势越明显。综上, 开展光伏电站及其周围缓冲区的遥感监测, 可为光伏电站的建设规划、精细化运营管理及其对生态环境的影响评估提供数据和技术支持。

关键词: 光伏电站, 语义分割模型, 植被空间聚集度, 全局莫兰指数

中图分类号: TP701/P237/P2

引用格式: 乔佳佳, 闫敏, 刘永强, 张丽, 吴音, 陈一仰, 邵伟. 2025. 深度学习光伏电站识别及对植被空间聚集度的影响研究. 遥感学报, 29(11): 3312–3326

Qiao J J, Yan M, Liu Y Q, Zhang L, Wu Y, Chen Y Y and Shao W. 2025. Deep Learning for photovoltaic station identification and its effect on vegetation spatial aggregation. National Remote Sensing Bulletin, 29(11): 3312–3326 [DOI: 10.11834/jrs.20254192]

1 引言

太阳能作为最具潜力的可再生能源之一(de Castro等, 2013), 在新能源建设中具有举足轻重的地位(Fang等, 2023)。中国光伏园区发展迅速, 是目前装机量最大、增长速度最快的国家之一

(Xia等, 2022a)。光伏系统并非零污染技术(Tawalbeh等, 2021), 蓬勃发展的光伏电站会占用戈壁荒漠, 甚至侵占部分耕地或者农田等(Zhang等, 2023), 研究中需综合考虑光伏电站对环境的积极和消极影响(Qi和Zhang, 2017)。新疆维吾尔自治区(以下简称新疆)凭借得天独厚

收稿日期: 2024-05-23; 预印本: 2025-03-03

基金项目: 第三次新疆综合科学考察项目(编号: 2022xjkk1100)

第一作者简介: 乔佳佳, 研究方向为干旱区目标识别。E-mail: 107552201159@stu.xju.edu.cn

通信作者简介: 闫敏, 研究方向为植被生态与碳循环遥感。E-mail: yanmin@aircas.ac.cn

的地域及光能资源,开展了荒漠戈壁区多时期、大范围的光伏电站建设,但其对荒漠植被、周围环境的影响仍需进一步定量化的研究。

目前已有多种自动识别方法应用于光伏提取中,如已有研究基于 Google Earth Engine (GEE) 平台和随机森林算法识别了区域及全国的光伏电站,并将其区分为水面光伏、沙漠光伏等 (Xia 等, 2022a, 2022b; Zhang 等, 2022b; Zhao 和 Yin, 2022)。该类机器算法在大范围光伏识别中精度较高,但对于不同时相、复杂光伏目标的准确识别方面存在局限性。

随着卷积神经网络 CNN (Convolution Neural Network) 的发展,深度学习语义分割模型广泛应用于光伏电站的识别,经历了从单一网络到多网络组合的目标识别研究。典型的单一网络包括全卷积神经网络 FCN (Fully Convolutional Network)、UNet、PSPNet (Pyramid Scene Parsing Network)、DeepLab 等,如 Pérez-González 等 (2021) 提出了基于 UNet 模型自动提取光伏电站边界,识别精度达 90.42%; Huang 等 (2024) 利用 UNet 进行遥感测绘,达到了 85.27% 的精确率 (Precision) 和 76.96% 的平均交并比 (mIOU); Zhao 等 (2024) 采用 UNet 作为基础架构,设计了纹理特征和光谱特征的双分支特征提取结构,实现了 98.04% 的 F1 得分 (F1-score) 和 96.15% 的交并比 (IOU)。典型的组合网络主要由 UNet、PSPNet、DeepLabV3+ 架构与 ResNet 系列、Efficient 系列骨干网络的组合,如于方圆等 (2023) 利用 UNet 与 ResNet50 相结合的方式提取西北三省的光伏分布,相比单一网络提取,三省精度均提升至 90% 左右; da Costa 等 (2021) 对比了 4 种架构 (UNet、DeepLabV3+、PSPNet、FPN (Feature Pyramid Network)) 和 4 种骨干网络 (Efficient-net-b0, Efficient-net-b7, ResNet-50 和 ResNet-101) 的光伏提取精度,并应用至巴西太阳能发电厂识别中。针对大范围、多类型光伏的识别和监测仍需多角度评估、进一步探索单一或组合网络的有效性和适用性。

光伏电站的阵列覆盖区域会通过改变地表反照率的方式影响地表温度 (Lv 等, 2023),进而影响周围环境及植被状况。相关研究通过光伏电站观测站监测、遥感指数反演等手段探究了光伏电站建设对地表反照率、温度等指标的直接影响。Ying 等 (2023) 对比古尔班通古特沙漠的光伏站

点和未开发的沙漠站点的监测数据,结果表明光伏电站的反射辐射明显低于裸露沙漠区; Jiang 等 (2021b) 根据新疆五家渠观测塔数据,发现与天然荒地相比光伏电站显热通量增加、潜热通量减少,地表热量降低; Chang 等 (2020) 模拟青海省大规模光伏电站建设对当地气候的影响,发现光伏电站会降低 10 m 内风速和白天地表温度; Chang 等 (2018) 对共和光伏园区进行监测和数值模拟,发现光伏电池板下地表温度全年下降,而光伏板表面白天升温,夜间降温。光伏电站建设对周边植被的影响主要体现在植被覆盖度的影响。Potter (2016) 利用 Landsat 4/5/8 遥感数据计算归一化植被指数 NDVI (Normalized Difference Vegetation Index),表征和量化沙漠地区的光伏电站对植被密度的影响,发现光伏电站建设会降低区域的 NDVI,导致植被密度下降; Luo 等 (2023) 利用遥感监测方法,发现光伏电站建设初期会导致区域 NDVI 急速下降。Xia 等 (2024) 量化了中国旱地光伏电站大规模部署对植被的影响,光伏电站对植被动态的影响表现出空间异质性。在极干旱区以及亚干旱区分别有 47% 和 69% 的光伏电站会导致 NDVI 减少。目前尚缺少光伏电站建设不同缓冲区范围内量化影响评估,导致无法准确评估光伏电站建设对环境的影响。

因此,本文基于 Sentinel-2 遥感影像,利用深度学习语义分割算法开展了光伏电站目标识别,得到了 2020 年的新疆光伏分布;利用莫兰指数分析法探究了新疆光伏电站建设对植被空间聚集度的影响。通过本文的研究将探索适合干旱区集中式光伏的深度学习模型,实现新疆光伏电站准确识别以及动态监测,评估光伏动态扩张对植被空间聚集度的影响,以期为干旱区光伏电站的选址布局、生态环境影响评估及可持续发展政策制定提供数据支撑与科学参考。

2 研究区概况与数据来源

2.1 研究区概况

新疆维吾尔自治区地理位置 (73°40'E—96°23'E, 34°25'N—49°10'N) (图 1),位于中国西北边陲。属于温带大陆性气候,气候干燥,日照时间长,昼夜温差大。年平均气温在 10—15 °C,最高气温 40 °C 以上,最低气温在零下 40 °C (Jiang 等, 2021b);

