doi:10.6041/j.issn.1000-1298.2023.12.016

基于改进半监督模型的空间异质性农田特征提取研究

陈　理[1,2]　韩　毅[1,2]　杨　广[1,2]　赖有春[1,2]　郑永军[1]　周宇光[1,2]
(1.中国农业大学工学院, 北京 100083; 2.农业农村部可再生能源清洁化利用技术重点实验室, 北京 100083)

摘要: 提取农田信息对智慧农业、环境保护等有重要意义。监督学习模型对不同地貌、区域、种植类型等空间异质性农田的特征提取效果不佳。针对该问题,本文提出一种半监督学习模型,该模型使用基于加权损失函数的在线难例样本挖掘策略,在 Vaihingen 数据集中总体精度高达 87.1%,相较于其他半监督学习模型的提取效果最好。在吉林一号农田影像数据集进行空间异质性农田特征提取中的对比试验和精度评估,结果表明:分别使用拟提取地区和训练集地区的无标注影像训练该模型,均可提高对空间异质性农田特征提取精度,若无标注影像与拟提取地区影像中农田特征相似度高,总体精度可提升 2.1~6.1 个百分点,总体精度最高可达 84.0%。该模型使用更少量的标注信息获得媲美监督学习模型的提取效果;而使用相同量的标注信息,可以通过增加无标注影像以取得比监督学习模型更好的提取效果。本文构建河北献县地区的农田数据集,模型使用吉林一号农田影像数据集(部分 1)作为有标注训练集,吉林一号农田影像数据集(部分 2)和献县地区高分二号影像数据集作为无标注影像训练后的总体精度高达 88.7%。验证了改进后的半监督学习模型可准确有效提取空间异质性农田特征。

关键词: 农田特征提取; 语义分割; 半监督学习; 空间异质性农田; 遥感影像
中图分类号: TP753　　**文献标识码**: A　　**文章编号**: 1000-1298(2023)12-0173-13　　**OSID**:

Spatially Heterogeneous Cropland Characteristic Extraction Based on Improved Semi-supervised Models

CHEN Li[1,2]　HAN Yi[1,2]　YANG Guang[1,2]　LAI Youchun[1,2]　ZHENG Yongjun[1]　ZHOU Yuguang[1,2]
(1. *College of Engineering*, *China Agricultural University*, *Beijing* 100083, *China*
2. *Key Laboratory of Clean Production and Utilization of Renewable Energy*, *Ministry of Agriculture and Rural Affairs*, *Beijing* 100083, *China*)

Abstract: Extracting cropland accurately and efficiently from high-resolution remote sensing images is of great significance to agricultural production and agricultural resource investigation. Cropland with different areas, ground covers and cultivation types in remote sensing images have large differences in features, whereas the insufficient generalization ability of traditional supervised learning models also leads to poor extraction of heterogeneous cropland with the above features. To solve this problem, the semi-supervised semantic segmentation with mutual knowledge distillation (SSS-MKD) model as the base model and incorporated an online hard example mining strategy based on a weighted loss function. The proposed model was evaluated on the Vaihingen dataset and achieved the highest overall accuracy of 87.1% and an average F1 score of 85.0%, The model had the best extraction accuracy compared with other semi-supervised models. In addition, for the task of large-area cropland extraction, the feature information of the unannotated images that were heterogeneous and homogeneous with the annotated images were added to the training of the semi-supervised learning model by designing two sets of experiments using Jilin-1 cropland image dataset, respectively, in order to improve the cropland extraction accuracy in the proposed extraction area. The experimental results showed that the proposed model could achieve the highest overall accuracy of 84.0% by using the cropland images to be extracted for assisted training. In addition, by using unlabeled images with strong similarity to the cropland in the target region, the overall accuracy could be further improved by 2.1~6.1 percentage points. The

收稿日期: 2023-07-01　修回日期: 2023-08-28
基金项目: 科技部创新方法工作专项项目(2020IM020901)
作者简介: 陈理(1971—),女,副教授,主要从事农业遥感图像处理研究,E-mail: chenli329@cau.edu.cn
通信作者: 周宇光(1983—),男,副教授,博士生导师,主要从事农业废弃物资源化利用研究,E-mail: zhouyg@cau.edu.cn

maximum overall accuracy achieved using unlabeled images with strong similarity to the cropland features in the training set was 81.6%, which was 6.6 ~ 8.5 percentage points higher than the accuracy achieved by using conventional supervised learning. Taking Xian County area in Hebei Province as an example, the model used the Jilin - 1 cropland image dataset (part 1) as the labeled training set, and achieved the highest accuracy of 88.7% overall accuracy after training with both the Jilin - 1 cropland image dataset (part 2) and the unlabeled images from the Xian County area's Gaofen - 2 image dataset, compared with the extraction accuracy by using these two datasets alone and without the unlabeled images, respectively 1.0 percentage points, 4.9 percentage points, and 8.1 percentage points. Under the realistic background of abundant cropland remote sensing data and insufficient corresponding labeled information. The semi-supervised model learned the feature information in the images of cultivated land in the proposed extraction area and the training set area, and improved the extraction accuracy of heterogeneous cultivated land. A method that maximized the learning of heterogeneous cropland unlabeled images and a minimum amount of labeled data using a semi-supervised learning model for the task of wide-area cropland extraction was proposed, and the extraction results were effective.

Key words: cropland characteristic extraction; semantic segmentation; semi-supervised learning; spatially heterogeneous cropland; remote sensing image

0 引言

及时准确获取到的农业信息是国家制定农业政策的重要依据,对确保粮食安全具有重要意义[1-2]。准确高效地提取农田信息是“十四五”时期农业农村信息化发展的主攻方向之一,对农业产业结构优化、环境保护和数字农业等领域起积极作用。随着遥感影像数据量增加、地物的视觉特征逐渐精细,利用遥感影像提取农田信息已成为主流方法之一[3-4]。

我国幅员辽阔,空间异质性农田在遥感影像中呈现出不同形状、颜色、纹理和地形地貌等特征,信息差异大[5]。现有数据集无法覆盖到全部环境下的农田,导致监督学习模型的泛化能力不足且难取得较高的提取精度,因此精准高效地提取空间异质性农田特征信息受到国内外学者普遍关注,使用迁移学习对农田特征研究取得较大进展[6]。陈理等[7]通过对 ILSVRC 数据集和 Cityscapes 数据集进行预训练,再经过迁移学习后提取到的农田和田间道路的 mIoU 可达 85% 和 95%。鲁恒等[8]从无人机影像提取线状及非线状地物特征向耕地特征迁移,保证了耕地提取结果的完整和连续性。杨思琦[9]使用多个数据集预训练后的 VGGNet 模型,对北京和山西分别进行迁移学习,可以保持良好图像场景分类效果。张书瑜[10]使用浙江省不同地区的高分二号遥感影像进行迁移学习,绝大部分样本高于未迁移学习的源域模型分类精度,证明了所提出方法的有效性。

以上迁移学习仍需使用拟提取地区的农田标注信息训练模型,而半监督学习通过将无标注数据与标注数据一起训练模型,学习无标注影像中的特征信息以获得高精准度的分割结果。半监督学习模型主要分为一致性正则化方法(Consistency regularization)[11-13]和伪标签方法(Pseudo label)[14]等。目前应用较多的是一致性正则化方法,其核心理念是加噪处理后的影像应与原始模型对影像分割结果保持一致,加噪处理主要包括影像[11]、特征[12]和网络模型[13] 3 种加噪方式。滕文秀等[15]使用半监督学习模型以 RSI - CB256、NWPU - RESISC45 作为源域数据集,以 UC - Merced、WHU - RS19 作为目标域数据集进行跨域迁移学习,显著提高了 VGG16 模型对目标域数据集的泛化能力。文益民等[16]提出的 Co - Transfer 半监督归纳迁移模型框架中包含两组分类器,分别通过对源域和目标域抽样迁移学习以提高模型泛化性能。由于半监督学习模型训练过程的特点,令其具有较强的目标域适应能力和模型泛化能力,可以解决提取空间异质性农田特征过程中面临的目标区域标注信息不足和模型泛化能力不足等问题。

基于以上问题,本文提出一种改进的半监督学习模型,令其在遥感影像中取得高精准的语义分割效果。针对广域农田特征提取任务,提出一种基于半监督模型的空间异质性农田特征提取方法,该方法通过训练拟提取农田的无标注影像,减少对拟提取地区的农田标注信息的依赖,并获得更为精准的提取效果,以期改善空间异质性农田特征提取效果不佳的问题。

