

基于 GF-2 遥感影像和改进后 PSPNet 模型的 丘陵地区耕地图斑提取方法

颜玲¹, 李少达², 李彩瑛¹, 陈薇¹, 刘林¹, 宋承远¹,
杨莉¹, 吴若楚¹, 冉培廉^{1,2}

1. 四川省不动产登记中心, 成都 610072; 2. 成都理工大学 地球与行星科学学院, 成都 610059

[摘要] 针对丘陵地区耕地地块具有边界模糊、覆盖物种类多样、大小和空间位置分布不规则等特点, 传统分类方法难以快速准确提取耕地信息的问题, 本文以四川省金堂县竹篙镇和高板镇为研究区域, 利用高分二号卫星影像和改进后的 PSPNet 语义分割网络模型进行耕地图斑提取研究。在模型训练中, 引入 CBAM 注意力模块以提高整个网络的特征提取和表达能力, 采用余弦退火学习率以加快模型的收敛速度。结果表明, 改进后的 PSPNet 模型在丘陵地区耕地提取精度方面取得了显著提高, 耕地识别精度达到了 95.69%, 比标准 PSPNet 模型提高了 1.07%, 比 Unet++, DeepLabv3+ 和支持向量机方法方法提高了 1.32%, 1.75% 和 6.33%。基于改进后的 PSPNet 模型具有更强的特征提取和表达能力, 可以更准确地提取丘陵地区的耕地信息, 为农业决策提供更准确的数据支持, 促进农业智能化和精准化, 提高农作物产量和质量, 推动农业现代化进程。

[关键词] 丘陵耕地; PSPNet 模型; CBAM 注意力模块; 余弦退火学习率; GF-2 遥感影像

[分类号] P237

[文献标志码] A

Extracting patches of arable land in hilly areas based on GF-2 remote sensing images and an improved PSPNet model

YAN Ling¹, LI Shaoda², LI Caiying¹, CHEN Wei¹, LIU Lin¹,
SONG Chengyuan¹, YANG Li¹, WU Ruochu¹, RAN Peilian^{1,2}

1. Sichuan Sheng Budongchan Dengjizhongxin, Chengdu 610072, China;

2. College of Earth and Planetary Science, Chengdu University of Technology, Chengdu 610059, China

Abstract: Traditional methods of classification encounter challenges in extracting accurate and timely information on cultivated land in hilly areas owing to blurred boundaries, diverse forms of land cover,

[收稿日期] 2023-04-20。

[基金项目] 四川省自然资源科研项目(KJ-2022-19)。

[第一作者] 颜玲(1981—), 女, 高级工程师, 研究方向: 地理信息系统、资源环境遥感, E-mail: 270322960@qq.com。

[通信作者] 冉培廉(1994—), 男, 工程师, 研究方向: 资源环境遥感、InSAR 地质灾害防治, E-mail: ranpeilian@stu.cdut.edu.cn。

[引用格式] 颜玲, 李少达, 李彩瑛, 等, 2024. 基于 GF-2 遥感影像和改进后 PSPNet 模型的丘陵地区耕地图斑提取方法[J]. 成都理工大学学报(自然科学版), 51(2): 269-280.

Yan L, Li S D, Li C Y, et al., 2024. Extracting patches of arable land in hilly areas based on GF-2 remote sensing images and an improved PSPNet model[J]. Journal of Chengdu University of Technology (Science & Technology Edition), 51(2): 269-280.

and irregular spatial distribution in the relevant images. In this study, we used Zhugao Town and Gaoban Town in Jintang County of China as the objects of research, and proposed an improved model of the PSPNet semantic segmentation network to extract cultivated land patches from high-resolution satellite images of hilly areas taken by the GF-2 satellite. The CBAM attention module was introduced to the network to enhance its capabilities of feature extraction and expression during model training, and the cosine annealing learning rate was used to accelerate the convergence of the model. The results of tests showed that the improved PSPNet model could extract cultivated land from images of hilly areas with an overall accuracy of 95.69%, 1.07% higher than that of the standard PSPNet model, and 1.32%, 1.75% and 6.33% higher than the those of the models of semantic segmentation UNet++, DeepLabv3+, and the support vector machine, respectively. This showed that the improved PSPNet model had strong capabilities of feature extraction and expression that could be used to accurately identify cultivated land in hilly areas. This provided important support for decision-making in agriculture, promotes intelligence and precision in the field, and helped improve the yield and quality of crops.

Key words: cultivated land in hilly area; PSPNet model; CBAM attention module; cosine annealing learning rate; GF-2 remote sensing images

耕地红线是 14 亿中国人的粮食安全底线,但是随着工业化、城镇化进程加快,建设用地等地类需求增加,导致耕地大幅减少(李大庆, 2017)。2021 年第三次全国土地调查中,全国耕地总面积相较于上次全国土地调查结果减少了 11 285 万亩(1 亩 \approx 666.7 m²)。耕地面积减少严重影响了国家制定的 18 亿亩耕地红线政策目标的实现(于法稳等, 2022; 鄯文聚等, 2022; 胡海川和殷羽齐, 2023)。耕地红线承载着农业发展和农村现代化建设的根本,同时作为中国粮食安全的重要保障,耕地红线也具备着基础性和命脉性的特征(Rounsevell et al., 2005; Lu et al., 2017; Swinnen et al., 2017)。因此,为坚守基本的耕地红线,快速、有效地了解耕地现状,是实现盘活存量建设用地的基础,同时为相关部门保护耕地红线提供了重要的基础数据(Pfeffer and Lap-ping, 1994; Alterman, 1997)。

然而,鉴于各种类型作物的种植情况、灌溉方式和土壤类型的差异(Wietzke and Leuschner, 2020; Joanna, 2021; Tang et al., 2022),在遥感影像中用于提取不同类型耕地的光谱和纹理等特征的类内差异较大,而且同一类型耕地的光谱表现差异也很显著,这样就导致特征提取工作的难度增大,使得如何准确高效地提取耕地成为难点问题(Cao et al., 2016; Liu et al., 2019; Li et al., 2022; Sheng et al., 2022)。尤其是丘陵地区地形起伏较大,地块破碎度高,加之种植面积与地块边