年平均降水量<150 mm; 年平均蒸发量 1000—4500 mm (Luo等, 2023); 年总日照时长为 3200—3400 h。光伏电站较多分布于地势较为平坦的地区, 下垫面主要为沙漠、戈壁、裸土等, 植被覆盖多为怪柳、碱蓬、枸杞、白前、苦豆子、骆驼刺等稀疏植被 (Ying等, 2023)。




图1 研究区示意图

Fig. 1 The map of study area

2.2 数据来源

2.2.1 遥感影像

本研究使用了 Sentinel-2 和 Landsat 7 遥感影像数据。Sentinel-2 数据来源于 Copernicus 开放获取数据平台 (<https://dataspace.copernicus.eu/> [2024-12-10]) 其重访周期为 5 d, 包含可见光、红边、近红外和短波红外等波段, 其中红、绿、蓝和近红外波段的空间分辨率均为 10 m, 其他波段分别为 20 和 60 m (闵钰魁等, 2023)。数据获取通过 GEE 平台完成, 选取了覆盖新疆 2020 年全年影像的数据, 并使用云掩膜算法去除了被云覆盖的像素, 通过中值合成法生成年度影像, 最终利用 2020 年 Sentinel-2 影像的红、绿、蓝波段制作了用于语义分割的光伏电站样本集, 以识别 2020 年新疆地区的光伏电站分布情况。

Landsat 7 数据来源于 USGS Earth Explorer 平台 (<https://earthexplorer.usgs.gov/> [2024-12-10]), 重访周期为 16 d, 包含可见光、近红外、中红外、热红外和全色波段。基于 GEE 平台调用 2000—2020 年的 Landsat 7 卫星 (LE07/C02/T1_L2) 数据集的近红外波段 (SR_B4) 和红光波段 (SR_B3), 采用多时相合成填补条带方法计算逐年最大值

NDVI。该 NDVI 数据用于分析新疆光伏电站对植被空间聚集度的影响。

2.2.2 其他数据集

本研究利用 2020 年中国土地利用/覆被遥感监测数据集 (CNLUCC) 来判别新疆光伏电站的下垫面土地利用/覆被类型, 该数据集来源于中国科学院资源环境科学与数据中心 (<https://www.resdc.cn/> [2024-12-10]), 空间分辨率为 30 m, 包括耕地、林地、草地、水域、建设用地、未利用土地 6 个一级类和 25 个二级类。通过空间匹配和叠加分析方法, 将新疆光伏分为植被光伏和裸地光伏, 植被光伏是指位于耕地、低覆盖草地、中覆盖草地和高覆盖草地的光伏电站, 裸地光伏是指位于沙漠、戈壁和裸土的光伏电站。

3 研究方法

利用 Sentinel-2 数据构建了新疆光伏电站样本集, 用于训练和验证深度学习语义分割模型 UNet、PSPNet、DeepLabV3+, 经验证后, 采用最优模型提取新疆光伏电站空间分布, 最后利用全局莫兰指数探究光伏电站对周围植被空间聚集度的影响, 具体技术路线如图 2 所示。

3.1 深度学习光伏电站识别

3.1.1 光伏样本标注和数据增广

本研究利用 Sentinel-2 影像红、绿、蓝 3 个波段, 人工标注光伏电站样本, 并根据 Google Earth Pro 影像检查和更正, 使得样本具有代表性和多样性, 确保模型的识别能力和泛化能力。样本重叠率设为 0.50, 裁剪为 256 像素×256 像素的瓦片, 并以栅格格式存储, 如图 3 所示。光伏电站通常由多个光伏阵列组成, 在遥感卫星影像中, 光伏阵列在远红外波段 (3—1000 μm) 的反射率较高, 在可见光 (0.4—0.7 μm) 和近红外波段 (0.7—1.4 μm) 的反射率较低 (Xia等, 2022a)。

为保证样本数量和内容的丰富性, 研究中将样本顺时针每隔 30° 旋转一次, 旋转一周将样本扩充为原来的 12 倍 (图 4), 以此提高模型的泛化能力和鲁棒性。最终用于深度学习目标识别的样本为 12924 组, 包括遥感影像和标注样本, 并按照 7:3 的比例将其划分为训练样本集和验证样本集。

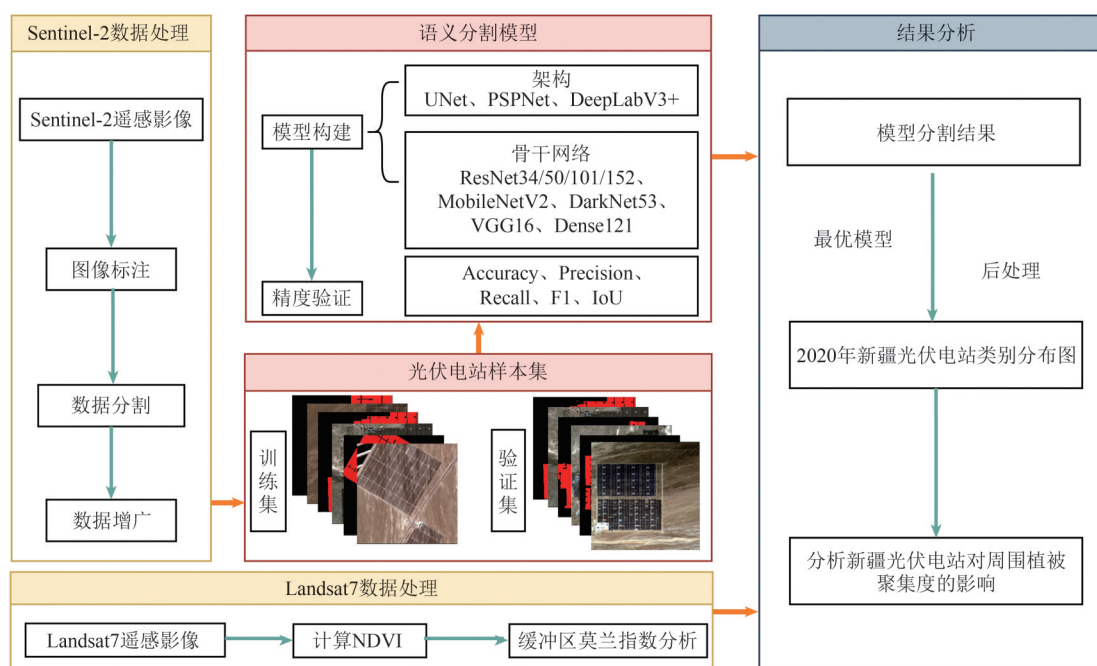


图2 技术路线图

Fig. 2 Technology roadmap




图3 光伏电站的Sentinel-2影像和标签

Fig. 3 Sentinel-2 images and labels of photovoltaic stations




图4 光伏电站样本数据增广(图(I)样本顺时针每隔30°旋转一次扩充得到图II—XII的样本)