1 半监督学习模型结构与模型优化

1.1 SSS - MKD 模型概述

相互知识蒸馏的半监督语义分割(Semi-supervised semantic segmentation with mutual

knowledge distillation, SSS－MKD)[17]是在 2021 年提出的一种基于一致性正则化方法的半监督学习模型。该模型结合 Mean－teacher 模型[18]和交叉伪监督(Cross pseudo supervision, CPS)[19]的优势。即通过构建 2 个 Mean－teacher 模型,对教师模型输入的图像进行弱增强以提高预测置信度;对学生模型输入的图像进行强增强以扩充训练样本,利用一个教师生成的伪标注来监督另一个学生网络,滑动平均更新(Exponential moving average, EMA)学生模型参数得到新的教师模型,另外一组也如此,该过程不断迭代可实现两个分支之间的相互知识蒸馏。此外,对两个分支的学生模型的输出进行一致性约束,即保证同一幅影像在两个 Mean－teacher 模型的预测结果应一致,如图 1 所示。

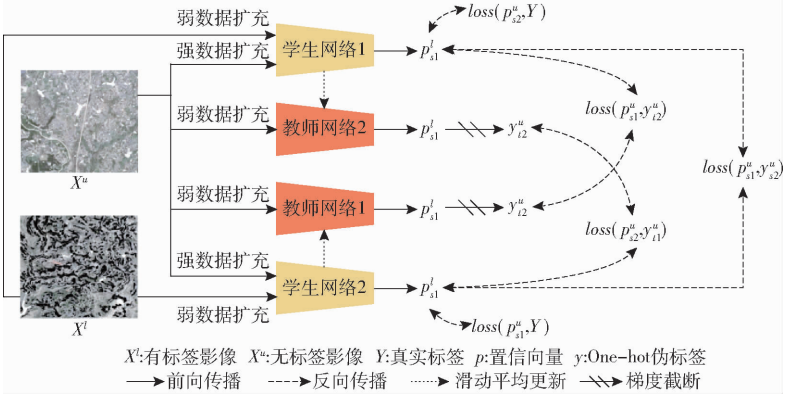

图 1　SSS－MKD 网络框架

Fig. 1　SSS－MKD network framework

1.2　基于加权损失函数的在线难例样本挖掘策略

空间异质性农田在高分遥感影像中间存在形态学差异性大、农田占比悬殊等现象,导致模型提取精度降低,而通过挖掘难以识别的目标区域并对难例样本更新模型参数,可有效提高模型提取精度。在线难例样本挖掘策略[20](Online hard example mining, OHEM)首次提出并应用于目标检测领域,该领域中模型对感兴趣目标进行候选框判定并完成分类以及定位修正,困难样本为损失较高、候选框偏移较大和类别不明确的候选框中的特征图。不同的是,本文筛选困难样本的流程为:将整个输入影像视为一个样本,经过前向传播后得到该影像所有像元的预测结果以及损失,并通过统计方法输出整幅影像分类的总体损失来筛选出困难样本。

选取最少像素数 $D=100\,000$ 及置信度 $p=0.7$ 作为本文中困难像元样本的阈值。当原始影像输入网络,以损失值计算每个样本的置信度 p,损失值越高置信度 p 越小,所有置信度小于 0.7 的样本视为困难样本。若所有困难样本的总像素数小于设定的最小像素数 D,则根据简单样本置信度由低到高排序,令置信度低的简单样本调整为困难样本,以保证训练轮次中具备足够多的像素数参与训练,进而提高训练效率。设定将包含最大损失的 D 个像素的影像或置信度小于 p 的所有影像视为困难样本,然后通过对简单样本和困难样本权重设为 0 和 1,置零简单像元样本的损失值,仅由困难样本进行后续梯度计算以及网络更新,最终实现一轮在线难例样本挖掘策略模型训练。图 2 为 OHEM 策略流程图。

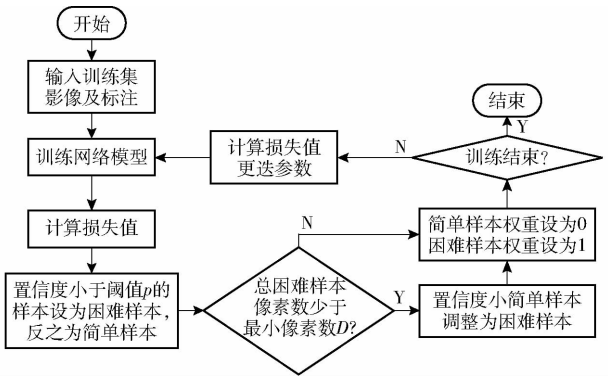

图 2　OHEM 策略流程图

Fig. 2　OHEM strategy flowchart

我国南北方地区农田破碎程度不同且地块大小不一,例如中原地区农田集中且规则,高原地带则农田稀疏且不规则,导致农田提取效果不佳。常用的交叉熵损失函数 L_{CE} 难以应对这种情况,是因为在训练集的农田占比不均衡会导致交叉熵损失函数 L_{CE} 值很小,不易于帮助模型达到最优。而 Dice Loss 不受农田大小影响,仅通过两区域交集判别分割效果。可以协助交叉熵损失函数 L_{CE} 获得更好的优化效果。因此利用 Dice Loss 从目标区域度量分割结果与真实值差异,可解决类不平衡问题,同时使用交叉熵损失函数 L_{CE} 从像素层面上衡量目标与真实值差异。研究采用的损失函数是 Dice Loss 和交叉熵损失函数 L_{CE} 权重比 3∶1 的加权叠加损失函数[21]。

加权损失函数 L_{Weighted}、Dice 损失函数 L_{Dice}和交叉熵损失函数 L_{CE}计算式为

$$L_{\text{Weighted}} = 3L_{\text{Dice}} + L_{CE} \tag{1}$$

$$L_{\text{Dice}} = 1 - \frac{2|X \cap Y| + 1}{|X| + |Y| + 1} \tag{2}$$

$$L_{CE} = -\sum_{i=1}^{N} y_i \lg p_{y_i'} \tag{3}$$

式中 X、Y——标签和预测结果

$|X|$、$|Y|$——X、Y 中所有像素值的和

$|X \cap Y|$——X、Y 集合交集像素值的和

y_i——标注值

$p_{y_i'}$——预测值概率

1.3 特征提取网络结构建立与模型优化

使用改进后的 ResNet101 为 DeepLabv3 + 的主干特征提取网络结构，DeepLabv3 + 模型结构如图 3 所示，其编码器由骨干网络和金字塔型空洞池化模块（Atrous spatial pyramid pooling，ASPP）组成。在编码器端，使用 ResNet101 残差网络模型作为骨干网络来进行 16 倍下采样，得到深层次特征提取图，经过 ASPP 模块可得到多尺度特征图；在解码器端，多尺度特征图通过连接 4 倍上采样和 1 × 1 卷积处理得到对应特征图，对处理后的特征图进行 Concat 连接，再通过卷积和 4 倍上采样可获得原影像大小的特征图，通过比较预测结果与真实标签进行损失

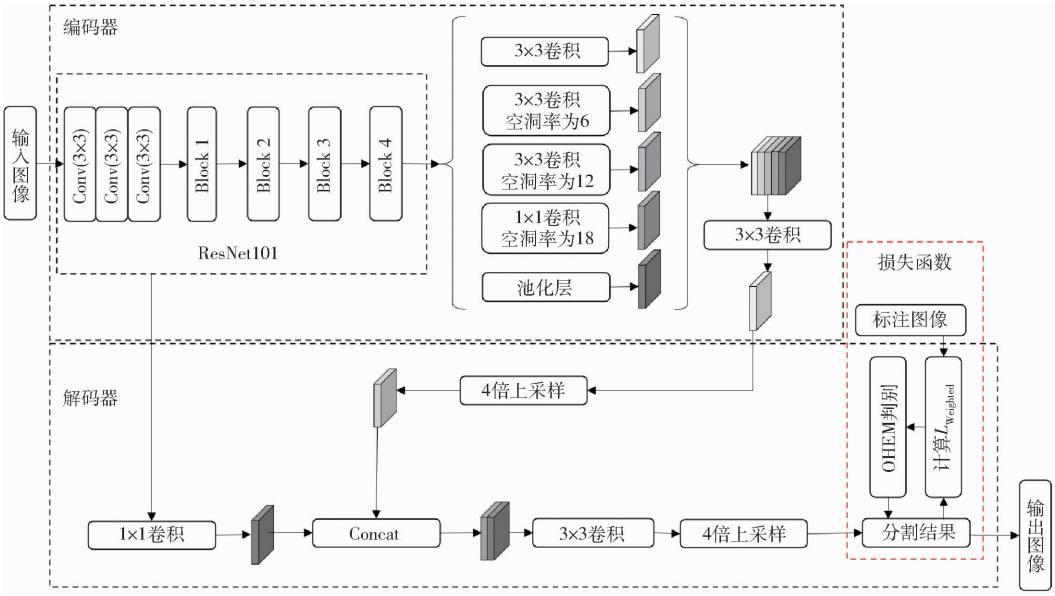

图 3 改进的 DeepLabv3 + 网络结构图

Fig. 3 Improved DeepLabv3 + network structure diagram

函数的计算，由损失函数反向传播迭代网络参数。经过分类器获得最终的语义分割结果。

2 半监督学习模型消融试验

2.1 评价指标

选取总体精度（Overall accuracy，OA）、F1 值和平均 F1 值为评价指标。总体精度表示预测正确数值占总预测量值的比例。平均 F1 值为各类别 F1 值平均值。