界形状大小不一,这都给遥感耕地信息的准确提取带来了很大的挑战(He et al., 2021; 张海天等, 2022; He et al., 2022)。传统的遥感影像分类方法受分类器影响较大,通常只能学习到遥感影像浅层的特征,并且较为依赖人工对于地物特征的选取,严重影响分类结果的精度和准确性(Hu and Li, 2019; Su et al., 2020; Bofana et al., 2020; 范震等, 2022)。近年来,深度学习模型能够学习到较为深层次的特征且自动提取主要目标特征,也具有更好的鲁棒性,所以基于深度学习的遥感影像分类方法逐渐成为热点研究领域(Zhou et al., 2019; Zhou et al., 2020; Wang et al., 2020; 李倩楠等, 2023; 吕林涛等, 2023)。高分二号(GF-2)卫星作为中国自主研发的第一颗民用光学遥感卫星,其空间分辨率可达到 0.8 m,对中国的国土资源管理、环境监测等方面发挥了巨大作用。但是如何在高分辨率遥感影像分类和提取特征领域中应用深度学习模型也存在难点,其一在于高分二号遥感影像空间分辨率虽高,但数据量大、特征复杂,而深度学习模型在应用中需要大量的计算资源和时间。如何提高计算效率、缩短训练和测试时间是一大难点。其二在于高分辨率遥感影像场景多样,模型往往容易出现过拟合现象,即在训练集上表现良好,但在测试集上表现不佳。如何提高深度学习模型的泛化能力是第二大难点(张海东等, 2019; 蔡志文等, 2022; 习文强等, 2022)。近年来,众多研究使用深度学习模型进行

耕地地块提取(Wang et al., 2020),如马永建等(2021)基于深度学习方法对荒漠区耕地进行了持续性精确监测,使用高分一号影像提取不同类别耕地信息,利用 Unet 模型实现了耕地的分类和提取。所以充分发挥深度学习模型的特征提取能力来克服高分遥感影像中耕地提取的难点问题具有重要价值,同时针对丘陵地区深度学习模型的特征学习能力和泛化能力仍需要讨论(Zhou et al., 2019; Tulczyjew et al., 2022)。

为了探讨在复杂丘陵地区深度学习模型的遥感影像耕地地块信息提取及迁移能力,本文提出了一种针对丘陵地块信息提取的改进的 PSPNet 模型,来探讨其特征学习能力;最后,与其他深度语义分割 Unet 网络、Deeplabv3+ 模型,以及传统机器学习方法支持向量机(Support Vector Machine, SVM)的分类结果进行对比分析,以验证该方法的有效性和优越性。希望本文的研究能够为丘陵地区耕地地块信息的精确遥感监测提供一套高效可行的方法,推动中国高分辨率影像在农业领域的应用和研究。

1 研究区概况

本文以四川省金堂县为典型研究区,其中以竹篙镇作为模型训练区域,高板镇作为模型测试区域(图 1)。

四川省金堂县竹篙镇位于龙泉山脉以东,地形以丘陵为主,面积 71.65 km²,相对高差达 90 m。

该地属于亚热带气候,四季分明,温和湿润。春季,随着太阳高度角的升高和天空辐射能量的增加,气温逐渐升高,至 4 月下旬,气温回升明显,呈现出明显的回暖趋势。雨季在 7 月至 9 月之间,尤其是 8 月份降水最多。但结冰现象相对较少,霜期较短。年均降雨量为 815.66 mm,蒸发量为 541.6 mm,无霜期长达 300 天,平均气温为 17.1℃。日照充足,全年日照时数达到 1 250 h。土壤类型以成都黏土为主,具有较好的肥力和耕作条件。农业方面,该地区适宜水稻、小麦、玉米等作物的种植,近年来也逐渐向以蔬菜、杂柑、蚕桑等经济作物为主转变。该地区拥有得天独厚的自然条件和良好的土壤资源,为农业生产提供了重要的保障。

四川省金堂县高板镇位于成都平原东部,总面积为 49.44 km²,地形呈东北高西南低的趋势。该镇位于四川盆地西南缘,地质构造较为复杂,主要由四川盆地地下伏地层组成。镇内相对高差为 146 m,地势较为平缓,气候温暖湿润,雨量充沛。该地区的年平均气温为 17.2℃,年降雨量为 874.7 mm,相对湿度高达 80%,日照时数为 1 295.5 h,海拔高度在 480~515 m。该地区土壤以紫泥土为主,属于成都平原南缘丘陵区土壤类型,耕种条件较好。农业生产以水稻、小麦、玉米、水果为主,其中水稻是主要作物,占据了该地区农业生产的重要地位。近年来,随着农业产业结构的调整和发展,蔬菜、水果、杂柑、蚕桑等也逐步成为该地区农业生产的主要经济作物。

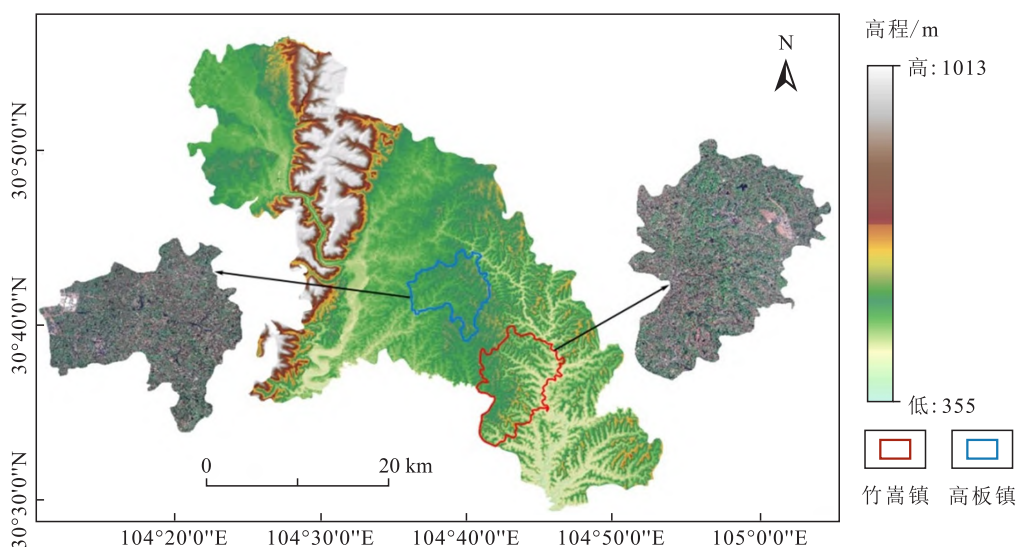


图 1 金堂县建模、预测区域选取

Fig. 1 The area of Jintang County that was modeled and used for predictions in this study