Fig.4 Data augmentation of photovoltaic station samples

3.1.2 深度学习模型训练

UNet是一种经典的语义分割模型,它通过编码器降低图像分辨率进行特征提取,再通过解码

器恢复图像分辨率进行预测。UNet在固定结构的数据集上具有优势(Shen等,2022;石伟博等,2023),但会损失图像细节。PSPNet利用金字塔池化核心模块捕捉多尺度的局部特征,但对于网格边缘只能提取到1/4的局部特征,且输出特征图直接上采样到输入图的大小,对局部细节捕捉的能力较弱(Yuan等,2022)。作为一种应用广泛的、具备编码、解码结构的语义分割模型,DeepLabV3+借鉴了UNet模型的编码器、解码器结构和PSPNet模型的金字塔池化两个模块(刘春亭等,2022)。在不损失信息的前提下,DeepLabV3+使用空洞卷积来增大感受野,获得不同尺度的上下文信息(Jiang等,2021a)。可通过替换DeepLabV3+模型的特征主干网络Xception,寻求其他骨干网络如DarkNet53(Demirci等,2021)、VGG16(Demirci等,2021;Li等,2023)、Dense121(Cinar等,2022)和轻量级MobileNetV2(Kulkarni等,2023)来获得更丰富的信息。

本研究使用Windows系统下的PyTorch深度学习框架,处理器型号为i9-13900K,GPU使用NVIDIA GeForce RTX 3090。利用3种架构(UNet、PSPNet、DeepLabV3+)和4种骨干网络(ResNet-34、ResNet-50、ResNet-101、ResNet-152)相结合DeepLabV3+骨干网络替换(MobileNetV2、

DarkNet53、VGG16、Dense121)的方式开展光伏电站目标识别。在超参数设置中,批次大小(Batch Size)设置为8,训练轮数(Epoch)设置为50。当模型在验证集上的性能不再提升时,训练过程将自动退出循环。

3.2 精度评价

为了验证语义分割模型的性能,采用准确率(Accuracy)、精确率(Precision)、召回率(Recall)、F1分数(F1-score)、交并比(IOUS) 5个指标作为光伏识别评价标准(Shen等, 2022; Yuan等, 2022; Jiang等, 2021a)。具体计算公式如下:

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FN} + \text{FP} + \text{TN}} \quad (1)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (3)$$

$$\text{F1} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

$$\text{IOUS} = 2 \times \frac{\text{TP}}{\text{TP} + \text{FN} + \text{FP}} \quad (5)$$

式中, TP为正确分类的光伏像素数, TN为正确分类的非光伏像素数, FP为误分的非光伏像素数, FN为误分的光伏像素数。

3.3 全局莫兰指数及趋势分析

全局莫兰指数(Global Moran's I)反映整体空间存在的自相关特征,可用于描述光伏电站区域与周围区域的平均关联程度,作为判断植被空间聚集程度的指标,取值范围是 $[-1, 1]$ 。“ $I>0$ ”表示空间正相关,值越接近1,空间聚集性越高;“ $I<0$ ”表示空间负相关性,值越小,空间差异越大;“ $I=0$ ”表示不存在空间聚集性,呈随机分布(Kozonogova和Dubrovskaya, 2020)。其计算公式为

$$I = \frac{n}{\sum_{i=1}^n \sum_{j=1}^n w_{ij}} \times \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} z_i z_j}{\sum_{i=1}^n z_i^2} \quad (6)$$

式中, n 为研究区内光伏电站单元的总个数, z_i 为第 i 个光伏电站的属性与其平均值的偏差,即 $x_i - \bar{x}$, z_j 为第 j 个光伏电站($i \neq j$)的属性与其平均值的偏差,即 $x_j - \bar{x}$, w_{ij} 为要素 i 、 j 之间的空间权重,当 i 、 j 相邻时, w_{ij} 为1,否则为0。

全局莫兰指数的显著性通过 P 值和 Z 得分来判断,若 P 值小于0.05,并且 Z 得分 >1.65 ,则存在显著正相关;若 P 值 <0.05 ,但 Z 得分 <-1.65 ,则为显著负相关(Zhang等, 2022a)。本研究通过使用最大值合成法,计算了2000年—2020年新疆逐年30 m分辨率的NDVI数据集。以2020年新疆光伏电站类别分布中的植被光伏为矢量边界,每隔30 m建立一个缓冲区,共建立20个缓冲区,覆盖光伏电站周围600 m的范围。逐年提取每个缓冲区范围内的平均NDVI,计算全局莫兰指数、 Z 得分以及 P 值,由此评价光伏电站对植被空间聚集程度的影响。

此外,本研究采用最小二乘回归法LSR(Least Square Regression)来分析光伏电站建设时间与植被空间聚集变化的关系。以最早建设植被光伏的时间作为整体植被光伏最初建设的时间,将此时间点设为分析的转折点。通过分段线性回归探究建设前后全局莫兰指数的变化。模型的拟合效果通过显著性水平0.05或0.01下的统计检验来评估。其中: $P<0.05$ 表示线性关系具有统计显著性, $P<0.01$ 则表示关系极为显著。

4 结果与分析

4.1 深度学习光伏电站识别

4.1.1 光伏电站训练集和验证集损失和准确率分析

本研究使用光伏电站数据集对16种深度学习语义分割模型(包括UNet-ResNet34、UNet-ResNet50、UNet-ResNet101、UNet-ResNet152、PSPNet-ResNet34、PSPNet-ResNet50、PSPNet-ResNet101、PSPNet-ResNet152、DeepLabV3+-ResNet34、DeepLabV3+-ResNet50、DeepLabV3+-ResNet101、DeepLabV3+-ResNet152、DeepLabV3+-MobileNetV2、DeepLabV3+-DarkNet53、DeepLabV3+-VGG16和DeepLabV3+-Dense121)进行训练和验证,得到训练集与验证集的损失函数和准确率曲线见图5。可见:大部分模型(如UNet-ResNet34、UNet-ResNet50、UNet-ResNet101、UNet-ResNet152、PSPNet-ResNet152、DeepLabV3+-ResNet34、DeepLabV3+-VGG16和DeepLabV3+-Dense121)的验证集准确率上升趋势和损失值下降趋势较为相似。




图5 不同模型的训练集和验证集损失、准确率曲线(acc和val_acc分别表示模型训练期间训练集和验证集的准确率; loss和val_loss分别表示模型训练期间训练集和验证集的损失值)

Fig. 5 Loss and accuracy curves of the training and validation sets for the model