2.2 软硬件及超参数设置

试验所用硬件环境为：Nvidia RTX 3090 显卡、64 GB 内存；软件环境为：Ubuntu 10.04、PyTorch：1.10.0、Python：3.7.13、Cuda 11.3、GCC 7.5.0；训练超参数设置：最大迭代次数 20000；Batch size 设置为 4；使用随机梯度优化器（Stochastic gradient descent，SGD）；使用 Softmax 分类器；使用测试阶段数据增强策略（Test time augmentation，TTA），对测试图像进行横纵翻转和 0.8、1.0、1.2 倍缩放。

2.3 半监督学习模型的消融试验

通过国际摄影测量与遥感学会（International Society for Photogrammetry and Remote Sensing，ISPRS）Vaihingen 数据集[23]评估本半监督模型的性能。该数据集包含分辨率为 9 cm 的正射影像，分为近红外、红光、绿光 3 个波段及其对应的数字表面模型，数据集中共包含 33 幅图像，如图 4a 所示。图 4b 为其中一幅遥感图像，图 4c 为其对应的标注图及图例，每幅图像的尺寸不完全相同，遵循文献[24]的划分方法，将原训练集中 12 幅（编号 1、3、11、13、15、17、21、26、28、32、34、37）图像作为试验中的训练集，其余 4 幅图像（编号 5、7、23、30）作为验证集。

通过与其他性能优异的半监督学习模型 SS - GAN[25]、Semi - SegGAN[26]、Adv - attGAN[24]和 SSS - MKD[17]的分割结果对比，验证本模型的有效性。SS - GAN[25]使用少量有标注样本生成伪图像、扩充数据



(a) 全部遥感影像　(b) 31号遥感影像　(c) 标注及图例

图 4　ISPRS Vaihingen 数据集

Fig. 4　Schematics of ISPRS Vaihingen dataset

集，实现半监督学习的语义分割。Semi－SegGAN[26]则利用辅助对抗网络，来对分割网络的更新方向进行约束，使用无标注样本来进行对抗训练，从而实现半监督学习语义分割。Adv－attGAN[24]为添加全卷积形式的辅助对抗网络，配合能够进行注意力选择的对抗损失进行语义分割。

相对于其他研究者提出的半监督学习模型在ISPRS Vaihingen 数据集的表现，在有标注影像占全部影像的 1/4 比例的试验中，本研究模型相较于Adv－attGAN[24]取得的总体精度虽然低 0.1 个百分点，但是平均 F1 值高 1.2 个百分点，说明本研究模型召回率更高。本研究模型与 Adv－attGAN 性能表现近似，在各类别的 F1 值各有高低。在 1/8 比例划分的试验中，本研究模型总体精度比 Adv－attGAN[24]高 0.2 个百分点，但是在平均 F1 值高 0.7 个百分点，除树木外的 4 个前景类别 F1 值均是最高。对于低矮植被和汽车等在遥感影像面积占比较少的类别提升明显，证明基于加权损失函数的在线难例样本挖掘策略的有效性。

表 1 为不同方法分割性能对比结果，使用有标注影像占全部影像 1/4 比例的试验中，本研究改进的半监督学习模型的总体精度达到 87.1%，平均 F1 值达到 85.0%；使用有标注影像占全部影像 1/8 比例的试验中，其中总体精度达到 86.3%，平均 F1 值达到 83.3%。使用在线难例样本挖掘策略模型相较于不使用 SSS－MKD 的精度，在 1/8 比例树木类别的 F1 值中降低 0.3 个百分点，其余都呈提升趋势，尤其对少样本类别，例如 1/8 比例试验中汽车和低矮植被类别的提升效果显著，F1 值最高可分别提升 6.3、2.5 个百分点。

表 1　与其他半监督学习模型提取精度对比

Tab. 1　Comparison of extraction accuracy with other semi-supervised learning models　%

比例	模型	各类别 F1 值					总体精度	平均 F1 值
		不透光水面	建筑物	低矮植被	树木	汽车		
1/4	SS－GAN[24]	83.6	91.0	63.9	84.1	65.7	82.9	77.7
	Semi－SegGAN[25]	87.3	93.3	73.5	87.1	75.7	86.5	83.4
	Adv－attGAN[23]	87.8	93.9	73.8	87.4	76.2	87.2	83.8
	SSS－MKD[18]	87.6	92.9	78.1	86.1	74.0	86.1	83.7
	本研究模型	89.0	93.4	78.4	85.8	78.3	87.1	85.0
1/8	SS－GAN[24]	81.1	88.3	62.5	82.0	54.3	81.6	73.6
	Semi－SegGAN[25]	85.9	91.5	70.8	86.1	72.3	84.9	81.3
	Adv－attGAN[23]	86.7	92.1	74.2	87.0	73.1	86.1	82.6
	SSS－MKD[18]	86.7	91.3	73.8	83.8	67.9	84.1	80.7
	本研究模型	88.0	92.6	76.3	85.7	74.2	86.3	83.3

3　半监督学习模型提取空间异质性农田特征

吉林一号农田影像数据集[27]是科大讯飞股份有限公司在 2021 年发布的语义分割数据集，用于高分辨率遥感影像提取农田的挑战比赛。该数据集使用中国东北地区的高分辨率遥感影像数据，时间跨度为春季至秋季，每幅影像都有 RGB 和近红外光共 4 个波段，空间分辨率在 0.75 ~ 1.1 m 之间，大小在 5 000 ~ 18 000 像素之间。为满足 GPU 显存需求和提升训练效率，利用滑窗裁剪和随机裁剪，将训练数据裁剪为若干 256 像素 ×256 像素的影像。吉林一号农田影像数据集中共包含 31 幅遥感影像，命名为 4 位英文加数字，相同英文名称的遥感影像视为同质农田，不同英文名称的遥感影像的农田差异度高，视为空间异质性农田。依此规律划分 15 种空间异质性农田的遥感影像组，各组空间异质性农田如图 5 所示。

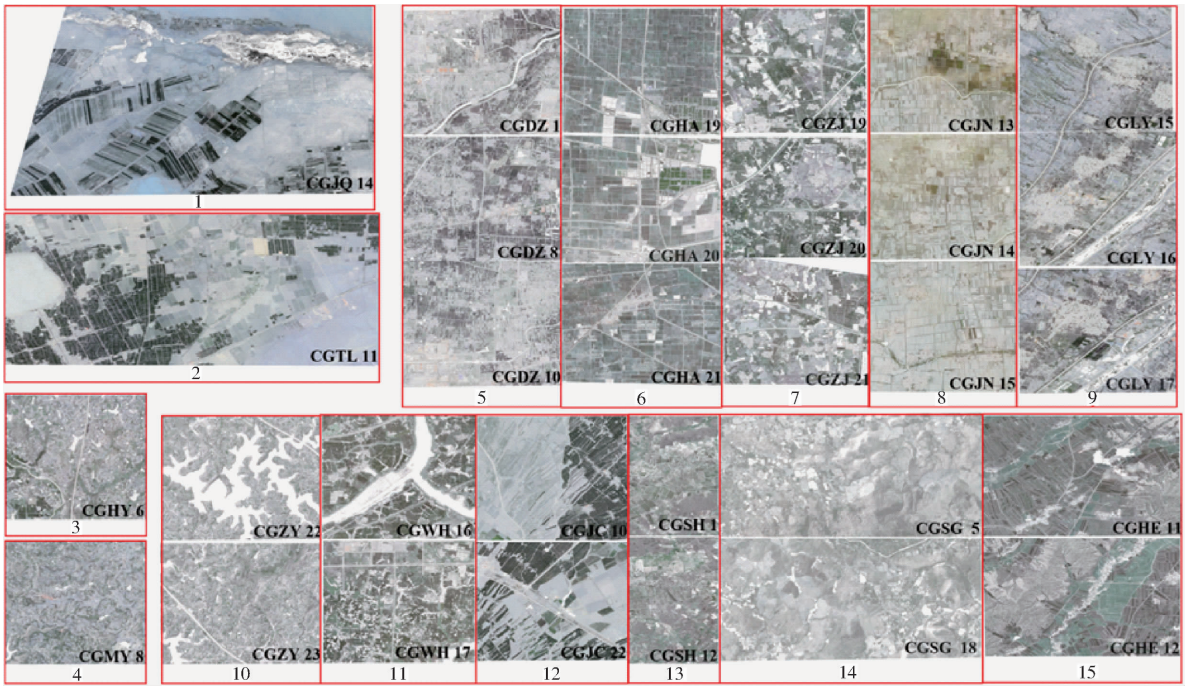

图 5 高分辨率吉林一号农田影像数据集

Fig. 5 Jilin－1 high-resolution remote sensing cropland dataset

针对广域空间异质性农田特征提取任务，通过设计图 6 所示使用验证集和训练集地区无标注影像的 2 组试验，其中验证集为拟提取地区影像，令半监督学习模型训练中分别使用拟提取地区和训练集地区的农田无标注影像训练，以提高对拟提取地区的农田特征提取精准度。以吉林一号农田影像数据集为例，探究半监督学习模型提取空间异质性农田特征的效果。