2 数据与研究方法

本研究从四川省典型丘陵区出发,选择了金堂县作为典型耕地提取区域。使用数据主要分为 3 个部分,第一部分为数据预处理,包括 GF-2 遥感影像的预处理。第二部分为深度学习模型的构建,包括样本库的构建和划分,模型训练和改进。此阶段以竹篙镇作为模型训练区域,高板镇作为模型测试区域。训练区域的样本用于模型的训练,通过专家目视解译制作耕地图斑样本,选择语义分割 PSPNet 模型,在模型架构中引入 CBAM 注意力模块,同时模型训练阶段使用余弦退火学

习率,得出最佳模型参数,将在训练测试阶段中得出的最佳模型参数迁移至金堂县高板镇,得到典型丘陵区金堂县高板镇解译图。第三部分为精度验证阶段,主要分为与其他分类方法进行比较分析以及野外验证。其流程如图 2 所示。

2.1 GF-2 遥感影像来源和预处理

高分二号卫星是中国自主研发的低轨道光学遥感卫星,利用 CS-L3000A 平台搭载一台全色相机和一台多光谱相机,其中全色相机能达到 0.8 m 的空间分辨率,多光谱相机能达到 3.2 m 的空间分辨率。GF-2 号遥感影像具有高空间分辨率、高定位精度、大幅宽,以及高整星姿态测摆机动能

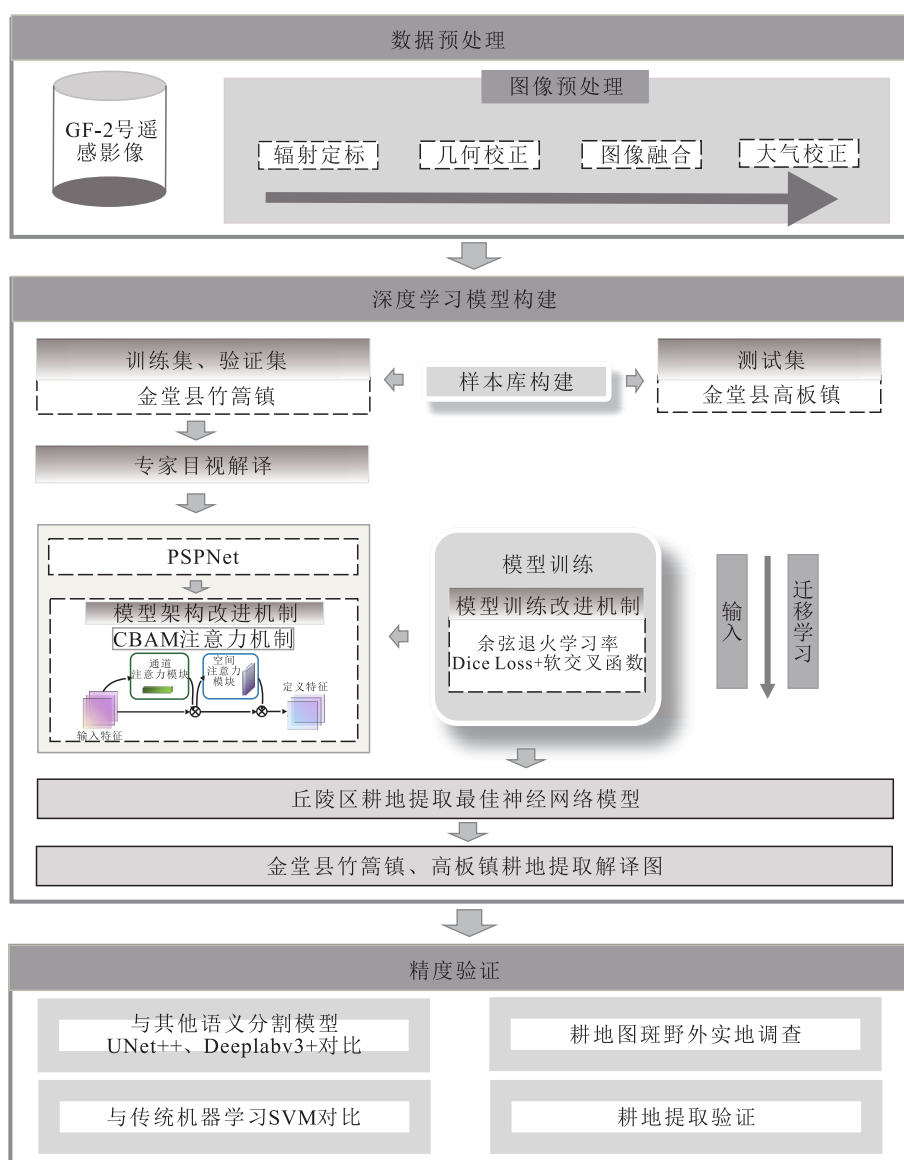


图 2 实验流程图

Fig. 2 Flowchart of the experimental procedure

力等特性,其性能达到国际前列。本研究所采用的 GF-2 卫星数据为 2021 年 3 月 27 日获取的 L1A 级 PMS1 产品,包含无云的多光谱和全色数据类型,其中多光谱数据包括 4 个波段(蓝、绿、红和近红外波段),空间分辨率为 4 m,而全色数据空间分辨率为 1 m。对 GF-2 卫星数据的预处理过程包括辐射定标、大气校正、正射校正和图像融合。其中,大气校正采用了 FLAASH 大气校正方法,可以有效去除大气影响。图像融合采用了 NNDifuse 数据融合算法,其响应函数重叠度较小。此外,NNDifuse 算法可以保持数据的纹理、色彩和光谱信息,使融合后影像的空间分辨率达到 1 m,能够更好地满足高分辨率遥感影像在实际应用中的需求。

2.2 样本库构建

深度学习网络进行耕地识别,需要使用已经标记好的样本数据进行网络训练。将金堂县竹篙镇按照 512×512 像素依次裁剪、分割成为若干图像,结合解译结果制作正、负样本。其中,正样本主要包括水田、水浇地以及旱地。负样本为非耕地图斑,主要包括水体、建筑物、道路、林地等。

同时,考虑到最终需要将训练好的模型迁移至金堂县高板镇进行滑坡识别,所以需要金堂县竹篙镇和高板镇两个镇的所有影像进行裁剪。本研究以 512×512 像素对整个研究区的 GF-2 号遥感影像进行裁剪,需制作竹篙镇正样本影像及标签(标记为 1)。

