

基于子图选择的土种识别* ——以重庆市璧山区紫色土为例

陈怡达^{1,2}, 曾绍华^{1,2}, 吴雪³, 王帅⁴, 刘国一⁵, 周鹏⁶

(1. 重庆师范大学 计算机与信息科学学院; 2. 重庆师范大学 重庆市数字农业服务工程技术研究中心, 重庆 401331;
3. 重庆市南川区农业技术推广中心, 重庆 南川 408400; 4. 重庆市农业技术推广总站, 重庆 400121;
5. 西藏自治区农牧科学院农业资源与环境研究所, 拉萨 850032;
6. 重庆市奉节县农业技术服务中心, 重庆 奉节 404600)

摘要:针对机器视觉野外自然条件下采集土壤图像包含阴影、空洞、缝隙等可能对土种识别产生影响的因素,和土壤图像采集、标记成本高,样本量小的问题,提出一种基于土壤子图选择的土种识别方法。该方法以局部阴影最小化及空间距离最大化为准则,构造最优化模型;并基于最大最小距离算法思想,迭代更新距离矩阵求解优化模型,获得选择子图中心点,构建土壤子图数据集。实验结果显示:土壤子图选择算法构建的数据集在3个不同深度ResNet模型下训练、识别测试,均有较好的训练、识别精度;在土壤子图选择 α 参数为1、子图尺寸为224时,在浅层网络ResNet-18下能达到最佳测试结果,训练的网络模型在验证集识别准确率为92.48%,测试集识别准确率为92.95%,相较于土壤原图数据集的最佳土种识别结果提升46.65%;利用最小外接矩阵能加速相较于不使用加速,子图选择算法提升运算速度38.88%。基于子图选择的土种识别大幅度提升了土种识别准确率,证明算法是有效的。

关键词:土种识别;子图选择;深度学习;土壤图像

中图分类号:TP391.4

文献标志码:A

文章编号:1672-6693(2024)03-0059-14

紫色土是三峡库区农业生产的重要土壤资源,它在库区内集中分布,分布面积达16 613.64 km²,占库区土地总面积的36%^[1]。紫色土因含有丰富的钙、磷、钾等营养元素,土力肥沃,具有较高的农业利用价值。因营养元素含量、pH等的不同,不同土种的紫色土呈现出不同的颜色,具有不同的性质,适种作物及相应的施肥管理也有所不同。因此,有效识别紫色土种类可进一步推动三峡库区的农业生产效率的提高,从而实现现有农业生产向精准农业^[2]发展。在深度学习等^[3-4]人工智能技术快速发展的今天,研究机器视觉识别土种的人工智能方法^[5-6]已成为可能。对紫色土进行机器视觉识别研究,在三峡库区农业经济发展、土壤研究、土壤资源有效利用和保护^[7-8]等方面具有重要意义。

目前,应用图像识别、分类的方法对土壤进行识别、分类^[9]的研究仅限于将土壤分为红土、黄土和灰土或者沙土、壤土和黏土等非常粗糙的分类^[10-11];Pandey等人^[12]和Duan等人^[13]应用遥感图像进行了黑土、灰土的土壤分类及作物长势预测;Sagayaraj等人^[14]应用图像识别检测了土壤含水量;Smith等人^[15]应用图像识别检测、分割了土壤中根系、孔隙度等。然而,关于机器视觉识别土种的研究当前鲜有报道。尽管对土壤图像的研究既有采用传统数字图像处理^[16]、机器学习^[17]的方法,也有采用深度学习的方法^[18-19],但是由于土壤图像采集成本、识别难度以及相关研究成果应用效益等诸多因素^[20]的影响,目前对土壤图像的研究不够深入且缺乏系统性研究。

机器视觉识别土种是利用视觉图像从土壤发生学分类角度来进行土种识别,可进一步识别土壤特征属性,解决农业生产中只有土壤专家才能识别土种的技术瓶颈问题,进而用于指导农业生产。本研究团队通过“土壤区域图像提取-阴影检测-土壤子图切割-土壤子图的可控亮度迁移-基于土壤子图土种及土壤特征属性识别”的技术路线开展机器视觉土种识别研究,得到了在土壤区域图像提取、阴影检测、土壤图像的可控亮度迁移上一系列