在本研究的实验条件和超参数设置下, UNet-ResNet50模型在验证集上的精度达到了0.88, 损失值达到0.03, 显著优于其他模型, 表明该模型在捕捉特征并进行精确分割方面具有较强的能力。相对而言, DeepLabV3+-MobileNetV2模型的表现较差, 其验证集上的准确率和损失函数曲线存在显著波动。DeepLabV3+模型通过整合空洞卷积和空间金字塔池化(ASPP)技术, 增强了语义分割的精度。然而, 由于MobileNetV2是轻量化的骨干

网络, 对训练参数的波动较为敏感, 实验将Batch Size设置为8, 小批次训练可能进一步加剧了损失函数和准确率的不稳定性, 导致该模型在验证集上的表现不如其他模型稳定。

综上, 16种模型在光伏电站识别任务中的性能存在显著差异, 其中UNet-ResNet50模型在精度与稳定性上表现最佳。

4.1.2 模型分割结果比较

图6为16种模型的实际分割效果图。可见UNet-

ResNet50、UNet-ResNet152 和 PSPNet-ResNet34 模型在分辨光伏阵列内部的道路和外部边界方面表现出色。相比之下, DeepLabV3+系列模型虽然

能够有效提取边缘信息,但对内部细节如道路的敏感度不足。此外, PSPNet-ResNet101 模型在处理图像边缘时表现不稳定,常出现断续的小斑块。




图6 基于不同模型简单背景的光伏电站分割结果

Fig. 6 Segmentation results of Photovoltaic stations on simple backgrounds based on different models

为了测试不同模型在复杂背景下的表现,本研究选取了颜色与光伏电站相近的典型复杂背景图像,分割结果如图7所示。

可见:在UNet系列中,UNet-ResNet50模型保持了较高的分割精度,这得益于其较优的特征提取能力和深度平衡;相比之下,UNet-ResNet101和UNet-ResNet152表现不佳,UNet-ResNet101在特征提取过程中出现信息过滤,导致关键上下文信息的丢失,而UNet-ResNet152由于网络过深、参数过多,出现背景与目标的分类错误,表现为特征过拟合。DeepLabV3+系列在边缘检测和语义分割的特异性上表现出色,但在复杂背景下的细节捕捉能力较弱,特别是在对光伏阵列内部结构(如道路等细节)的分割方面性能不足。PSPNet系列模型在复杂场景下的语义解析能力较差,容易受到环境噪声的影响,导致了边缘区域出现较多的分割错误。

综上,UNet-ResNet50模型在光伏电站的图像

分割任务中表现出较高的稳定性和精确度,这得益于其恰当的网络深度和有效的残差学习机制,能够有效地平衡特征的捕捉与计算效率。而DeepLabV3+系列虽在边缘特征的提取上表现优异,但在细节分割的连续性和准确性上仍有改进空间。PSPNet系列则在处理复杂背景和细节丰富的场景时表现不足,经常将非目标区域误判为目标,从而影响了分割的整体准确率。

4.1.3 模型评价分析

为了定量评价光伏电站分割效果,对16个模型进行了精度分析,结果见表1。可见,UNet-ResNet50模型在所有评估指标中表现突出,其中Accuracy、F1-score和IOU分别达到了98.64%、95.00%和90.47%。表明UNet-ResNet50在整体分类准确性、分类精确性与召回率的平衡性、以及预测区域与实际区域的重合度方面均具有显著优势。




图7 基于不同模型复杂背景的光伏电站分割结果

Fig. 7 Segmentation results of Photovoltaic stations on complex backgrounds based on different models

表1 UNet、PSPNet以及DeepLabV3+模型精度评价结果
Table 1 Accuracy assessment for UNet, PSPNet, and DeepLabV3+ Models

模型	Accuracy	Precision	Recall	F1	IOU
UNet-ResNet34	98.40	92.76	95.53	94.13	<u>89.90</u>
UNet-ResNet50	98.64	<u>94.15</u>	95.85	95.00	90.47
UNet-ResNet101	98.29	92.81	94.56	93.68	88.11
UNet-ResNet152	<u>98.55</u>	93.95	95.19	94.57	88.62
PSPNet-ResNet34	98.36	92.68	95.29	93.97	88.62
PSPNet-ResNet50	98.46	92.94	95.76	94.33	89.27
PSPNet-ResNet101	97.94	90.63	94.37	92.47	85.99
PSPNet-ResNet152	97.54	94.72	86.48	90.41	82.50
DeepLabV3+-ResNet34	98.43	91.49	96.06	93.72	88.18
DeepLabV3+-ResNet50	98.48	92.98	95.90	94.41	89.42
DeepLabV3+-ResNet101	98.52	93.01	96.23	94.59	89.74
DeepLabV3+-ResNet152	98.32	92.25	95.49	93.84	88.40
DeepLabV3+-MobileNetV2	98.51	93.25	95.85	94.53	89.63
DeepLabV3+-DarkNet53	98.46	92.65	<u>96.12</u>	94.35	89.31
DeepLabV3+-VGG16	98.52	93.08	96.08	94.56	89.68
DeepLabV3+-Dense121	98.53	93.29	95.96	<u>94.60</u>	89.76

注：Accuracy、Precision、Recall、和 IOU 分别代表准确率、精确率、召回率和交并比。数值的粗体和下划线分别表示最佳和次最佳精度。

UNet-ResNet50 的 Accuracy 达到了 98.64%，表明该模型在光伏电站区域识别任务中具有极高的整体分类准确性，尤其适用于大规模光伏电站场景；其 F1-score 达到了 95.00%，表明模型在准确识别光伏电站区域方面的同时，能有效减少漏检和误检，提升实际应用的可靠性。IOU 值达到了 90.47%，进一步显示了其在精确提取光伏电站边界方面的能力，即使在复杂背景下也能保持高精度的边界分割。

UNet-ResNet50 模型结合了 UNet 全卷积网络结构和 ResNet50 残差网络的深层特征提取能力，既充分利用了 ResNet50 在提取深层次特征时的优势，又保留了 UNet 在捕捉多尺度语义信息方面的高效性。因此，该模型在光伏电站语义分割任务中的表现尤为出色，特别是在处理光伏电站与背景复杂边界的分割任务时具有明显的优势。与其他模型（如 PSPNet-ResNet50 和 DeepLabV3+-Dense121）相比，UNet-ResNet50 不仅在单项指标上表现优异，而且在多个核心指标上实现了全面领先。

综上，UNet-ResNet50 在光伏电站语义分割任务中具有出色的鲁棒性和稳定性，尤其适用于大型光伏电站的实际场景应用，其高精度分割能力使其成为该任务的首选模型。

4.2 光伏电站对植被空间聚集度的影响分析

4.2.1 新疆光伏电站空间分布

图8为新疆2020年10 m分辨率的光伏电站类别分布图。可见新疆共提取到266个光伏电站,其中植被光伏83个,裸地光伏183个。本研究统计结果表明,2020年新疆光伏电站总面积为305.5 km²,其中植被光伏与裸地光伏的面积占比分别为30%和70%。新疆光伏电站主要分布在准噶尔盆地边缘、古尔班通古特沙漠边缘、吐鲁番—哈密盆地及塔克拉玛干沙漠边缘。