2.2.1 样本库的制作

精准的样本是深度学习模型训练的基础,本研究使用的标注方法为:①首先在 ArcGIS 10.2 中打开预处理好的原始遥感影像,建立 1 个面图层(.shp)文件。②矢量转栅格,用 C++ 利用 GDAL 库编实现矢量转栅格。③将.tif 格式转换为模型需要的.png 格式。由于设置好的训练样本像素是固定大小的,故可利用 Python 实现图像分割。将高分影像上获得的样本采样到与经由谷歌地球获取的多源遥感影像一致,对照 Google Earth 和高分二号卫星提供的历史遥感影像,通过目视解译进行详细的边界勾绘,从而得到样本数据集。为了确保数据集的多样性,耕地样本图斑的训练测试集有 6 149 个样本,其面积达到 $45\,328\,394.22\text{ m}^2$,金堂县竹篙镇耕地解译结果如图 3 所示。




图 3 金堂县竹篙镇耕地解译结果

Fig. 3 Results of decoding of cultivated land in Zhugao Town, Jintang County

2.2.2 数据集划分

深度学习模型的样本库需要划分为训练样本数据集、验证样本数据集和测试样本集。将金堂县竹篙镇的样本数据集按照 7 : 3 的比例划分为训练样本数据集、验证样本数据集,其中训练样本用于训练模型,验证样本用于选择模型最优参数;金堂县高板镇为测试集,用于最终评估模型性能。

2.3 改进的 PSPNet 模型

PSPNet(pyramid scene parsing network)是通过全局均值池化操作和特征融合来引入周围的信息帮助学习目标特征,其效果明显优于其他卷积神经网络。PSPNet 使用的特征提取网络为 ResNet50。残差网络是在 2015 年提出的,在模型结构上具有里程碑的意义,残差网络将模型的深度从 20 层推向了上千层,在设计网络深度时,一般网络越深,提取的特征越多,模型的性能越好。但网络深度具有饱和性,达到一定深度后,模型的性能反而会下降,此时残差连接对于深度学习网络的设计具有重要意义。残差网络是由残差块堆叠而成,残差块的基本结构如图 4 所示。

改进的 PSPNet 模型在原始 PSPNet 模型的特征提取阶段引入注意力机制。注意力机制是一种特征选择的过程,通过将注意力转移到与目标最相关的特征,并忽略不相关部分,从而促

进整个网络的特征提取和表达能力,达到高效分析和理解复杂场景的效果。CBAM 注意力模

块(convolutional block attention module)不单是关注特征与通道之间的关系,同时关注通道维度和空间维度上的特征信息,这与普通的 SE 通道注意力模块不同。CBAM 注意力模块在结构上包括了 CAM(channel attention model)通道注意模块和 SAM(spatial attention model)空间注意模块 2 个子模块(图 5)。




图 4 残差单元结构

Fig. 4 Residual cell structure

通道注意力模块(channel attention model, 简称为 CAM)用来寻找最为关键的学习特征,空间注意力模块(spatial attention model, 简称为 SAM)用来学习关键特征的位置信息,并自适应地完善特征。如图 6 所示。

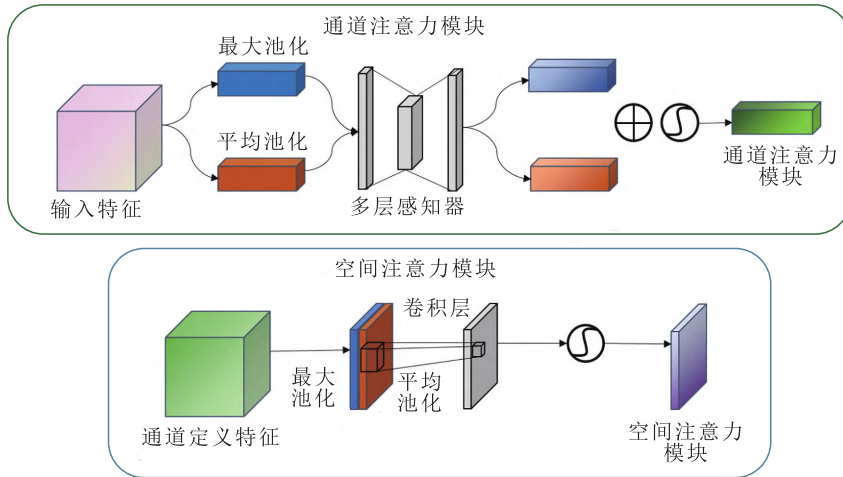


图 5 注意力机制示意图

Fig. 5 Attention mechanism




图 6 CBAM 模型结构示意图(Woo et al., 2018)

Fig. 6 Schematic diagram of the CBAM model

CAM 和 SAM 2 个模块以“串联”的形式构成 CBAM 模型,具体结构如图 6 所示。CAM 关注不同通道特征图之间的权重,同时关注权重值大的信息,用来寻找到最为关键的学习特征; SAM 用来学习关键特征的位置信息,它采用的方法是对不同空间位置信息给予对应的权重。这样网络可以根据权重分布来学习对图像分类有用的

空间位置信息,提高判别特征的表现力。其整体结构如图 7 所示。

在改进的 PSPNet 模型结构(图 7)中,首先将 GF-2 号遥感影像输入至 ResNet50 网络中进行特征提取,在此网络中使用了 ResBlock 和 CBAM 注意力模块。之后将 ResNet50 网络中提取到的特征图作为金字塔池化模块的输入。

该金字塔池化模块通过不同尺寸的特征池化操作学习到多尺度的特征,构建了尺度分别为 $1 \times 1, 2 \times 2, 3 \times 3, 6 \times 6$ 的 4 个特征金字塔。随后通过 1×1 的卷积将得到的各个尺度的特征通道数缩小到原来的 25%,再将维度用双线性插值方式上采样到输入特征相同大小,最后和输入特征做合并操作,其目的是融合提取的细

节特征和全局特征以学习到更多的特征。在改进的 PSPNet 在特征提取阶段也一样采用到了带有空洞卷积的 ResNet50 结构,在 FCN, UNet 等编码—解码模型中都采用卷积与池化堆叠的下采样方式来完成特征提取,再通过反卷积或者插值方式完成上采样,将特征图还原到输入的大小。