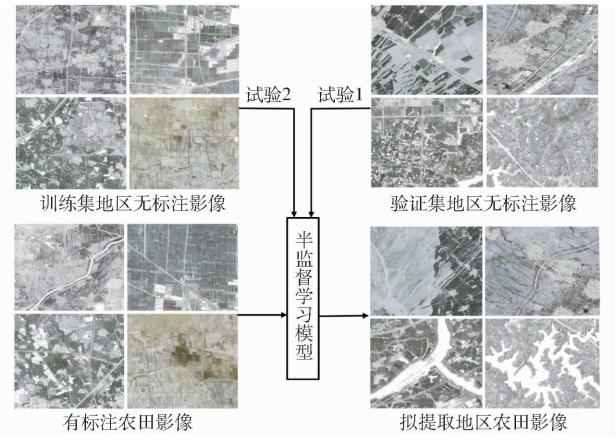

图 6 半监督学习模型提取空间异质性农田特征提取试验设计

Fig. 6 Semi-supervised learning model extracting heterogeneous cropland extraction experiment design

3.1 使用验证集地区无标注影像试验

在使用验证集地区无标注影像（CGHA 19）试验中，设计 7 组对比试验，如图 7 所示。各组方案提取精度如表 2 所示。方案 1 中训练地区与验证地区不同时，总体精度为 64.9%，方案 2 中仅使用与验证影像相近地区的影像，其总体精度可以提高到 84.0%，方案 6 中同时利用与验证影像相近的影像和标注来训练，其总体精度可以提高至 88.9%。对比方案 2 与方案 4 可以得出使用与验证集影像中农田特征相近的影像，比特征差异大的影像的提取总体精度高 6.1 个百分点，说明使用拟进行农田提取任务地区的影像的精度提升明显。另外方案 3、5、7 是在方案 2、4、6 的基础上额外添加一幅影像完成训练。图 8 为各方案的农田特征提取效果对比，图 8a 为原图和对应标注，图 8b～8h 对应方案 1～7。

图 9 为采用半监督学习模型的农田特征提取情况，该地区农田破碎度低且形状规则，农田占整幅影像的比例高，绿色虚线框中为破碎度高农田提取效果，轮廓清晰。红色虚线框中展示提取出现瑕疵的部分以及对荒地的误判，在整幅图的右半部分出现“椒盐现象”，总体的提取效果仍不错，后续可以通过形态学处理方法修正“椒盐现象”。

3.2 使用训练集地区无标注影像试验

在使用训练集地区无标注影像试验中，设计 5 组对比试验方案，如图 10 所示。各组方案提取精度如表 3 所示。在研究中，方案 2 只使用 11 幅有标注影像加 11 幅未标注影像的提取精度达到 81.6%，而相较于方案 1 的常规监督学习中只使用 11 幅有标注影像精度提升 6.4 个百分点。主要误判表现在破碎程度较高的农田被识别为非农田；大块的农田只有中心地区被识别为农田；提取边界信息出现明显错误。当使用 11 幅无标注影

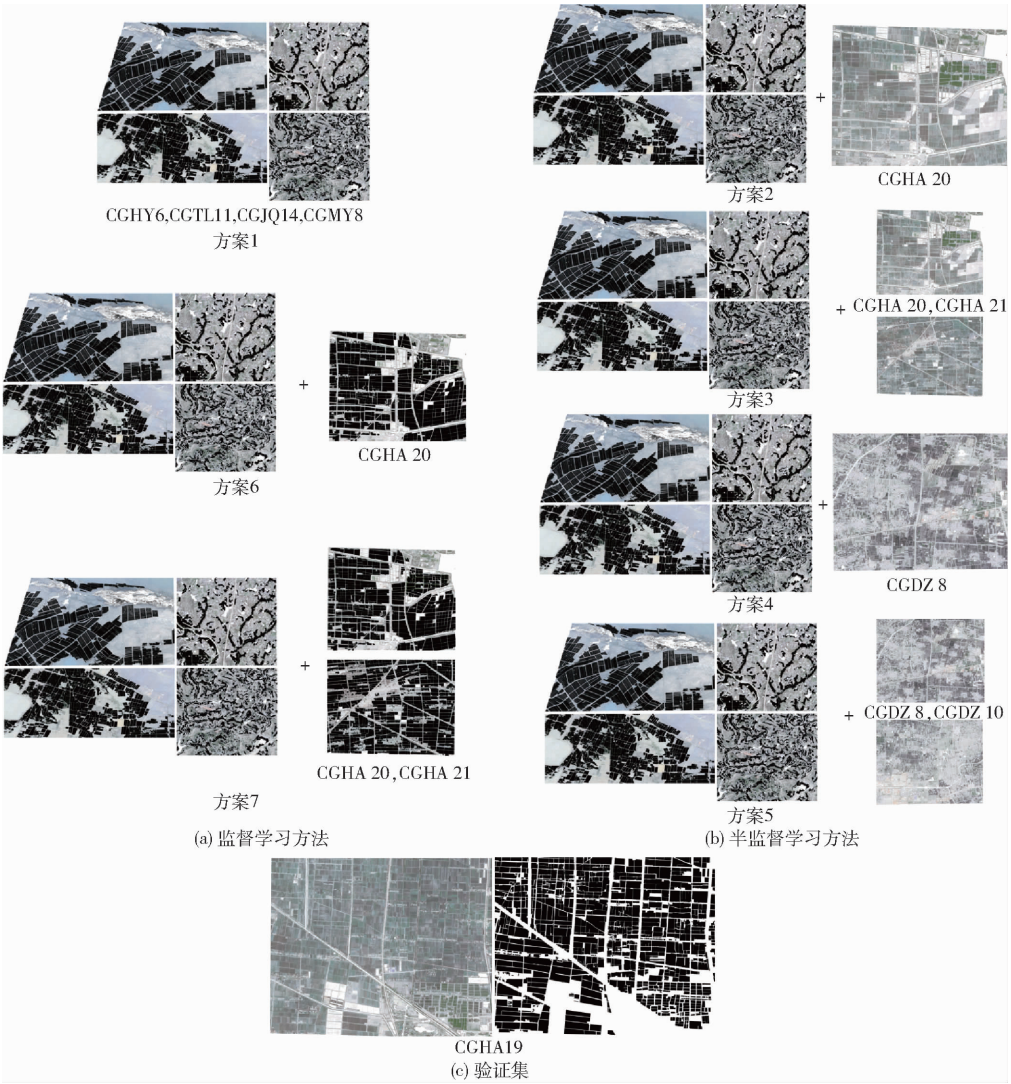

图 7　使用验证集地区无标注影像试验方案设计

Fig. 7　Experimental program design for unannotated images using validation set area

表 2　使用验证集地区影像的不同方案试验及精度

Tab. 2　Experiments and accuracy of different schemes using validation set area images　%

方案编号	有标注影像	无标注影像	各类别 F1 值		总体精度	平均 F1 值
			背景	农田		
1	CGHY6, CGTL11, CGJQ14, CGMY8		62.0	67.5	64.9	64.7
2	CGHY6, CGTL11, CGJQ14, CGMY8	CGHA 20	86.2	80.9	84.0	83.5
3	CGHY6, CGTL11, CGJQ14, CGMY8	CGHA 20, CGHA 21	84.3	79.8	82.3	82.0
4	CGHY6, CGTL11, CGJQ14, CGMY8	CGDZ 8	79.3	76.4	77.9	77.8
5	CGHY6, CGTL11, CGJQ14, CGMY8	CGDZ 8, CGDZ 10	82.4	77.6	80.2	80.1
6	CGHY6, CGTL11, CGJQ14, CGMY8, CGHA 20		90.6	86.4	88.9	86.4
7	CGHY6, CGTL11, CGJQ14, CGMY8, CGHA 20, CGHA 21		91.5	85.8	89.4	88.6