* 收稿日期:2023-02-28 修回日期:2023-09-13 网络出版时间:2024-06-07T14:07

资助项目:重庆市教育委员会科学技术研究计划重点项目(No. KJZD-K201900505);重庆市高校创新研究群体(No. CXQT20015);重庆市技术预见与制度创新项目(No. CSTB2022TFII-OFX0043);重庆师范大学研究生科研创新项目(No. YKC22016)

第一作者简介:陈怡达,男,研究方向为图像处理与机器视觉,E-mail:yida_myth@stu.cqnu.edu.cn;通信作者:曾绍华,男,教授,博士,E-mail:zsh_cqu@126.com

网络出版地址:https://link.cnki.net/urlid/50.1165.N.20240607.0919.004

研究成果,先后提出基于自适应密度峰值聚类算法^[21]、改进模糊 C 均值聚类(fuzzy C-means,FCM)算法^[22]等将土壤区域从机器视觉图像背景中分离;提出吸引权重加权 FCM 算法^[23]、基于密度峰值聚类算法^[24-25]等检测土壤图像阴影;为了扩充样本、尽可能消除样本图像不能完全覆盖自然光照条件的日照影响,通过加权高斯减法拟合实现土壤图像的可控亮度迁移^[26],丰富训练样本。上述预处理的相关研究均为实现“土种识别”这一最终目标,而本研究提出的“土壤子图切割、选择和识别”是机器视觉识别土种的关键步骤。

1 数据采集

依据《重庆市地方标准 DB50/T 796-2017:重庆土壤分类与代码》^[27],在重庆市璧山区用铁锹挖掘出 0~20 cm 耕层“心土”,拍摄“心土”自然断口图像作为实验样本,其中部分土壤原图样本如图 1 所示。



图 1 土壤原图样本
Fig. 1 Original soil image

在拍摄上述图像时,需让相机镜头距离“心土”土块自然断口 60~100 cm 且土壤位于图像正中心,土壤专家现场识别土壤后打土种标签,此外拍摄角度随机。采集到重庆市璧山区分布的 3 土属 11 土种紫色土“心土”土壤图像 270 张,具体情况见表 1。

表 1 土壤图像的土种分布
Tab. 1 Number of soil samples for each species

土属	土种	样本数量/张
暗紫泥土	油石骨子土	24
	夹砂土	10
	二泥土	31
	大泥土	43
灰棕紫泥土	石骨子土	22
	砂土	20
	半砂半泥土	22
	大眼泥土	7
红棕紫泥土	红石骨子土	28
	红紫砂泥土	27
	红棕紫泥土	36

2 子图选择算法

在土壤图像中获取一定大小的充满土壤的区域子图,因它包含了该土壤图像的特征信息,故称之为土壤子图。提取土壤子图,构造土壤子图数据集以用于后续模型训练与识别。土壤子图切割、选择和土种识别流程见图 2。

2.1 数据预处理

2.1.1 土壤区域图像分割

为了消除野外复杂背景对后续土种识别的不利影响,应用改进 FCM 算法^[22]对野外采集的土壤图像进行土

壤与背景分割,分割出的土壤区域图像用于土壤图像子图切割。

2.1.2 最小外接矩阵

对分割出的土壤区域图像去掉上、下、左、右白边,获得最小外接图 T ,对应标记 $0 \sim 1$ 的标记信息记为最小外接矩阵 t ;用最小外接图 T 的大小更新 $m, n \in \mathbf{N}$ 。外接矩阵域外无效的背景部分不参与计算,减少用时。




图2 土种识别流程

Fig. 2 Process of soil species classification

2.2 局部阴影最小化

2.2.1 子图中心点矩阵

为了能从小外接图 T 上切取 $s \times s$ 的全土壤子图,对最小外接矩阵 t 均值滤波,获得土壤子图中心点矩阵 C :

$$C(x, y) = \left[\frac{1}{s \times s} \sum_{(i, j) \in \Omega} t(i, j) \right]. \quad (1)$$