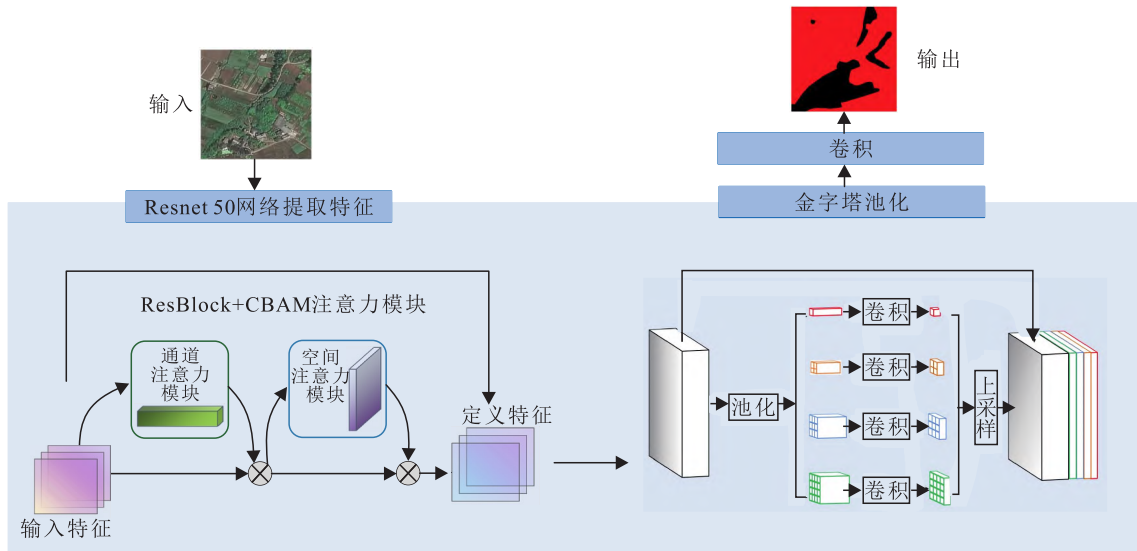


图 7 改进的 PSPNet 模型结构
Fig. 7 Improved PSPNet model

同时,本文使用余弦退火学习率替换了 PSPNet 模型中固定常数的学习率。与原始模型的网络架构相比,余弦退火学习率随着迭代次数的增加,先极速下降,之后突然上升,然后不断重复这个过程,目的是为了逃离局部最优点,有利于加快模型的收敛速度并获得最佳模型效果,其公式为:

$$\eta_t = \eta_{m,\min} + 0.5(\eta_{m,\max} - \eta_{m,\min}) \left(1 + \cos\left(\frac{T_{\text{cur}}}{T_m}\right) \right) \quad (1)$$

式中, η_t 表示余弦退火学习率; $\eta_{m,\min}$ 为第 n 次运行的学习率的最小值; m 为运行的索引值; $\eta_{m,\max}$ 和 $\eta_{m,\min}$ 和分别为第 m 次运行的学习率的最大值和最小值,定义了学习率的范围; T_{cur} 则表示当前执行的迭代次数的数量,在每个批处理运行之后就会更新; T_m 表示第 m 次运行中的总迭代次数。

2.4 运行环境与精度评价

本研究中深度学习运行硬件环境为:GPU 选择 NVIDIA GeForce RTX 2080Ti,显存大小为 12 GB,拥有 4 352 个计算单元,能够很好地保证不同卷积神经网络的运行。CPU 号为 Intel Xeon

E5-2680 v3,其拥有 12 核心 24 线程的硬件规格以及 2.5 GHz 的 CPU 主频;软件方面,深度学习架构为 PyTorch。具体配置如表 1 所示。

表 1 平台配置

Table 1 Platform

硬件名称	参数
CPU	Intel Xeon E5-2680 v3
GPU	NVIDIA GeForce RTX 2080Ti
运行内存	256 GB
总显存	60 GB
深度学习架构	PyTorch

此外,本研究选取 Unet++, Deeplabv3+ 和机器学习 SVM 来进行分类精度结果评价对比,同时验证模型的泛化性能。Unet 网络架构包含 4 次下采样与 4 次上采样,选取交叉熵损失函数,对小样本数据集进行有效分割,并能够有效增强模型的泛化性能。SVM 是一种二分类模型,基本思想为求解能够正确划分训练数据集并且集合间隔最大的分离超平面。SVM 类型为 C-SVC(C-support vector classification),核函数类型为

RBF(radial basis function)函数。Unet++和Unet采用余弦退火学习率,损失函数为SGD,初始设置迭代次数为200次,初始学习率为0.0001。

精度评价采用精确度(Precision)、召回率(Recall)、F1分数、总体精度(Overall Accuracy, OA)、MIoU(Mean Intersection over Union)以及IoU(Intersection over Union)作为分类结果精度评价指标。

$$P = \frac{TP}{TP + FP} \tag{2}$$

$$R = \frac{TP}{TP + FN} \tag{3}$$

$$F1 = 2 \times \frac{P \times R}{P + R} \tag{4}$$

$$OA = \frac{TP + TN}{TP + TN + FP + FN} \tag{5}$$

$$MIoU = \frac{1}{k + 1} \sum_{i=0}^k \frac{TP}{FN + FP + TP} \tag{6}$$

$$IoU = \frac{1}{\sum_{i=0}^k \sum_{j=0}^k FP + \sum_{i=0}^k FN - TN} \tag{7}$$

式中, k 为样本数量; TP 为正确划分的正样本; TN 为正确划分的负样本; FP 为错误划分的正样本; FN 为错误划分的负样本。

3 结果与分析

3.1 改进的PSPNet模型训练结果

改进PSPNet引入注意力机制的同时,将学

习率改为余弦退火学习率,初始设置迭代次数为200次,初始学习率为0.0001,如果精度20个Epoch不提高会提前停止。标准的PSPNet和改进的PSPNet训练过程中Loss值如图8所示。

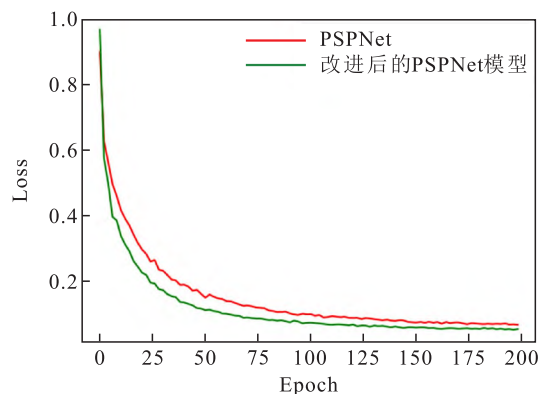


图8 金堂县竹篙镇改进后的PSPNet模型的训练过程
Fig.8 Training of the improved PSPNet model on data from Zhugao Town, Jintang County