像可以丰富训练集，提取农田的边界线时有明显改善。与方案 4 使用有标注的 22 幅影像进行训练相比，利用两倍的标注信息，精度仅提高 5.6 个百分点，证明该方法可充分利用原遥感影像的信息，并有效降低农田特征提取中需要的标注量。方案 3、5 为在方案 2、4 的基础上继续添加 5 幅影像和对应标注进行训练，其总体精度已无明显增长。其原因在于方案 3、5 额外使用的 5 幅影像中农田纹理几何特征，已经在方案 2、4 中使用的 11 幅图中有体现，没有有效的学习。图 11 为各方案的农田特征提取效果对比，其中图 11a 为原图和对应标注，图 11b ~ 11f 对应方案 1 ~ 5。

图 12 为试验 2 的半监督学习模型的农田特征提取情况，该地区农田破碎度高且形状不规则，农

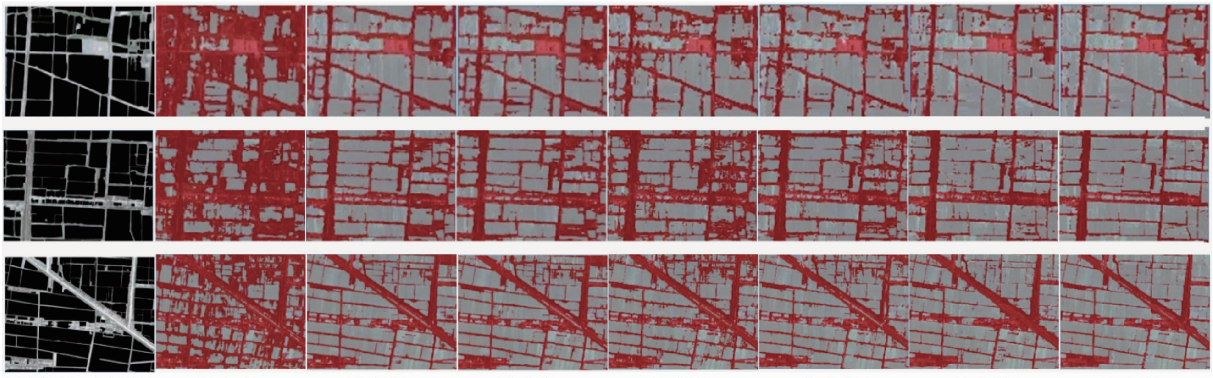

图 8 使用验证集地区影像各方案提取农田特征效果对比

Fig. 8 Comparison of effects of different schemes for extracting cropland coverage information from images in validation set area

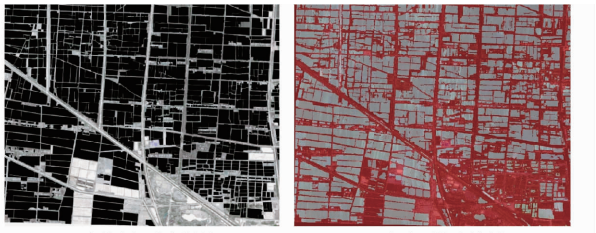

图 9 使用验证集地区影像的方案 2 提取农田的效果

Fig. 9 Comparison of effect of Scheme 2 for extracting farmland features using validation set area images

田占整幅影像的比例也较低,因此该地区的农田特征提取较难。绿色虚线框选中为破碎度高农田特征提取的效果,可以发现研究的半监督学习模型可以有效提取出破碎度高的农田。红色虚线框选中对荒地明显的误判,该情况同样也出现在别的方案中,其原因为荒地与未种植的农田特征相似,将荒地错认为农田。

3.3 河北省献县农田提取

本文使用一景拍摄于 2021 年 5 月 28 日的高分

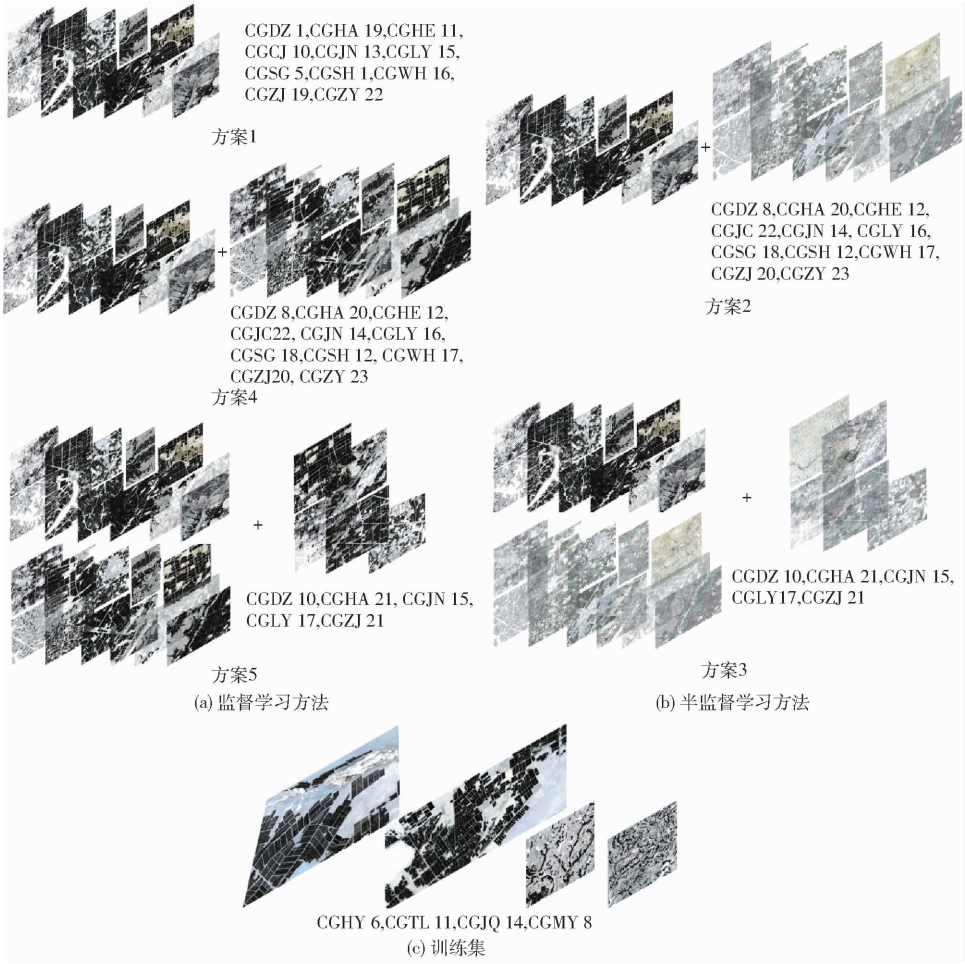

图 10 使用训练集地区无标注影像试验方案设计

Fig. 10 Experimental program design for unannotated images using training set area

表 3　使用训练集地区影像的不同方案试验及精度

Tab. 3　Experiments and accuracy of different schemes using training set area images　%

方案编号	有标注影像	无标注影像	各类别 F1 值		总体精度	平均 F1 值
			背景	农田		
1	CGDZ 1, CGHA 19, CGHE 11, CGCJ 10, CGJN 13, CGLY 15, CGSG 5, CGSH 1, CGWH 16, CGZJ 19, CGZY 22		33.8	84.8	75.2	59.3
2	CGDZ 1, CGHA 19, CGHE 11, CGCJ 10, CGJN 13, CGLY 15, CGSG 5, CGSH 1, CGWH 16, CGZJ 19, CGZY 22	CGDZ 8, CGHA 20, CGHE 12, CGJC 22, CGJN 14, CGLY 16, CGSG 18, CGSH 12, CGWH 17, CGZJ 20, CGZY23	57.7	88.3	81.6	73.0
3	CGDZ 1, CGHA 19, CGHE 11, CGCJ 10, CGJN 13, CGLY 15, CGSG 5, CGSH 1, CGWH 16, CGZJ 19, CGZY 22	方案 2 + CGDZ 10, CGHA 21, CGJN 15, CGLY 17, CGZJ 21	63.0	89.3	83.7	76.1
4	方案 1 + CGDZ 8, CGHA 20, CGHE 12, CGCJ 22, CGJN 14, CGLY 16, CGSG 18, CGSH 12, CGWH 17, CGZJ 20, CGZY 23		74.9	91.4	87.2	83.1
5	方案 4 + CGDZ 10, CGHA 21, CGJN 15, CGLY 17, CGZJ 21		77.1	91.8	87.9	84.4