其中: Ω 是模板覆盖 $t(i, j)$ 中以 (x, y) 为中心的邻域; $t(i, j)$ 是最小外接标记矩阵 t 中 Ω 内的二值点。

在最小外接图 T 上,以土壤子图中心点矩阵 C 的非 0 点位为中心,任意切取 $s \times s$ 子图均为土壤子图。

2.2.2 构建局部亮度矩阵

由于土壤自然断口凹凸不平,存在空洞、裂缝等,造成土壤图像中有阴影和空洞、裂缝等情况。如果在阴影、空洞、裂缝等处切割土壤子图,可能淹没土壤本身的特征,进而影响土种识别。

土壤图像中阴影、空洞、裂缝等最明显的特征表现为亮度较暗。为了有效避开阴影、空洞、裂缝等对土壤子图影响,引入 HSV 颜色空间 V 通道 Ω 域均值构建土壤图像的局部亮度矩阵 W :

$$W(x, y) = \frac{1}{s \times s} \sum_{(i, j) \in \Omega} V(i, j). \quad (2)$$

W 中点值较小表示以该点为中心切取 $s \times s$ 土壤子图整体偏暗,阴影较多或有空洞、裂缝; W 中点值较大表示该点为中心切取 $s \times s$ 子图阴影较少,没有空洞、裂缝。

重置 W 为它与 C 矩阵的 Hadamard 积,重构局部亮度矩阵 W :

$$W = W \otimes C. \quad (3)$$

2.3 空间距离最大化

通过局部亮度矩阵可有效避免选择含大面积阴影、空洞、裂缝区域的子图。选择子图在没有大面积阴影、空洞、裂缝基础上,间距还应尽可能远,重叠度尽可能少,以确保土壤子图样本的多样性和独立性。

引入欧式距离构建距离矩阵 D ,维度与 C 矩阵相同,大小为 $m \times n$:

$$D_{i,j}(x, y) = \begin{cases} \sqrt{(i-x)^2 + (j-y)^2}, & C(x, y) = 1; \\ 0, & C(x, y) = 0. \end{cases} \quad (4)$$

式中: $D_{i,j}$ 是以点 (i, j) 为中心的距离矩阵, $C(x, y)$ 是子图中心点矩阵标记值。距离矩阵 $D_{i,j}$ 是以点 (i, j) 为中

心,与对应 C 矩阵标记点间的欧式距离,点 (i, j) 与非标记点距离为 0。




图 3 局部亮度矩阵生成过程

Fig. 3 The generation process of local luminance matrix

2.4 构建土壤子图数据集

2.4.1 决策子图中心点

融合亮度与空间距离信息,构建局部阴影最小化及空间距离最大化优化模型:

$$p_{i,j} = \arg \max(W \cdot D), \quad (5)$$

其中: $p_{i,j}$ 为融合局部亮度与空间距离矩阵中最大值所对应的点坐标 p , 它的横坐标为 i 、纵坐标为 j 。

借用最大最小距离^[28]选取尽可能远的点作为聚类中心的算法思想,选取与已选点较远的点为子图中心点,以减少切取子图的重叠度。应用最大最小距离更新距离矩阵,提出一种基于贪心的算法策略,迭代求解最优化模型,获取选择的子图中心点,以切取对应土壤子图,构建土壤子图数据集。

基于上述算法思想,获得土壤子图选择算法的详细算法步骤如下所示。

输入:土壤最小外接图 T ,选择子图个数 N ,子图大小 $s \times s$;

输出:土壤子图数据集 TrainSet;

过程:步骤 1:生成基于图像 T 的局部亮度矩阵 W ;

步骤 2:以局部亮度矩阵 W 中的最大值点,初始化当前子图中心点 p ;

步骤 3:用式(5)计算子图中心点 p 与其它点的距离矩阵 D' ;置 $\text{flag}=1$;

步骤 4:将点 p 对应 $W_{i,j}$ 置为 $-\text{flag}$;

Repeat{

步骤 5:用式(5)计算子图中心点 p 与其它点的距离矩阵 D'' ;

步骤 6:更新距离矩阵 $D = \min\{D', D''\}$;

步骤 7:求解优化模型 $\arg \max(W \cdot D)$,更新当前子图中心点 p ;

步骤 8: $\text{flag}++$;

步骤 9:将点 p 对应 $W_{i,j}$ 置为 $-\text{flag}$;

步骤 10:更新距离矩阵 $D' = D$;

}Until($N == \text{flag}$);