从图8中可以看出,在训练了200个Epoch后,标准的PSPNet和改进后的PSPNet模型在训练过程的损失值都呈下降趋势,在进行第175次迭代时趋于平缓,获取到最佳模型结果,其中2种模型的Loss分别为0.0678和0.0548。相比之下,改进之后的Loss值降低了0.013,且改进后的PSPNet模型比标准的PSPNet模型收敛的速度更快,说明改进后的PSPNet模型精度会有所提升。改进后PSPNet模型和PSPNet模型的训练精度,如表2所示。

表2 金堂县竹篙镇改进后的PSPNet模型训练精度(%)

Table 2 Accuracy of training of the improved PSPNet model on data from Zhugao Town, Jintang county(%)

模型	精确度	召回率	F1	OA	MIoU	IoU(耕地)
标准PSPNet	92.10	93.77	93.87	94.62	88.52	84.69
改进PSPNet	93.58	95.03	95.08	95.69	90.68	87.55

从上表可以看出,典型浅丘区金堂县竹篙镇经过改进模型之后训练精度可以达到OA值95.69%,改进后精确度值低于召回率值,说明改进后的PSPNet模型仍然存在误分耕地图斑的现象,但此现象少于漏分耕地图斑的现象。改进后F1值提升至95.08%,提高了1.21%,而针对耕地的IoU也提升至87.55%,提高了2.86%,说明改进后的模型主要提升了耕地的识别精确率。

3.2 分类结果对比与分析

3.2.1 分类结果

将改进后的PSPNet模型的最佳权重保留,将金堂县高板镇高分二号影像输入模型中,得到典型浅丘区域金堂县高板镇耕地预测图。如图9所示。

3.2.2 对比分析

将训练集(金堂县竹篙镇)的样本数据和高分二号影像分别输入Unet++,DeepLabv3+两个

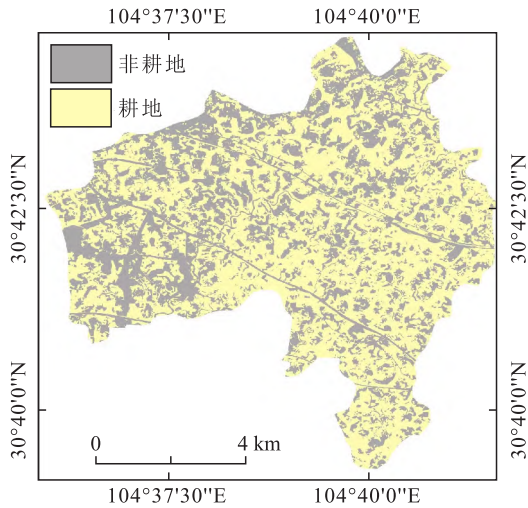


图 9 金堂县高板镇耕地预测图
 Fig. 9 Map forecasting arable land in Gaoban Town, Jintang County

模型中,以便对比实验结果。实验中初始设置迭代次数为 200 次,初始学习率为 0.000 1,如果精度在前 20 个 Epoch 内不提高,则模型迭代训练会提前停止。同时,本研究也设置了与传统机器学习 SVM 的对比实验,SVM 在 ENVI 5.3 软件中完成监督分类,其模型的训练精度如表 3 所示。

由表 3 可知,针对金堂县竹篙镇模型训练中,改进后的 PSPNet 训练精度最高,其次是标准 PSPNet,Unet++,DeepLabv3+,精度最低的是 SVM。从评价指标来看,MIoU 和 IoU 指标分别比 SVM,Unet++ 和 DeepLabv3+ 高 11.57%,2.65%,3.52%,14.33%,3.5% 和 4.65%。将每个模型的最佳权重保留,将金堂县高板镇高分二号影像输入各个模型中,得到典型浅丘区域金堂县高板镇耕地预测图,其对比结果如图 10 所示。

表 3 Unet++,PSPNet,DeepLabv3+,SVM 模型训练精度 (%)

Table 3 Accuracies of training of UNet++,PSPNet,DeepLabv3+,and SVM models(%)

深度学习模型	精确度	召回率	F1	OA	MIoU	IoU(耕地)
SVM	80.28	89.27	84.54	89.36	79.11	73.22
Unet++	91.59	93.53	93.59	94.37	88.03	84.05
DeepLabv3+	91.14	92.96	93.08	93.94	87.16	82.90
改进后的 PSPNet	93.58	95.03	95.08	95.69	90.68	87.55




图 10 部分区域分类结果对比图
 Fig. 10 Some comparative results of region classification

从耕地提取结果(图 10)来看,深度学习模型在金堂县竹篙镇耕地提取中的表现都优于 SVM 模型。SVM 提取结果最为破碎,与标签差距最

大。从区域内模型的耕地提取效果看,改进后的 PSPNet 模型最接近标签,从区域 1,2 中可以看出,Unet++,DeepLabv3++ 和标准的 PSPNet

都存在破碎小块;从区域 3,4 中可以看出,非耕地中光谱与耕地相近且形状较为规则的地物(如绿化带等)被误分为耕地,或者部分耕地旁的房屋与耕地(旱地)会形成边界不清晰的情况。而本研究改进的 PSPNet 模型对出现的识别误差具有一定的改善效果,这说明本文提出的改进的 PSPNet 模型在一定程度上提升了丘陵地区耕地识别的准确性。

3.3 野外验证

为了验证金堂县高板镇(测试集)的精度,使用野外实证的方式对分类结果进行验证。从金堂县高板镇耕地预测图(图 9)中选取 56 个耕地点,野外验证点应尽可能均匀分布于全区,且较容易到达。高板镇野外验证点分布如图 11 所示。