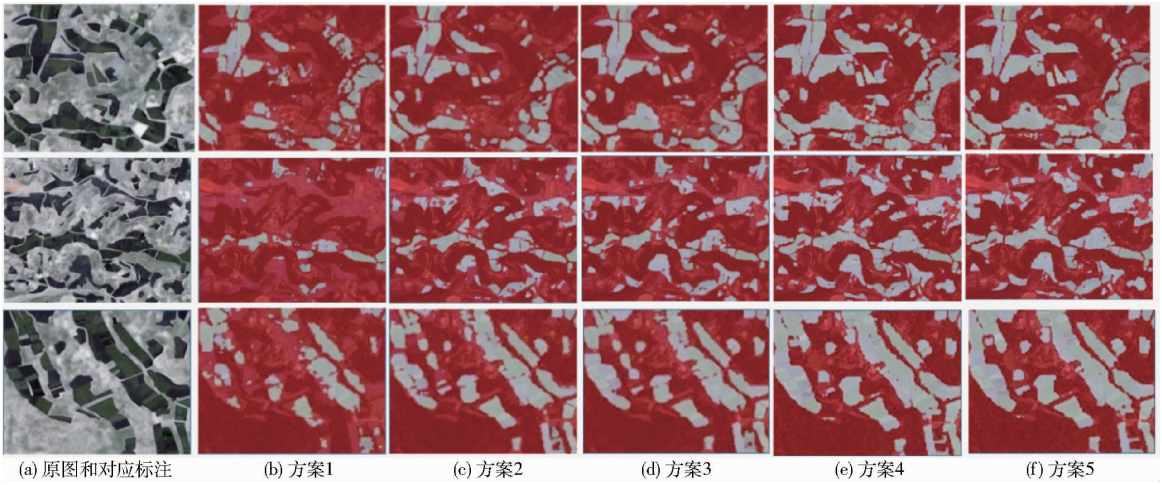

图 11　使用训练集地区影像各方案提取农田特征效果对比

Fig. 11　Comparison of effects of different schemes for extracting cropland coverage information from images with training sets area images

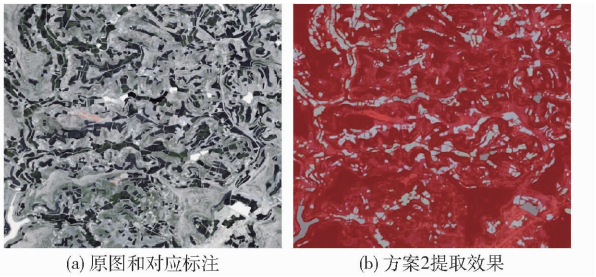

图 12　使用训练集地区影像的方案 2 提取农田特征效果对比

Fig. 12　Comparison of effect of Scheme 2 for extracting farmland features using training set area images

二号遥感影像，其覆盖范围主要位于河北省献县境内，其主要农作物为冬小麦。使用经过几何校正、辐射定标、大气校正自动配准和图像融合技术后的分辨率为 1 m 的栅格影像，以及经人工目视解译的农田标注信息作为试验数据。如图 13 所示，其中黑色

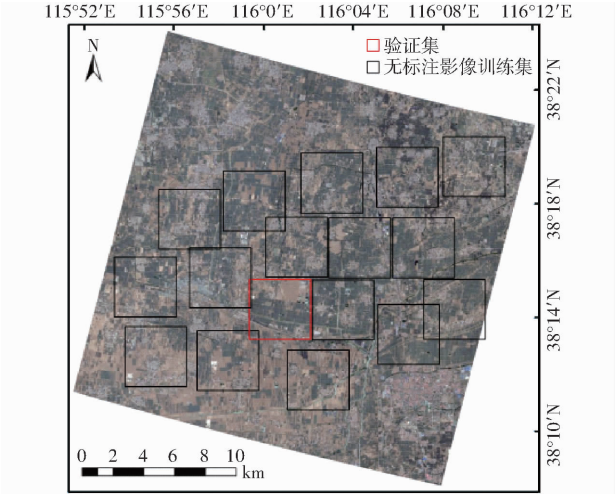

图 13　献县地区高分二号遥感影像数据集

Fig. 13　Gaofen－2 remote sensing imagery dataset for Xian County area

和红色框中的遥感及标注数据分别作为训练集的无标注影像和验证集，使用部分吉林一号农田影像数据集作为有标注影像进行训练。其中训练参数和影像大小与以上试验保持一致。

由表 4 可知，同时使用两个数据集的无标注影像训练后的模型精度达到最高，总体精度为 88.7%。在分别使用这两个数据集训练后的模型精度结果中，使用献县地区高分二号影像数据集训练，总体精度可达 87.7%，仅使用吉林一号农田影像数据集无标注影像进行训练取得的总体精度为 83.8%，相较于监督学习方式，以上 3 种方案提取精度均有不同程度的提升，总体精度最高可提升 8.1 个百分点。

表 4 献县地区农田特征提取不同方案试验及精度

Tab. 4 Experiment and accuracy of different schemes of cropland extraction in Xian County %

方案编号	有标注影像训练集	无标注影像训练集		各类别 F1 值		总体精度	平均 F1 值
	吉林一号农田影像数据集(部分 1)	献县地区高分二号影像数据集	吉林一号农田影像数据集(部分 2)	背景	农田		
1	√	√	√	91.2	84.3	88.7	87.7
2		√		90.1	83.8	87.7	86.9
3			√	86.8	79.1	83.8	83.0
4				84.0	75.2	80.6	79.6

注：吉林一号农田影像数据集(部分 1)包含 CGDZ 1、CGHA 19、CGHE 11、CGCJ 10、CGJN 13、CGLY 15、CGSG 5、CGSH 1、CGWH 16、CGZJ 19、CGZY 22 共 11 幅影像，共包含 13 665 幅 256 像素 ×256 像素影像；吉林一号农田影像数据集(部分 2)为 CGDZ 8、CGHA 20、CGHE 12、CGJC 22、CGJN 14、CGLY 16、CGSG 18、CGSH 12、CGWH 17、CGZJ 20、CGZY 23、CGDZ 10、CGHA 21、CGJN、15 CGLY 17、CGZJ 21 共 16 幅影像，共包含 18 090 幅 256 像素 ×256 像素影像；献县地区高分二号影像数据集共包含 19 775 幅 256 像素 ×256 像素影像。

图 14 为表 4 中提出的 4 种方案的农田特征提取效果，通过目视解译法判断其主要的误判分为以下 3 种情况：①农田道路与裸地的误判、高破碎度农田的误判和非大宗作物农田的误判。农田道路与裸地的误判主要是由于两者光谱信息近似，且由于农田道路细长且在农田之间，导致农田道路易被错判为裸地。②靠近城镇地区的农田破碎度高，识别难度高，在方案 1、2 中使用献县地区高分二号影像数据集进行训练，可明显提高对城镇周边的高破碎度农田的提取精度。③非大宗作物农田的误判包括对未种植农田和小宗作物的误判，方案 1 相较于其余方案可更精准地识别非大宗作物农田，减小误判，但其边界信息提取不理想。图 15 为整幅高分 2 号影像的农田提取效果。

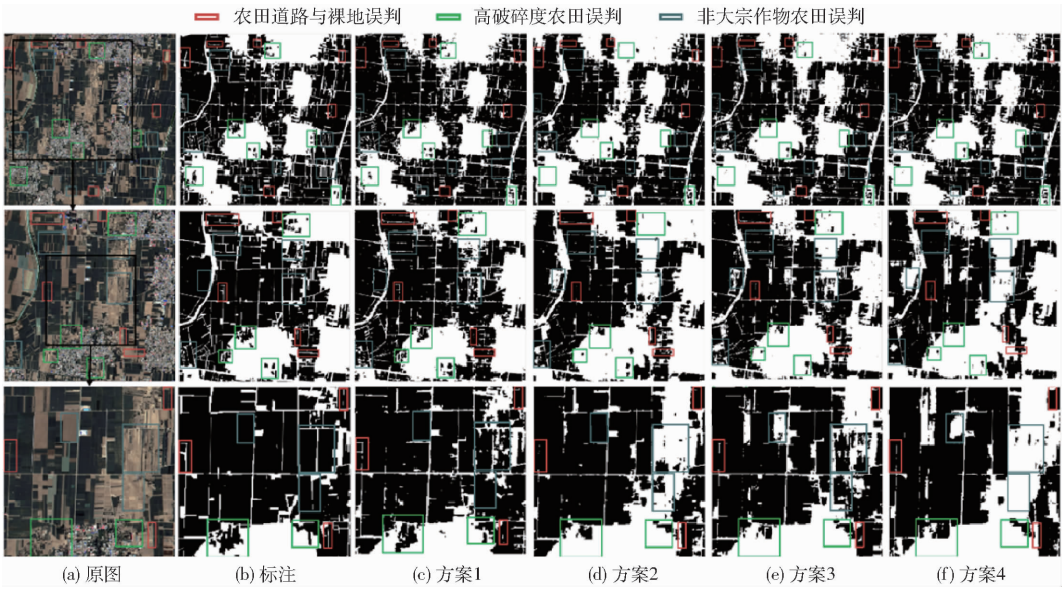

图 14 献县地区不同方案提取农田特征效果对比

Fig. 14 Comparison of effects of different schemes for extracting cropland coverage information from images in Xian County area