步骤 11:将 W 局部亮度矩阵中小于 0 的点放入子图中心点集 P ;

步骤 12:以集合 P 中每个点为中心,在土壤图像 T 上切取 $s \times s$ 的土壤子图存入土壤子图数据 TrainSet。

2.4.2 自适应获取土壤子图

根据一张土壤图像 T 的大小,自适应确定土壤子图数 N :

$$N = \lfloor (\alpha \cdot m \cdot n) / s^2 \rfloor \quad (6)$$

式中: α 为权重因子,用于自适应调节切取子图数量,后面将在实验部分对 α 取值进行讨论。

3 实验结果与分析

3.1 实验样本集

将共计 270 张采集到的重庆市璧山区共计 270 张 3 土属 11 土种紫色土的土壤图像依据土种不同按大约 3:1 的比例随机不重复分为训练图和测试图。

样本集 1:在土壤图像中心,以尺寸 224×224 为基准,分别以 224 的 0.25、0.5、0.75、1.0、1.5、2.0、2.5 倍为边长,切取正方形土壤区域代替土壤原图,构成 7 个土壤原图子集。依据土种,将每个土壤原图子集随机选择 80% 构成土壤原图训练集 TrainSet,余下 20% 图像构成土壤原图验证集 ValSet;测试图切取正方形土壤区域构成土壤原图测试集为 TestSet。

对于土壤子图构成的样本集,对每张训练图切取子图,随机选择 80% 子图放入该样本集土壤子图训练集 TrainSet;余下 20% 子图放入该样本集土壤子图验证集 ValSet;测试图切取的子图放入该样本集的测试集 TestSet。

样本集 2:土壤子图尺寸为 224×224 ,用本文提出子图选择算法以 5 个不同的 α 参数切取土壤子图构成 5 个子集。

样本集 3:分别以 224 像素的 0.25、0.5、0.75、1.0、1.5、2.0、2.5 倍为边长,用本文提出子图选择算法切取正方形土壤子图构成 7 个子集。

样本集 4:用本文提出子图选择算法和实验获得最佳土壤子图尺寸切取土壤子图,分别参入 0%、5%、10%、20% 和 30% 含大面积阴影或空洞具有破坏性的土壤子图样本构成 5 个子集。

3.2 实验设计

为验证本文子图选择算法的有效性,设计实验如下:

1) 实验 1:土壤原图识别精度实验。

用样本集 1 在 ResNet-18 等 3 个不同深度网络上,实验获得土壤原图识别精度。

2) 实验 2:土壤子图切割不同 α 参数对比实验。

用样本集 2 在 ResNet-18 等 3 个不同深度网络上,实验获取较优的切取土壤子图参数 α 。

3) 实验 3:土壤子图切割尺寸对比实验。

用样本集 3 在 ResNet-18 等 3 个不同深度网络上,实验获取较优的切取土壤子图尺寸。

4) 实验 4:子图选择算法效能对比实验。

用样本集 4 在 ResNet-18 等 3 个不同深度网络上,实验获取本文子图选择算法效能。

5) 实验 5:子图选择算法使用最小外接矩阵加速效能实验。

对 71 张测试图,分别进行采用和不采用最小外接矩阵加速实验对比,获得使用最小外接矩阵加速效能。

3.3 实验环境

子图选择算法实验环境:处理器 2.6 GHz 六核 Intel Core i7,内存 16 GB,未使用 GPU 加速;操作系统 Mac OS 12.1,PyCharm 专业版 2021.1,Python 3.8.5,opencv-python 4.5.1,numpy 1.19.5,matplotlib 3.3.3。

网络模型训练与测试实验在云服务器运行,云服务器环境配置为:处理器 2.50 GHz 八核 Intel(R) Xeon(R) Gold 6133,内存 32 GB,显卡型号 Tesla V100-SXM2,32 GB 显存,使用 GPU 加速;Centos Linux 操作系统 release 7.8.2003(Core),Python 3.8.5,torch 1.7.0,torchvision 0.8.0。

3.4 网络模型选择及实验参数

选择图像分类领域中经典的不同深度 ResNet^[29] 残差神经网络作为实验的分类模型,分别为:ResNet-18、ResNet-34 和 ResNet-50。土种识别网络模型训练参数。