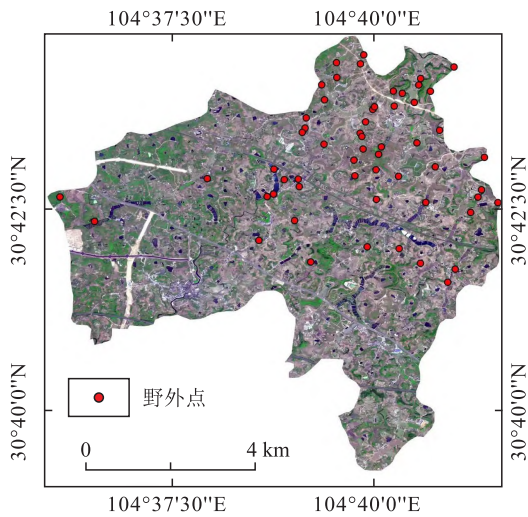


图 11 金堂县高板镇野外实证点分布
Fig. 11 Distribution of sites of field evidence in Gaoban Town, Jintang County

通过野外打点和实地拍照可知,本文选取的所有野外验证点均为耕地,这说明本研究提出的模型能够在一定程度上满足耕地信息的高效提取。

4 结论

本文选取 GF-2 遥感影像对丘陵地区耕地地块进行快速提取,以金堂县竹篙镇为模型训练区域,高板镇作为模型测试区域。通过专家目视解译制作耕地图斑样本,选择语义分割 PSPNet 模型,在模型架构中引入 CBAM 注意力模块,同时模型训练阶段使用余弦退火学习率,得出最佳模型参数,将在训练测试阶段中得出的最佳模型参

数迁移至金堂县高板镇,得到典型丘陵区域金堂县高板镇解译图。同时与传统的遥感影像分类方法进行比较分析,得出以下结论:

a. 采用改进后的 PSPNet 模型对研究区耕地类型进行提取,其模型精度可达 95.69%。表明借助深度学习的方法可有效挖掘高分辨率遥感影像耕地地块特征,能实现丘陵地区耕地提取。

b. 引入 CBAM 注意力模块的改进后 PSPNet,能提高整个网络的特征提取和表达能力,比标准 PSPNet 模型提高了 1.07%,可一定程度上提升对研究区耕地的判别准确度,减少误分现象;同时在模型训练阶段,使用余弦退火学习率,能够提高模型的收敛速度。

c. 改进后的 PSPNet 的 MIoU 和 IoU 指标也分别比 SVM, Unet++ 和 DeepLabv3+ 高 11.57%, 2.65% 和 3.52%, 14.33%, 3.5% 和 4.65%。针对非耕地中光谱与耕地相近且形状较为规则的地物(如绿化带等)误分为耕地,或者部分耕地旁的房屋与耕地(旱地)会形成边界不清晰的情况,改进的 PSPNet 模型纠正了部分识别误差,这说明本文提出的改进的 PSPNet 模型在能够有效提升丘陵地区耕地识别的准确性。

[参 考 文 献]

蔡志文,何真,王文静,等,2022. 基于多源国产高分卫星时空信息的米级分辨率耕地提取[J]. 遥感学报, 26(7):1368-1382.

Cai Z W, He Z, Wang W J, et al., 2022. Mapping cropland at metric resolution using the spatiotemporal information from multi-source GF satellite data[J]. National Remote Sensing Bulletin, 26(7):1368-1382. (in Chinese)

范震,乔梓,李栋梁,等,2022. 基于随机森林方法的遥感影像耕地提取与变化分析[J]. 安徽农学通报, 28(10):116-119.

Fan Z, Qiao Z, Li D L, et al., 2022. Extraction and change analysis of cultivated land from remote sensing images based on random forest method[J]. Anhui Agriculture Science Bulletin, 28(10):116-119. (in Chinese)

胡海川,殷羽齐,2023. 粮食安全战略下耕地生态补偿机制与实施路径研究[J]. 农业经济, (1):96-98.

李大庆,2017. 中国优质耕地减少[J]. 黑龙江粮食, (6): 50.