图8 2020年新疆光伏电站分布图

Fig. 8 Distribution of photovoltaic stations in Xinjiang, 2020

4.2.2 光伏电站对植被空间聚集度的影响分析

为了研究植被光伏对周围植被空间聚集度的影响,本研究对83个植被光伏电站周边设定了30—600 m的等间隔缓冲区,并计算了这些区域内全局莫兰指数的时间序列,结果见图9。可见:缓冲区的全局莫兰指数均>0,表明NDVI呈正向自相关,即相似的NDVI值彼此靠近;缓冲区Z得分均>180,且 $P<0.01$,说明在光伏电站周围600 m范围内,NDVI存在正向自相关且显著聚集。

本研究假设光伏电站周围600 m范围内(20个缓冲区)的气候条件(气温、降水等)一致,对比光伏电站建设前后植被全局莫兰指数趋势,如图10所示。2000年—2011年间,光伏电站在60—600 m内NDVI的全局莫兰指数呈现波动但不显著($P>0.05$)。2012年—2020年间,全局莫兰指数在光伏电站周围600 m范围内呈下降趋势。特别是在60 m缓冲区范围内,光伏电站建设前全局莫兰指数波动剧烈,建设后呈极显著下降趋势($P<0.01$);210 m缓冲区内,光伏电站建设前变化不显著,建设后显著下降($P<0.05$),且降幅大于建设前;在缓冲区210—360 m,光伏电站建设前无显著性,建设后有显著性;360 m缓冲区之外,光伏电站建设前后均无显著性。这些结果表明,光伏电站对周围210 m范围内的植被聚集度影响较大,光伏电站的建设减少了周围植被的空间聚集度,具有负向生态作用。






图9 2000年—2020年距光伏电站不同缓冲区范围的植被全局莫兰指数

Fig. 9 Global Moran's I of NDVI within different buffer zone ranges from photovoltaic stations from 2000–2020




图10 2000年—2020年光伏电站建设前后植被全局莫兰指数趋势以及P值

Fig. 10 Trends and P-values of Global Moran's I before and after the construction of photovoltaic stations from 2000–2020

如图11所示, 对比2000年—2011年和2012年—2020年光伏电站建设前后的趋势发现, 在光伏电站600 m范围内, 随着缓冲区向外扩充, 趋势

差值逐渐减小, 这表明, 随着光伏电站缓冲区范围的扩大, 其对植被空间聚集度的影响逐渐减弱。




图 11 2000 年—2020 年光伏电站建设前后植被全局莫兰指数趋势差值

Fig.11 The differences in Global Moran's I trends before and after the construction of photovoltaic stations from 2000–2020

5 讨论

本研究评估了 16 种语义分割模型在干旱区光伏电站识别中的性能，结果显示所有模型的 Accuracy、F1-score 和 IOU 均超过了 97%、90% 和 82%。冯权洸等 (2022) 指出，高质量的数据集是决定深度学习模型准确性的关键因素。本研究构建的数据集全面覆盖了新疆光伏电站的多种场景，使模型能够在训练期间有效学习到复杂场景下光伏电站的结构形态特征。特别是，UNet-ResNet50 模型凭借其在特征提取和深度平衡方面的优势，在 Accuracy、F1-score 和 IOU 上均表现最佳，分别达到 98.64%、95% 和 90.47%。Pérez-González 等 (2021) 研究表明，UNet 模型在自动提取光伏电站边界的应用中表现出色，特别是在荒芜地区光伏电站的边界识别上可以准确无误地执行，尽管在植被覆盖的光伏边界识别中存在微小误差，但该模型的 IOU 达到 90.42%；另一方面，da Costa 等 (2021) 的研究显示，在同一数据集上，采用 UNet 架构的模型在性能上优于 DeepLabV3+、PSPNet 及 FPN，其中 F1-score 和 IOU 分别超过 95% 和 90%。这表明如果图像中光伏板边界清晰且需要高精度的局部特征识别，UNet 模型将是最佳选择。然而，Yan 等 (2023) 认为，在包含复杂背景或需求广泛空间关系理解的场景中，PSPNet 和 DeepLabV3+ 可能更适合。新疆约 62% 的光伏电站主要建设于未利用地区，本研究开发的方法能快速精确提取这

些区域的光伏电站。相较而言，中国东南部光伏电站的地形复杂，包括水面和屋顶光伏，分布较为碎片化，本方法在此类复杂背景下的识别精度有待提高。未来研究将致力于优化复杂环境下光伏电站的自动识别技术，以支持大范围光伏分布的高效绘制。

中国光伏电站快速增长，特别是在新疆，光伏电站已成为重要的土地覆盖类型 (韩梦瑶 等, 2022; Xu 和 Lu, 2023)，大规模部署导致了显著的生态环境变化。本研究指出，在光伏电站 210 m 范围内，植被全局莫兰指数显著下降，表明光伏电站建设对周边植被空间聚集度具有负面影响。此外，杨凯迪等 (2023) 研究也显示，中国西北地区的光伏电站抑制了植被生长，其影响范围可达 500 m。干旱区植被减少一方面由于光伏组件吸收太阳辐射，导致地表反照率和地表温度降低 (Xu 等, 2024)。Li 等 (2021) 的研究表明，光伏电站具有显著的冷却效应，影响范围可达 730 m。特别是在光伏电站 100 m 内，地表温度可降低 2.3 °C，这种温度变化显著影响了周围植被的生长状态，不利于植被的繁茂。另一方面，新疆的怪柳、碱蓬、枸杞、白前、苦豆子等植被均属草本类，其根系较短，对地下水位的变化较为敏感。Song 等 (2021) 的研究表明，当地区地下水位深度增加时，这些草本植被的生长受到抑制，逐渐枯萎，导致植被覆盖率下降。Glanville 等 (2023) 的研究也显示，干旱地区的植被群落极度依赖地

下水, 地下水位的下降与植被的死亡率密切相关, 严重情况下可能导致植被永久性损失。

然而, 也有研究表明光伏电站对生态环境有积极影响。Zhang 等 (2024b) 的研究显示, 通过水养协调和碳水耦合, 光伏电站可以促进草原生态系统植被的恢复。此外, Xia 等 (2022b) 研究表明, 大规模的光伏治沙项目有效促进了沙漠地区的绿化, 有助于防治沙漠化。基于目前研究, 有必要进一步量化分析光伏电站对生态环境异质性的影响。