为保证实验可重复性,将各类随机数种子置为 2022;归一化参数在训练集中抽样计算得出;训练网络时统计每个 epoch 的训练损失及验证集准确率;保存最后一个 epoch 的模型参数 last.pth,加载模型参数后在测试集上进行最终测试;因显存消耗不同,训练模型时调整相应 BatchSize 大小。

测试时,应用子图选择算法对每张土壤图像切取土壤子图(与训练集切取子图方法及参数一致),对同一张土壤图像切取的子图逐张识别,以该张土壤图像所有子图识别为某个土种概率最大决策识别结果。

3.5 实验结果与分析

3.5.1 实验 1 的土壤原图识别精度实验结果与分析

样本集 1 中土壤原图训练集 TrainSet 共 160 张图像,土壤原图验证集 ValSet 共 39 张图像,土壤原图测试集

为 TestSet 共 71 张图像。

受限于数据量,将 BatchSize 大小统一设为 40。采用 7 种大小规格的土壤原图子集在 ResNet-18 等 3 个不同深度的网络模型上训练和测试。训练过程见图 4,识别结果见表 3。

表 2 模型训练参数
Tab. 2 Training parameters of Models

名称	训练参数	名称	训练参数
优化器	Adam	num_workers	4
初始学习率	1E-4	是否-Shuffle	是
损失函数	CrossEntropyLoss	开启-混合精度	是
weight_decay	1E-4	Nomalize	(0.49,0.37,0.31),(0.16,0.15,0.14)
Epoch	120	随机数种子	2022




图 4 土壤原图训练过程
Fig. 4 Training process of original soil image

图 4 显示,3 个模型的训练损失值均能有效降低。但 ResNet-50 损失曲线波动较大,ResNet-18 更加平滑,ResNet-34 则在两者之间。3 个模型验证集准确率在训练时均出现剧烈震荡,无法有效收敛。不同分辨率构成的土壤原图数据集波动程度不同,在大分辨率土壤原图上能得到更好的验证集准确率。其中,ResNet-18 在原图分辨率为 560 时能得到最好的测试结果为 63.38%。

表 3 结果显示,识别精度较低;识别结果并未随着模型深度增加而提高;在原图上切取的土壤区域,尺寸较大子集的土壤特征能得到更好呈现,但测试结果仍然很差。原因在于土壤图像数据量有限,直接对原图识别波动较大,不能得到理想的识别结果。另外,土壤纹理等特征存在不确定性,当切取的土壤特征中有较多阴影和空洞、裂缝时,则无法有效识别土种。

表 3 土壤原图识别结果
Tab. 3 Classification results of original soil image

序号	图像大小	ResNet-18 识别准确率		ResNet-34 识别准确率		ResNet-50 识别准确率	
		验证集	测试集	验证集	测试集	验证集	测试集
1	56	0.25	0.281 6	0.136 4	0.281 6	0.227 3	0.225 3
2	112	0.272 7	0.323 9	0.295 5	0.352 1	0.204 5	0.267 6
3	168	0.272 7	0.394 3	0.295 5	0.394 3	0.272 7	0.338 0
4	224	0.386 4	0.492 9	0.340 9	0.338 0	0.250 0	0.436 6
5	336	0.409 1	0.549 2	0.409 1	0.535 2	0.295 5	0.380 2
6	448	0.477 3	0.563 3	0.363 6	0.492 9	0.386 4	0.436 6
7	560	0.500 0	0.633 8	0.340 9	0.5915	0.454 5	0.532 5

注:加黑的数据表示测试中得到的最好结果。下同。

3.5.2 实验 2 的子图切割不同 α 参数实验结果与分析

样本集 2 在 ResNet-18 等 3 个不同深度的网络模型上训练和识别。为最大限度利用显存,保证各模型显存不超过最大值,子图尺寸在 224×224 下训练模型时 *BatchSize* 模型参数统一设为 600。训练过程见图 5,识别结果见表 4。

图 5 显示,基于土壤子图数据集比土壤原图有更好的训练收敛特性,3 个模型训练损失均能快速降低。当 α 取 0.5 时,3 个模型验证集均表现最差。随着 α 取值增加,3 个模型的验证集准确率逐步提升,均比基于土壤原图训练有更好的验证准确率。其中,ResNet-18 不同 α 下验证集准确率较为接近,ResNet-34 和 50 差异更大。