李倩楠,张杜娟,潘耀忠,等,2023. MPSPNet 和 UNet 网

- 络下山东省高分辨耕地遥感提取[J]. 遥感学报, 27(2):471-491.
- Li Q N, Zhang D J, Pan Y Z, *et al.*, 2023. High-resolution cropland extraction in Shandong Province using MP-SPNet and UNet network[J]. National Remote Sensing Bulletin, 27(2):471-491. (in Chinese)
- 吕林涛, 姚建华, 黄涛, 等, 2023. 基于深度学习的遥感影像耕地提取[J]. 数字技术与应用, 41(2):98-100.
- 马永建, 汪传建, 赵庆展, 等, 2021. 基于 GF-1 遥感影像的荒漠区耕地分类与提取方法[J]. 石河子大学学报(自然科学版), 39(3):383-390.
- Ma Y J, Wang C J, Zhao Q Z, *et al.*, 2021. Study on extraction of cultivated land in desert area with GF-1 remote sensing image based on U-Net model [J]. Journal of Shihezi University (Natural Science), 39(3):383-390. (in Chinese)
- 习文强, 杜世宏, 杜守基, 2022. 多时相耕地覆盖提取和变化分析:一种结合遥感和空间统计的时空上下文方法[J]. 地球信息科学学报, 24(2):310-325.
- Xi W Q, Du S H, Du S J, 2022. Multi-temporal cultivated land cover extraction and change analysis: A spatio-temporal context method combining remote sensing and spatial statistics[J]. Journal of Geo-information Science, 24(2):310-325. (in Chinese)
- 郎文聚, 汤怀志, 桑玲玲, 等, 2022. 发展耕地保护思想建设耕地资源强国[J]. 中国农业综合开发, (12):4-6.
- 于法稳, 代明慧, 林珊, 2022. 基于粮食安全底线思维的耕地保护:现状、困境及对策[J]. 经济纵横, (12):9-16.
- Yu F W, Dai M H, Lin S, 2022. Cultivated land protection based on bottom line thinking of food security: Current situation, difficulties and countermeasures[J]. Economic Review Journal, (12):9-16. (in Chinese)
- 张海东, 田婷, 张青, 等, 2019. 基于 GF-1 影像的耕地地块破碎区水稻遥感提取[J]. 遥感技术与应用, 34(4):785-792.
- Zhang H D, Tian T, Zhang Q, *et al.*, 2019. Study on extraction of paddy rice planting area in low fragmented regions based on GF-1 WFV images [J]. Remote Sensing Technology and Applications, 34(4):785-792. (in Chinese)
- 张海天, 高懋芳, 任超, 2022. 基于改进 Unet++ 的丘陵地区耕地地块深度分割与提取[J]. 航天返回与遥感, 43(4):36-45.
- Zhang H T, Gao M F, Ren C, 2022. Deep segmentation and extraction of cultivated land in hilly areas based on improved Unet++ [J]. Spacecraft Recovery and Remote Sensing, 43(4):36-45. (in Chinese)
- Alterman R, 1997. The challenge of farmland preservation: Lessons from a six-nation comparison[J]. Journal of the American Planning Association, 63(2):220-243.
- Bofana J, Zhang M, Nabil M, *et al.*, 2020. Comparison of different cropland classification methods under diversified agroecological conditions in the Zambezi River Basin[J]. Remote Sensing, 12(13):2096.
- Cao X, Chen X H, Zhang W W, *et al.*, 2016. Global cultivated land mapping at 30 m spatial resolution[J]. Science China Earth Sciences, 59(12):2275-2284.
- He S, Shao H Y, Xian W, *et al.*, 2021. Extraction of abandoned land in hilly areas based on the spatio-temporal fusion of multi-source remote sensing images[J]. Remote Sensing, 13(19):3956.
- He S, Shao H Y, Xian W, *et al.*, 2022. Monitoring cropland abandonment in hilly areas with Sentinel-1 and Sentinel-2 timeseries [J]. Remote Sensing, 14(15):3806.
- Hu X, Li X J, 2019. Information extraction of subsided cultivated land in high-groundwater-level coal mines based on unmanned aerial vehicle visible bands[J]. Environmental Earth Sciences, 78(14):1-11.
- Joanna P, 2021. Review on multitemporal classification methods of satellite images for crop and arable land recognition[J]. Agriculture Basel, 11(10):999.
- Li Z Q, Chen S B, Meng X Y, *et al.*, 2022. Full convolution neural network combined with contextual feature representation for cropland extraction from high-resolution remote sensing images[J]. Remote Sensing, 14(9):2157.
- Liu J G, Shang J L, Qian B D, *et al.*, 2019. Crop yield estimation using time-series MODIS data and the effects of cropland masks in Ontario, Canada [J]. Remote Sensing, 11(20):2419.
- Lu H, Fu X, Liu C, *et al.*, 2017. Cultivated land information extraction in UAV imagery based on deep convolutional neural network and transfer learning [J]. Journal of Mountain Science, 14(4):731-741.
- Pfeffer M J, Lapping M B, 1994. Farmland preservation, development rights and the theory of the growth machine: The views of planners [J]. Journal of Rural Studies, 10(3):233-248.
- Rounsevell M D, Ewert F, Reginster I, *et al.*, 2005. Future scenarios of European agricultural land use[J]. Agriculture Ecosystems & Environment, 107(2-3):

- 117—135.
- Sheng J J, Sun Y Q, Huang H, *et al.*, 2022. HBRNet: Boundary enhancement segmentation network for cropland extraction in high-resolution remote sensing images[J]. *Agriculture Basel*, 12(8):1284.
- Su T F, Zhang S W, Tian Y N, 2020. Extracting croplands in western Inner Mongolia by using random forest and temporal feature selection[J]. *Journal of Spatial Science*, 65(3):519—537.
- Swinnen J, Burkitbayeva S, Schierhorn F, *et al.*, 2017. Production potential in the “bread baskets” of Eastern Europe and Central Asia[J]. *Global Food Security*, 14:38—53.
- Tang J, Zhang X Y, Chen Z C, *et al.*, 2022. Crop identification and analysis in typical cultivated areas of Inner Mongolia with single-phase Sentinel-2 images [J]. *Sustainability*, 14(19):12789.
- Tulczyjew L, Kawulok M, Longepe N, *et al.*, 2022. Graph neural networks extract high-resolution cultivated land maps from Sentinel-2 image series[J]. *IEEE Geoscience and Remote Sensing Letters*, 19.
- Wang Z Y, Zhou J H, Liao Z H, *et al.*, 2020. Semantic segmentation of track image based on deep neural network[J]. *The Journal of China Universities of Posts and Telecommunications*, 27(5):23—33.
- Wietzke A, Leuschner C, 2020. Surveying the arable plant diversity of conventionally managed farmland: A comparison of methods [J]. *Environmental Monitoring and Assessment*, 192(2):1—15.
- Woo S, Park J, Lee J Y, *et al.*, 2018. Cbam: Convolutional block attention module[C]//Proceedings of the European conference on computer vision (ECCV). Munich: Springer Nature Switzerland, 3—19.
- Zhou J C, Hao M L, Zhang D H, *et al.*, 2019. Fusion PSP-net image segmentation based method for multi-focus image fusion [J]. *IEEE Photonics Journal*, 11(6):1—12.
- Zhou Z W, Siddiquee M, Tajbakhsh N, *et al.*, 2020. UNet plus plus: Redesigning skip connections to exploit multiscale features in image segmentation[J]. *IEEE Transactions on Medical Imaging*, 39(6):1856—1867.

(责任编辑:甘娟娟)



(上接第 268 页)

- Zhang L L, Cheng H, Yao Z S, *et al.*, 2023. Prediction of maximum surface subsidence velocity based on improved Knothe time model[J]. *Rock and Soil Mechanics*, 44(4):1111—1119. (in Chinese)
- 中华人民共和国住房和城乡建设部, 2011. 建筑地基基础设计规范: GB 50007—2011[S]. 北京: 中国建筑工业出版社.
- Ministry of Housing and Urban-Rural Development of the People's Republic of China, 2011. Code for design of building foundation: GB 50007—2011 [S]. Beijing: China Construction Industry Press.
- Azzouz A S, Krizek R J, Corotis R B, 1976. Regression analysis of soil compressibility[J]. *Soils and Foundations*, 16(2):19—29.
- Giasi I C, Cherubini C, Paccapelo F, 2003. Evaluation of compression index of remoulded clays by means of Atterberg limits[J]. *Bulletin of Engineering Geology and the Environment*, 62(4):333—340.
- Sridharan A, Nagaraj H B, 2000. Compressibility behaviour of remoulded, fine-grained soils and correlation with index properties [J]. *Canadian Geotechnical Journal*, 37(3):712—722.
- Zhang D M, Zhang J Z, Huang H W, *et al.*, 2020. Machine learning-based prediction of soil compression modulus with application of 1D settlement[J]. *Journal of Zhejiang University-Science A (Applied Physics & Engineering)*, 21(6):430—444.

(责任编辑:甘娟娟)