4 讨论

4.1 半监督模型性能

本文提出一种改进半监督学习模型，该模型是以相互知识蒸馏的半监督语义分割模型为基础，使用改进后的 ResNet101 作为 DeepLabv3 + 的网络结构，利用加权损失函数的在线难例样本挖掘策略，筛选出训练中的难样本对网络参数进行更迭，以减少

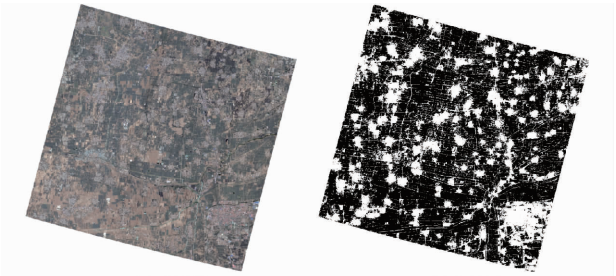

图 15　献县地区农田特征提取效果

Fig. 15　Extraction effect of cropland characteristic in Xian County area

农田破碎度高和比例不平衡带来的精度下降。在 ISPRS Vaihingen 数据集中本文改进的半监督学习模型呈现优异的性能，使用有标注影像占全部影像 1/4 比例的试验中，其中总体精度达到 87.1%，平均 F1 值达到 85.0%，较其他模型平均 F1 值至少高 1.2 个百分点；在 1/8 比例的试验中，其中总体精度达到 86.3%，平均 F1 值达到 83.3%，较其他模型平均 F1 值至少高 0.7 个百分点。使用加权损失函数的在线难例样本挖掘策略的模型，对少样本类别例如汽车和低矮植被的提升效果显著，F1 值可以分别提升 6.3、2.5 个百分点，证明本文模型的有效性。综合对比，本文模型相较于前人研究中提出的模型在 ISPRS Vaihingen 数据集表现最好。

由于半监督模型是通过少量标注影像和大量未标注影像共同训练的属性，因此本文提出的方法可以利用该属性减少对农田特征标注信息的依赖。具体表现为以下两方面：①在农田特征标注信息不足时，半监督模型可使用更少量的标注信息取得媲美监督学习的提取效果：在吉林一号农田影像数据集的试验结果显示，本文在试验 1 中仅使用监督学习中 66.7% ~ 80% 的训练集的标注信息，可获得 92.1% ~94.5% 的提取精度；在试验 2 中仅使用一半的监督学习模型使用的标注数据量，便获得 93.6% ~95.2% 的提取精度。②使用相同量的标注信息，半监督模型可以增加无标注影像以取得更高的提取效果：本文提出的方法可通过使用与训练集地区的农田特征相似度高的无标注影像，加强模型对农田语义特征的学习，取得更高的精度。在试验中额外使用 1 ~1.45 倍的基础监督学习方法训练使用的无标注影像量，总体精度提升 6.6 ~8.5 个百分点，最高总体精度达到 81.6%。

4.2　应用性分析

在农田遥感数据丰富，而对应标注信息不足的现实背景下，针对广域空间异质性农田特征提取任务，提出一种利用半监督学习模型，学习空间异质性农田无标注影像的特征信息，最终可改善空间异质性农田特征提取效果不佳的问题。半监督学习模型使用拟提取地区和训练集地区的农田无标注影像训练，可提高对空间异质性农田特征提取精度。在吉林一号农田影像数据集的试验结果显示，相比于不使用无标注影像训练的监督学习方法，本模型的总体精度高达 84.0%。当使用农田特征相似度高的无标注影像训练，相较于使用农田特征相似度低的影像训练，总体精度可提升 2.1 ~6.1 个百分点。以河北省献县地区为例，该半监督模型使用的无标注影像，为该地区高分二号影像数据集的无标注影像和吉林一号农田影像数据集（部分 2），使用的有标注影像为吉林一号农田影像数据集（部分 1），提取该地区农田特征总体精度高达 88.7%。

此外，在半监督学习模型提取到农田特征的基础上，提取细类划分的农田特征会对有标注数据集和无标注数据集的质量要求更高，比如高分二号影像数据集（Gaofen image dataset, GID）[28] 中将农田分为稻田、灌溉地和旱田 3 类。在该数据集基础上，使用拟提取地区无标注影像可以实现对空间异质性农田特征的细类划分。同理，在细分提取不同种植作物的农田特征任务中，需要有标注数据集包含不同作物的农田标注信息。

半监督学习模型进行空间异质性农田特征提取中，最终提取效果的影响因素有：①有标注数据集和无标注数据集的空间分辨率不应差距过大，两者属于同一遥感数据源最佳。②有标注数据集和无标注数据集的数据质量对模型性能都有显著影响，有标注数据集应该经过精心标注和验证，避免包含过多的噪声或错误标记。③农田在影像中的占比不宜过低，否则模型会更倾向于学习频繁出现的其他地物类别而忽略农田类别。④半监督学习模型进行空间异质性农田提取中，使用的无标注信息的影像量并非越多越好，过量影像中的农田特征已经被充分学习，无标注的杂物反而会干扰模型的训练。因此在使用半监督学习模型时训练使用的无标注影像量需要结合农田覆盖提取任务中范围大小、农田特征丰富度等综合考虑。

5　结论

（1）使用加权损失函数的在线难例样本挖掘策略的 SSL－MKD 模型，筛选出训练中的难样本对网络参数进行更迭，在 ISPRS Vaihingen 数据集中表现优异，可提高对少样本类别例如汽车和低矮植被类别的提取效果。在有标注影像占全部影像的 1/4 比例的试验中，总体精度达到 87.1%，平均 F1 值达到 85.0%；在有标注影像占全部影像的 1/8 比例的试

验中，总体精度达到 86.3%，平均 F1 值达到 83.3%，相较于源模型实现有效提升。

(2)针对广域空间异质性农田特征提取任务，提出了一种空间异质性农田特征提取方法，在训练半监督模型时分别使用拟提取地区和训练集地区的农田无标注影像训练，以提高该区域的农田特征提取精度。在吉林一号农田影像数据集中，使用拟提取农田的农田无标注影像训练，其总体精度可以提高到 84.0%；使用训练集地区的农田无标注影像训练后的提取精度达到 81.6%。

(3)使用吉林一号农田影像数据集(部分 1)作为有标注训练集，同时使用吉林一号农田影像数据集(部分 2)和献县地区高分二号影像数据集的无标注影像，训练后的总体精度高达 88.7%，相较于单独使用上述两个数据集和不使用无标注影像数据集的提取精度分别提高 1.0、4.9、8.1 个百分点。

参 考 文 献

[1] DEBATS S R, LUO D, ESTES L D, et al. A generalized computer vision approach to mapping crop fields in heterogeneous agricultural landscapes[J]. Remote Sensing of Environment, 2016, 179: 210 - 221.

[2] BELGIU M, CSILLIK O. Sentinel - 2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis[J]. Remote Sensing of Environment, 2018, 204: 509 - 523.

[3] SYKAS D, SDRDAKA M, ZOGRAFAKIS D, et al. A Sentinel - 2 multiyear, multicountry benchmark dataset for crop classification and segmentation with deep learning[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15: 3323 - 3339.

[4] RAEI E, ASANJAN A A, NIKOO M R, et al. A deep learning image segmentation model for agricultural irrigation system classification[J]. Computers and Electronics in Agriculture, 2022, 198: 106977.