表 4 结果显示,对一张土壤图像的土壤子图逐张识别,该张土壤图像所有子图识别为某个土种概率最大决策识别结果,能大大提高模型鲁棒性及容错率,有效提升土种识别效果。

土壤子图数据集比直接对土壤原图训练识别模型准确率各方面均有大幅度提升。不同 α 参数下构建的土壤子图数据集,样本数不同,会导致子图样本拥有不同的重叠度。随着数量的不断增加,子图重叠度更高,测试、验证集准确率总体呈上升趋势。

当网络模型深度不同时,最佳的土壤子图 α 参数有区别。对于特殊的土壤图像而言,并非一味的堆叠网络深度就能拥有更好的识别结果。在 ResNet-18 网络中,当 α 取 1.0、1.5 和 2.0 时均能得到最佳的测试结果,即为 92.95%。综合考虑实验 2 的算法用时、子图重叠度和数据量, α 取值为 1 是比较合适的。

3.5.3 实验 3 的子图切割尺寸对比试验结果与分析

样本集 3 在 ResNet-18 等 3 个不同深度的网络模型上训练和识别。为最大限度利用显存且保证各模型显存不超过最大值,在训练时将尺寸为 56、112、168、224、336、448 和 560 的子图的 3 个模型参数 *BatchSize* 均分别设为 9 600、2 400、1 066、600、266、150 和 96。训练过程见图 6,识别结果见表 5。

图 6 显示,子图尺寸太小和太大都可能出现训练收敛振荡。3 个模型均在子图尺寸为 56 时,训练过程中损失值出现大幅度变化,ResNet-34 还在子图尺寸为 112 时出现相同情况。ResNet-34 和 ResNet-50 在不同子图尺寸间验证集准确率波动较大,而 ResNet-18 验证集准确率相对平稳。

表 5 结果表明,子图尺寸太小或太大均无法进行有效识别;相同尺寸下,浅层网络整体能拥有更好的识别结果,不同深度的模型的最佳子图尺寸不完全相同。当子图尺寸为 224×224 时,在 ResNet-18 下能够获得最好的测试结果为 92.95%。




图 5 不同 α 构建的土壤子图数据集训练过程

Fig. 5 Training process of soil sub-image datasets constructed with different α

表 4 不同 α 构建的土壤子图数据集识别结果

Tab. 4 Classification results of soil sub-image datasets constructed with different α

序号	自适应因子	实验样本数/张			ResNet-18		ResNet-34		ResNet-50	
		训练子图数	验证子图数	测试原图	验证集	测试集	验证集	测试集	验证集	测试集
1	0.5	5 740	1 571	71	0.813 5	0.830 9	0.690 0	0.760 5	0.684 9	0.718 3
2	1.0	11 667	3 059	71	0.924 8	0.929 5	0.846 0	0.816 9	0.864 0	0.845 0
3	1.5	17 591	4 540	71	0.954 8	0.929 5	0.926 2	0.915 4	0.893 0	0.816 9
4	2.0	23 526	6 030	71	0.970 8	0.929 5	0.964 7	0.873 2	0.925 7	0.816 9
5	2.5	29 454	7 510	71	0.897 6	0.816 9	0.977 2	0.873 2	0.953 0	0.859 1




图 6 不同子图尺寸构建的土壤子图数据集训练过程

Fig. 6 Training process of soil sub-image datasets constructed with different sub-image sizes

表 5 不同子图尺寸构建的土壤子图数据集识别结果

Tab. 5 Classification results of soil sub-image datasets constructed with different sub-image sizes