6 结 论

为实现干旱区集中式光伏电站的精准识别与动态监测, 评估光伏电站开发对植被空间格局的生态效应, 本研究以新疆为研究区域, 基于2020年获取的 Sentinel-2 卫星影像构建了光伏电站的语义分割数据集。通过训练和评估 UNet、PSPNet 和 DeepLabV3+ 系列的 16 个深度学习模型, 确定最适合于新疆光伏电站识别的模型。进一步利用此最优模型, 成功提取了新疆地区光伏电站的空间分布, 并通过对光伏电站周边 30—600 m 缓冲区内植被的全局莫兰指数进行时间序列分析, 深入探讨了光伏电站对周边植被聚集度的影响。主要结论如下:

(1) 采用 F1-score 和 IOU 作为主要性能评估指标, 确定了 UNet-ResNet50 模型在 Accuracy、F1-score 和 IOU 方面的卓越表现, 分别达到 98.64%、95% 和 90.47%。与其他模型相比, UNet-ResNet50 在这些关键性能指标上分别提高了至少 0.09%、0.4% 和 0.57%。该模型之所以表现最佳, 得益于 UNet 架构在处理二分类任务中的高效性, 以及 ResNet50 的适中网络深度, 这使得模型能够有效处理光伏电站图像并平衡特征提取的深度与复杂度。

(2) 使用 UNet-ResNet50 模型, 成功提取了 2020 年新疆光伏电站分布数据, 共计 266 个光伏电站, 覆盖总面积达到 305.5 km²。其中植被光伏占 91 km², 裸地光伏占 214.5 km²。植被光伏主要分布在天山山脉北麓, 涵盖了准噶尔盆地南缘和古尔班通古特沙漠南缘; 而裸地光伏主要分布在吐鲁番-哈密盆地以及塔克拉玛干沙漠边缘。

(3) 新疆 83 个植被光伏对周围 60 m 范围内的植被聚集度具有极显著的负面影响, 而在 210 m 范

围内的影响虽然减弱但依然显著。这表明光伏电站的存在显著抑制了周边植被的生长。随着距离光伏电站的增加, 其对植被聚集度的影响逐渐降低, 显示出空间影响的衰减趋势。

因此, 合理规划光伏电站对实现“双碳”目标至关重要。本研究提供了关于光伏电站建设对环境影响的科学数据, 支持制定有效的土地使用策略和环保措施, 确保能源发展的可持续性。

参考文献 (References)

- Chang R, Luo Y and Zhu R. 2020. Simulated local climatic impacts of large-scale photovoltaics over the barren area of Qinghai, China. *Renewable Energy*, 145: 478-489 [DOI: 10.1016/j.renene.2019.06.059]
- Chang R, Shen Y B, Luo Y, Wang B, Yang Z B and Guo P. 2018. Observed surface radiation and temperature impacts from the large-scale deployment of photovoltaics in the barren area of Gonghe, China. *Renewable Energy*, 118: 131-137 [DOI: 10.1016/j.renene.2017.11.007]
- Cinar N, Ozcan A and Kaya M. 2022. A hybrid DenseNet121-UNet model for brain tumor segmentation from MR Images. *Biomedical Signal Processing and Control*, 76: 103647 [DOI: 10.1016/j.bspc.2022.103647]
- da Costa M V C V, de Carvalho O L F, Orlandi A G, Hirata I, de Albuquerque A O, Silva F V E, Guimarães R F, Gomes R A T and de Carvalho Júnior O A. 2021. Remote sensing for monitoring photovoltaic solar plants in Brazil using deep semantic segmentation. *Energies*, 14(10): 2960 [DOI: 10.3390/en14102960]
- de Castro C, Mediavilla M, Miguel L J and Frechoso F. 2013. Global solar electric potential: a review of their technical and sustainable limits. *Renewable and Sustainable Energy Reviews*, 28: 824-835 [DOI: 10.1016/j.rser.2013.08.040]
- Demirci M Y, Bešli N and Gümüşçü A. 2021. Efficient deep feature extraction and classification for identifying defective photovoltaic module cells in Electroluminescence images. *Expert Systems with Applications*, 175: 114810 [DOI: 10.1016/j.eswa.2021.114810]
- Fang G C, Gao Z Y and Sun C W. 2023. How the new energy industry contributes to carbon reduction? —Evidence from China. *Journal of Environmental Management*, 329: 117066 [DOI: 10.1016/j.jenvman.2022.117066]
- Feng Q L, Chen B A, Li G Q, Yao X C, Gao B B and Zhang L C. 2022. A review for sample datasets of remote sensing imagery. *National Remote Sensing Bulletin*, 26(4): 589-605 (冯权洸, 陈泊安, 李国庆, 姚晓闯, 高秉博, 张连翀. 2022. 遥感影像样本数据集研究综述. *遥感学报*, 26(4): 589-605) [DOI: 10.11834/jrs.20221162]
- Glanville K, Sheldon F, Butler D and Capon S. 2023. Effects and significance of groundwater for vegetation: a systematic review. *Science of the Total Environment*, 875: 162577 [DOI: 10.1016/j.scitotenv.2023.162577]