[5] 张超,高璐璐,郧文聚,等. 遥感技术获取耕地质量评价指标的研究进展分析[J]. 农业机械学报, 2022,53(1):1 - 13.
ZHANG Chao, GAO Lulu, YUN Wenju, et al. Research progress on obtaining cultivated land quality evaluation indexes by remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022,53(1):1 - 13. (in Chinese)

[6] 王鹏新,田惠仁,张悦,等. 基于深度学习的作物长势监测和产量估测研究进展[J]. 农业机械学报, 2022,53(2):1 - 14.
WANG Pengxin, TIAN Huiren, ZHANG Yue, et al. Crop growth monitoring and yield estimation based on deep learning: state of the art and beyond[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022,53(2):1 - 14. (in Chinese)

[7] 陈理,杨广,刘名洋,等. 基于遥感影像和卷积神经网络的农田及道路信息提取[J]. 中国农业大学学报, 2022,27(6): 182 - 191.
CHEN Li, YANG Guang, LIU Mingyang, et al. Extraction of field and road information based on remote sensing image and convolution neural network[J]. Journal of China Agricultural University, 2022,27(6):182 - 191. (in Chinese)

[8] 鲁恒,付萧,贺一楠,等. 基于迁移学习的无人机影像耕地信息提取方法[J]. 农业机械学报, 2015, 46(12):274 - 279,284.
LU Heng, FU Xiao, HE Yi'nan, et al. Cultivated land information extraction from high resolution UAV images based on transfer learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(12):274 - 279,284. (in Chinese)

[9] 杨思琦. 基于迁移学习的高分辨率遥感图像场景分类研究[D]. 北京:中国地质大学, 2021.
YANG Siqi. Scene classification of high resolution remote sensing images based on transfer learning[D]. Beijing: China University of Geosciences, 2021. (in Chinese)

[10] 张书瑜. 基于深度学习和多尺度多特征融合的高分辨率遥感地表覆盖分类研究[D]. 杭州:浙江大学,2020.
ZHANG Shuyu. High-resolution remote sensing image land cover classification based on deep learning and multi-scale and multi-feature fusion[D]. Hangzhou: Zhejiang University,2020. (in Chinese)

[11] YUAN J, LIU Y, SHEN C, et al. A simple baseline for semi-supervised semantic segmentation with strong data augmentation [C]// Proceedings of the 18th IEEE/CVF International Conference on Computer Vision, 2021: 8229 - 8238.

[12] CUYPERS S, BASSIER M, VERGAUWEN M. Deep learning on construction sites: a case study of sparse data learning techniques for rebar segmentation[J]. Sensors, 2021, 21(16): 5428.

[13] CHEN X, YUAN Y, ZENG G, et al. Semi-supervised semantic segmentation with cross pseudo supervision[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 2613 - 2622.

[14] LEE D H. Pseudo-label: the simple and efficient semi-supervised learning method for deep neural networks[J]. Workshop on Challenges in Representation Learning, 2013, 3(2): 896 - 902.

[15] 滕文秀,王妮,陈泰生,等. 基于深度对抗域适应的高分辨率遥感影像跨域分类[J]. 激光与光电子学进展,2019, 56(11):236 - 246.
TENG Wenxu, WANG Ni, CHEN Taisheng, et al. Deep adversarial domain adaptation method for cross-domain classification in high-resolution remote sensing images[J]. Laser & Optoelectronics Progress,2019, 56(11):236 - 246. (in Chinese)

[16] 文益民,员喆,余航. 一种新的半监督归纳迁移学习框架:Co - Transfer[J]. 计算机研究与发展, 2023,60(7):1603 - 1614.
WEN Yimin, YUAN Zhe, YU Hang, et al. A new semi-supervised inductive transfer learning framework: Co - Transfer[J]. Journal of Computer Research and Development,2023,60(7):1603 - 1614. (in Chinese)

[17] WANG W. Semi-supervised semantic segmentation network based on knowledge distillation[C]//2021 IEEE 4th Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC). IEEE, 2021: 1900 – 1905.
[18] TARVAINEN A, VALPOLA H. Mean teachers are better role models: weight-averaged consistency targetsimprove semi-supervised deep learning results[J]. Advances in Neural Information Processing Systems, 2017, 30:30 – 40.
[19] CHEN X, YUAN Y, ZENG G, et al. Semi-supervised semantic segmentation with cross pseudo supervision[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 2613 – 2622.
[20] 黄海. 基于高分辨率遥感影像的农用地提取方法研究[D]. 广州:广州大学, 2021.
HUANG Hai. Research on extraction methods of agricultural land based on high-resolution remote sensing images[D]. Guangzhou: Guangzhou University, 2021. (in Chinese)
[21] TAGHANAKI S A, ZHENG Y, ZHOU S K, et al. Combo loss: handling input and output imbalance in multi-organ segmentation[J]. Computerized Medical Imaging and Graphics, 2019, 75: 24 – 33.
[22] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 2818 – 2826.
[23] ROTTENSTEINER F, SOHN G, JUNG J, et al. The ISPRS benchmark on urban object classification and 3D building reconstruction[C]//ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences, 2012.
[24] 刘雨溪,张铂,王斌. 基于生成式对抗网络的遥感图像半监督语义分割[J]. 红外与毫米波学报, 2020,39(4):473 – 482.
LIU Yuxi, ZHANG Bo, WANG Bin. Semi-supervised semantic segmentation based on generative adversarial networks for remote sensing images[J]. Journal of Infrared and Millimeter Waves,2020,39(4):473 – 482. (in Chinese)
[25] SOULY N, SPAMPINATO C, SHAH M. Semi supervised semantic segmentation using generative adversarial network[C]//Proceedings of the IEEE International Conference on Computer Vision, 2017: 5688 – 5696.
[26] HUNG W C, TSAI Y H, LIOU Y T, et al. Adversarial learning for semi-supervised semantic segmentation[J]. arXiv preprint arXiv:1802.07934, 2018.
[27] ZHAO Z, LIU Y, ZHANG G, et al. The winning solution to the iFLYTEK challenge 2021 cultivated land extraction from high-resolution remote sensing images[C]//2022 14th International Conference on Advanced Computational Intelligence (ICACI). IEEE, 2022: 376 – 380.
[28] TONG X Y, XIA G S, LU Q, et al. Land-cover classification with high-resolution remote sensing images using transferable deep models[J]. Remote Sensing of Environment, 2020, 237: 111322.

(上接第 128 页)

[16] LAI Xiao, QIN Zhiwen, YANG Peng, et al. Small sugarcane harvester conveying failure analysis[C]//Proceedings of 2018 3rd International Conference on Electrical, Automation and Mechanical Engineering,2018:215 – 219.
[17] 宫元娟,金忠博,白晓平,等. 甘蔗收获机割台随动控制系统设计与试验[J]. 农业机械学报,2023,54(2):119 – 128.
GONG Yuanjuan,JIN Zhongbo,BAI Xiaoping,et al. Design and experiment of servo control system for sugarcane header[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(2):119 – 128. (in Chinese)
[18] 李尚平,周敬辉,赖晓,等. 甘蔗收获机及其防堵塞方法:CN106612939A[P]. 2017 – 05 – 10.
[19] 赖晓,郭文峰,黄海波,等. 甘蔗收割机物流堵塞影响因素的试验研究[J]. 农机化研究,2016,38(10):155 – 159.
LAI Xiao,GUO Wenfeng,HUANG Haibo,et al. Experiment study on sugarcane harvester logistics[J]. Journal of Agricultural Mechanization Research,2016,38(10):155 – 159. (in Chinese)
[20] LI Li. The logistics characteristics analysis on flexible conveying device of mini-type sugarcane harvester[J]. Applied Mechanics and Materials,2013,321 – 324:201 – 204.
[21] 李立新,陈伟叙,程志青,等. 小型甘蔗收获机物流防堵机构的设计与仿真分析[J]. 农机化研究,2008,30(11):84 – 87.
LI Lixin,CHEN Weixu,CHENG Zhiqing,at al. Design and simulation analysis on anti-block mechanism in small sugarcane harvester[J]. Journal of Agricutural Mechanization Research,2008,30(11):84 – 87. (in Chinese)
[22] OTTEN H, LIEGERS G, LANDWEHR K, et al. Sugar-cane harvesting machine: US5157904 A[P]. 1992 – 10 – 27.
[23] GAL P Y L, MASSON J L, BEZUIDENHOUT C N, et al. Coupled modelling of sugarcane supply planning and logistics as a management tool[J]. Computers & Electronics in Agriculture, 2009, 68(2):168 – 177.
[24] 何志勇. 电液比例换向阀替代电液伺服阀的改进实践[J]. 宽厚板,2005(4):21 – 23.
HE Zhiyong. Improvement practice in substituting electro-hydraulic proportional direction-changeover valve for electro-hydraulic servovalve[J]. Wide and Heavy Plate,2005(4):21 – 23. (in Chinese)
[25] 黄志坚. 液压气动系统 PLC 控制入门与提高[M]. 北京:化学工业出版社,2019.