- Han M Y, Xiong J and Liu W D. 2022. Spatio-temporal distribution, competitive development and emission reduction of China's photovoltaic power generation. *Journal of Natural Resources*, 37(5): 1338-1351 (韩梦瑶, 熊焦, 刘卫东. 2022. 中国光伏发电的时空分布、竞争格局及减排效益. *自然资源学报*, 37(5): 1338-1351) [DOI: 10.31497/zrzyxb.20220516]
- Huang C H, Xie L J, Chen W Z, Lin Y, Wu Y X, Li P H, Chen W R, Yang W and Deng J S. 2024. Remote-sensing extraction and carbon emission reduction benefit assessment for centralized photovoltaic power plants in Agrivoltaic systems. *Applied Energy*, 370: 123585 [DOI: 10.1016/j.apenergy.2024.123585]
- Jiang H, Yao L, Lu N, Qin J, Liu T, Liu Y J and Zhou C H. 2021a. Multi-resolution dataset for photovoltaic panel segmentation from satellite and aerial imagery. *Earth System Science Data*, 13(11): 5389-5401 [DOI: 10.5194/essd-13-5389-2021]
- Jiang J X, Gao X Q, Lv Q Q, Li Z C and Li P D. 2021b. Observed impacts of utility-scale photovoltaic plant on local air temperature and energy partitioning in the barren areas. *Renewable Energy*, 174: 157-169 [DOI: 10.1016/j.renene.2021.03.148]
- Kozonogova E and Dubrovskaya J. 2020. Assessment of the features of the spatial organization of the Russian economy based on the global and local Moran indices//Bilgin M H, Danis H, Demir E and Tony-Okeke U, eds. *Eurasian Economic Perspectives*. Cham: Springer: 195-203 [DOI: 10.1007/978-3-030-48531-3_14]
- Kulkarni U, Gurlahosur S V, Babar P, Muttagi S I, Soumya N, Jadekar P A and M M S. 2023. Facial key points detection using MobileNetV2 architecture//2023 IEEE 8th International Conference for Convergence in Technology (I2CT). Lonavla: IEEE: 1-6 [DOI: 10.1109/I2CT57861.2023.10126381]
- Li G Q, Hernandez R R, Blackburn G A, Davies G, Hunt M, Whyatt J D and Armstrong A. 2021. Ground-mounted photovoltaic solar parks promote land surface cool islands in arid ecosystems. *Renewable and Sustainable Energy Transition*, 1: 100008 [DOI: 10.1016/j.rset.2021.100008]
- Li L, Lu N, Jiang H and Qin J. 2023. Impact of deep convolutional neural network structure on photovoltaic array extraction from high spatial resolution remote sensing images. *Remote Sensing*, 15(18): 4554 [DOI: 10.3390/rs15184554]
- Liu C T, Feng Q L, Liu J T, Wang Y, Shi T G, Li Y, Gong J H and Zhao H H. 2022. Urban green plastic cover extraction and spatial pattern changes in Jinan city based on DeepLabv3+ semantic segmentation model. *National Remote Sensing Bulletin*, 26(12): 2518-2530 (刘春亭, 冯权泷, 刘建涛, 王莹, 史同广, 李毅, 龚建华, 赵辉辉. 2022. DeepLabv3+语义分割模型的济南市防尘绿网提取及时空变化分析. *遥感学报*, 26(12): 2518-2530) [DOI: 10.11834/jrs.20220101]
- Luo L H, Zhuang Y L, Liu H, Zhao W Z, Chen J Z, Du W T and Gao X Q. 2023. Environmental impacts of photovoltaic power plants in northwest China. *Sustainable Energy Technologies and Assessments*, 56: 103120 [DOI: 10.1016/j.seta.2023.103120]
- Lv Q Q, Zhang Z Z, Gao P F and Li J. 2023. The impact of photovoltaic power stations on the ecological environment//2023 7th International Conference on Smart Grid and Smart Cities (ICSGSC). Lanzhou: IEEE: 494-500 [DOI: 10.1109/ICSGSC59580.2023.10319196]
- Min Y K, Ke Y H, Han Y, Yin X L and Zhou D M. 2023. Dynamic monitoring of invasive *Spartina alterniflora* clearance via fusion of Sentinel-2 and GF-1 time series images. *National Remote Sensing Bulletin*, 27(6): 1467-1479 (闵钰魁, 柯樱海, 韩月, 尹小岚, 周德民. 2023. 融合 Sentinel-2 和 GF-1 时序影像的入侵植物互花米草清除动态监测. *遥感学报*, 27(6): 1467-1479) [DOI: 10.11834/jrs.20232279]
- Pérez-González A, Jaramillo-Duque Á and Cano-Quintero J B. 2021. Automatic boundary extraction for photovoltaic plants using the deep learning U-Net model. *Applied Sciences*, 11(14): 6524 [DOI: 10.3390/app11146524]
- Potter C. 2016. Landsat time series analysis of vegetation changes in solar energy development areas of the lower Colorado desert, Southern California. *Journal of Geoscience and Environment Protection*, 4(2): 1-6 [DOI: 10.4236/gep.2016.42001]
- Qi L Q and Zhang Y J. 2017. Effects of solar photovoltaic technology on the environment in China. *Environmental Science and Pollution Research*, 24(28): 22133-22142 [DOI: 10.1007/s11356-017-9987-0]
- Shen Y, Fan T, Lai G Z, Na Z X, Liu H, Wang Z Y, Wang Y Y, Jiao Y P, Chen X Y, Lou Z W, Zhang J X, Zhang K J and Wei H K. 2022. Modified U-Net based photovoltaic array extraction from complex scene in aerial infrared thermal imagery. *Solar Energy*, 240: 90-103 [DOI: 10.1016/j.solener.2022.05.017]
- Shi W B, Liao X H, Wang S Q, Yue H Y and Wang D L. 2023. Effects of image input size and resolution by CNN on the classification accuracy for coniferous forest vegetation in western Sichuan. *National Remote Sensing Bulletin*, 27(11): 2640-2652 (石伟博, 廖小罕, 王绍强, 岳焕印, 王东亮. 2023. CNN 影像输入尺寸和分辨率对川西针叶林植被分类精度的影响. *遥感学报*, 27(11): 2640-2652) [DOI: 10.11834/jrs.20221868]
- Song G, Huang J T, Ning B H, Wang J W and Zeng L. 2021. Effects of groundwater level on vegetation in the arid area of western China. *China Geology*, 4(3): 527-535 [DOI: 10.31035/cg2021062]
- Tawalbeh M, Al-Othman A, Kafiah F, Abdelsalam E, Almomani F and Alkasrawi M. 2021. Environmental impacts of solar photovoltaic systems: a critical review of recent progress and future outlook. *Science of the Total Environment*, 759: 143528 [DOI: 10.1016/j.scitotenv.2020.143528]
- Xia Z L, Li Y J, Chen R S, Sengupta D, Guo X N, Xiong B and Niu Y L. 2022a. Mapping the rapid development of photovoltaic power stations in northwestern China using remote sensing. *Energy Reports*, 8: 4117-4127 [DOI: 10.1016/j.egyr.2022.03.039]
- Xia Z L, Li Y J, Guo S C, Chen R S, Zhang W, Guo X N, Zhang X G and Du P J. 2024. Satellites reveal spatial heterogeneity in dryland photovoltaic plants' effects on vegetation dynamics. *Earth's Future*, 12(6): e2024EF004427 [DOI: 10.1029/2024EF004427]
- Xia Z L, Li Y J, Zhang W, Chen R S, Guo S C, Zhang P and Du P J. 2022b. Solar photovoltaic program helps turn deserts green in China: evidence from satellite monitoring. *Journal of Environmental*

- Management, 324: 116338 [DOI: 10.1016/j.jenvman.2022.116338]
- Xu Y and Lu L Z. 2023. Extracting 10-m resolution photovoltaic land-cover using a slightly modified U-Net and sentinel-2 images//2023 11th International Conference on Agro-Geoinformatics (Agro-Geo-informatics). Wuhan: IEEE: 1-5 [DOI: 10.1109/Agro-Geoinformatics59224.2023.10233594]
- Xu Z J, Li Y, Qin Y Z and Bach E. 2024. A global assessment of the effects of solar farms on albedo, vegetation, and land surface temperature using remote sensing. *Solar Energy*, 268: 112198 [DOI: 10.1016/j.solener.2023.112198]
- Yan Z Y, Wang P J, Xu F, Sun X and Diao W H. 2023. AIR-PV: a benchmark dataset for photovoltaic panel extraction in optical remote sensing imagery. *Science China Information Sciences*, 66(4): 140307 [DOI: 10.1007/s11432-022-3663-1]
- Yang K D, Li G Q and Lu X N. 2023. Effects of PV power stations on vegetation spatial aggregation in northwest China. *Solar Energy*, (10): 38-44 (杨凯迪, 李国庆, 卢潇楠. 2023. 中国西北地区光伏电站对植被空间聚集的影响. *太阳能*, (10): 38-44) [DOI: 10.19911/j.1003-0417.tyn20220806.01]
- Ying J, Li Z C, Yang L W, Jiang Y, Luo Y and Gao X Q. 2023. The characteristics and parameterizations of the surface albedo of a utility-scale photovoltaic plant in the Gobi Desert. *Theoretical and Applied Climatology*, 151(3/4): 1469-1481 [DOI: 10.1007/s00704-022-04337-5]
- Yu F Y, Cao J W, Li F Y and Li S J. 2023. Ground photovoltaic power station extraction considering object characteristics and carbon reduction benefit evaluation. *Journal of Geo-information Science*, 25(3): 529-545 (于方圆, 曹家玮, 李发源, 李思进. 2023. 顾及对象特征的地面式光伏电站提取及减碳效益评估. *地球信息科学学报*, 25(3): 529-545) [DOI: 10.12082/dqxxkx.2023.220680]
- Yuan W, Wang J and Xu W B. 2022. Shift pooling PSPNet: rethinking PSPNet for building extraction in remote sensing images from entire local feature pooling. *Remote Sensing*, 14(19): 4889 [DOI: 10.3390/rs14194889]
- Zhang C Y, Zhao L, Zhang H T, Chen M N, Fang R Y, Yao Y, Zhang Q P and Wang Q. 2022a. Spatial-temporal characteristics of carbon emissions from land use change in Yellow River Delta region, China. *Ecological Indicators*, 136: 108623 [DOI: 10.1016/j.ecolind.2022.108623]
- Zhang H, Hu Z Y, Zhang Z, Li Y M, Song S R and Chen X. 2024a. How does vegetation change under the warm-wet tendency across Xinjiang, China?. *International Journal of Applied Earth Observation and Geoinformation*, 127: 103664 [DOI: 10.1016/j.jag.2024.103664]
- Zhang N, Duan H B, Shan Y L, Miller T R, Yang J K and Bai X M. 2023. Booming solar energy is encroaching on cropland. *Nature Geoscience*, 16(11): 932-934 [DOI: 10.1038/s41561-023-01304-1]
- Zhang S Q, Gong J R, Zhang W Y, Dong X D, Hu Y X, Yang G S, Yan C Y, Liu Y Y, Wang R J, Zhang S P and Wang T. 2024b. Photovoltaic systems promote grassland restoration by coordinating water and nutrient uptake, transport and utilization. *Journal of Cleaner Production*, 447: 141437 [DOI: 10.1016/j.jclepro.2024.141437]
- Zhang X H, Xu M, Wang S J, Huang Y K and Xie Z Y. 2022b. Mapping photovoltaic power plants in China using Landsat, random forest, and Google Earth Engine. *Earth System Science Data*, 14(8): 3743-3755 [DOI: 10.5194/essd-14-3743-2022]
- Zhao H Y and Yin Z P. 2022. Remote sensing extraction of photovoltaic panels in desert areas based on feature optimization//2022 15th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI). Beijing: IEEE: 1-6 [DOI: 10.1109/CISP-BMEI56279.2022.9980307]
- Zhao Z Y, Chen Y H, Li K N, Ji W Z and Sun H. 2024. Extracting Photovoltaic panels from heterogeneous remote sensing images with spatial and spectral differences. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17: 5553-5564 [DOI: 10.1109/JSTARS.2024.3369660]

Deep Learning for photovoltaic station identification and its effect on vegetation spatial aggregation

QIAO Jiajia^{1,2,3}, YAN Min^{2,3}, LIU Yongqiang^{1,4}, ZHANG Li^{2,3}, WU YIN⁵,
CHEN Yiyang^{2,3}, SHAO Wei^{2,3}

1. College of Geography and Remote Sensing Sciences, Xinjiang University, Urumqi 830046, China;

2. International Research Center of Big Data for Sustainable Development Goals, Beijing 100094, China;

3. Key Laboratory of Digital Earth Science, Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100094, China;

4. Xinjiang Key Laboratory of Oasis Ecology, Xinjiang University, Urumqi 830046, China;

5. Xinjiang Uygur Autonomous Region Natural Resources Planning and Research Institute (Xinjiang Uygur Autonomous Region Real Estate Registration Center), Urumqi 830011, China

Abstract: Xinjiang Uygur Autonomous Region, endowed with abundant land and solar energy resources, has emerged as a national leader in terms of installed photovoltaic (PV) capacity, driven by the growing demand for renewable energy and advancements in PV technology.

Accurate, real-time identification of PV station distribution and quantitative analysis of its effects on the spatial aggregation of surrounding vegetation provide crucial data and informed decision-making support for PV siting in Xinjiang.

This study employs deep learning semantic segmentation models constructed by combining three architectures (UNet, pyramid scene parsing network, and DeepLabV3+) with four backbone networks (ResNet-34, ResNet-50, ResNet-101, and ResNet-152), as well as alternative DeepLabV3+ backbones including MobileNetV2, DarkNet53, VGG16, and DenseNet121 in different combinations. The objective is to determine the optimal model for PV station detection and map the spatial distribution of PV stations across Xinjiang. Global Moran's I values are calculated as a time series within buffer zones divided into equal intervals (ranging from 30 m to 600 m around the PV stations) to assess the effect of PV station construction on vegetation spatial aggregation.

Results reveal that (1) the UNet-ResNet50 model demonstrates superior performance in PV station recognition, achieving an accuracy of 98.64% (improvement of 0.09 percentage points), an F1 score of 95% (improvement of 0.4 percentage points), and an intersection over union value of 90.47% (improvement of 0.57 percentage points). These exceptional recognition capabilities are primarily attributable to the high accuracy of the PV sample set and the model's outstanding feature extraction and depth balancing abilities. (2) With Sentinel-2 remote sensing images and the UNet-ResNet50 model, the 2020 PV stations in Xinjiang are extracted and classified into vegetation-covered and bare-land PV stations, with area proportions of 30% and 70%, respectively. (3) Within different buffer zones ranging from 30 m to 210 m from a PV station, the Global Moran's I of vegetation shows a remarkable downward trend from 2012 to 2020. In the buffer zones 210–600 m from a PV station, decrease in the Global Moran's I of vegetation slows down substantially. The closer the location is to a PV station, the greater the influence on the spatial aggregation of vegetation is and the more evident the decrement in the time series is.

Therefore, remote sensing monitoring of PV stations and their surrounding buffer zones offers critical data and technical support for construction planning, precise operational management, and assessment of ecological effects associated with PV stations.

Key words: photovoltaic station, semantic segmentation model, vegetation spatial aggregation, Global Moran's Index

Supported by the Third Xinjiang Scientific Expedition Program (No. 2022xjkk1100)