序号	子图分辨率	实验样本数/张			ResNet-18		ResNet-34		ResNet-50	
		训练子图数	验证子图数	测试原图	验证集	测试集	验证集	测试集	验证集	测试集
1	56	184 576	46 296	71	0. 724 2	0. 859 1	0. 682 7	0. 816 9	0. 574 4	0. 788 7
2	112	46 815	11 853	71	0. 831 4	0. 873 2	0. 827 6	0. 746 4	0. 697 1	0. 774 6
3	168	20 819	5 351	71	0. 898 7	0. 887 3	0. 845 1	0. 859 1	0. 793 3	0. 802 8
4	224	11 667	3 059	71	0. 924 8	0. 929 5	0. 846 0	0. 816 9	0. 864 0	0. 845 0
5	336	5 097	1 411	71	0. 871 7	0. 718 3	0. 895 8	0. 802 8	0. 749 8	0. 619 7
6	448	2 789	844	71	0. 971 6	0. 802 8	0. 874 4	0. 774 6	0. 740 5	0. 591 5
7	560	1 709	573	71	0. 925 0	0. 760 5	0. 928 4	0. 732 3	0. 757 4	0. 563 3

3.5.4 实验 4 的子图选择算法效能试验结果与分析

在最佳土壤子图分辨率 224×224 下,构成的土壤子图数据集为 TrainSet。为探究阴影、空洞、裂缝等对识别结果的影响,分别手动加入 5%、10%、20% 和 30% 具有破坏性的子图样本,构成破坏性子图数据集 TrainBroke_0.05、TrainBroke_0.1、TrainBroke_0.2 和 TrainBroke_0.3。破坏性子图样本随机选择从局部亮度矩阵中小于整体范围 30% 的子图中心点中切取。验证集与测试集与 TrainSet 保持相同。

样本集 4 在 ResNet-18 等 3 个不同深度的网络模型上训练和测试。训练过程见图 7,识别结果见表 6。




图 7 插入不同破坏程度的土壤子图数据集训练过程

Fig. 7 Training process of inserting soil sub-image datasets with different degrees of damage

图 7 显示伴随着破坏性样本的加入,训练收敛过程的振荡加剧。3 个模型训练损失均能逐步下降,但在 ResNet-50 中损失曲线相对平稳,ResNet-18 和 ResNet-34 训练过程中损失曲线均有突出的起伏。ResNet-50 验证集准确率相对稳定,变换幅度相近;而对于 ResNet-18 和 ResNet-34 加入不同破坏程度样本后,对训练过程的影响程度大,造成验证集准确率剧烈震荡。

表 6 结果表明:随着破坏性样本的加入,验证集的整体准确率逐步下降;测试时识别每张土壤子图,共同决策的识别结果,仍能取得较好测试结果。

表 6 插入不同破坏程度的土壤子图数据集识别结果

Tab. 6 Classification results of inserting soil sub-image datasets with different degrees of damage

数据集	ResNet-18		ResNet-34		ResNet-50	
	验证集	测试集	验证集	测试集	验证集	测试集
TrainSet	0.924 8	0.929 5	0.846 0	0.816 9	0.864 0	0.845 0
TrainBroke_0.05	0.890 5	0.873 2	0.862 5	0.859 1	0.851 3	0.873 2
TrainBroke_0.1	0.874 8	0.915 4	0.818 9	0.859 1	0.828 0	0.830 9
TrainBroke_0.2	0.848 3	0.859 1	0.773 8	0.788 7	0.828 7	0.802 8
TrainBroke_0.3	0.807 5	0.816 9	0.738 8	0.788 7	0.774 1	0.788 7

当混入的破坏性样本数较少时,由于采用迭代次数终止网络模型训练,参杂破坏性子图样本识别错误,不足以影响到整个网络训练,测试集出现不确定波动;当加入大量破坏性样本时,测试集准确率逐步降低。但总体上看,包含阴影和空洞、裂缝的土壤子图训练网络模型将影响识别结果;子图不经选择而包含大量破坏性样本,会大幅度降低深度网络的土种识别精度。

3.5.5 实验 5 的最小外接矩阵加速效能实验结果

子图尺寸为 224×224 ,设置不同子图选择算法 α 参数,切取土壤子图,构建土壤子图数据集。统计是否使用最小外接矩阵加速子图选择算法的时间消耗。

图 8 显示使用最小外接矩阵加速子图选择算法能够在 α 参数分别为 0.5、1.0、1.5、2.0 和 2.5 时,算法运行速度提升:37.91%、38.88%、41.49%、42.06%和 41.37%。

子图选择算法自适应参数 α 取 1 时,切取不同尺寸大小的土壤子图,构建土壤子图数据集。统计是否使用最小外接矩阵加速子图选择算法的时间消耗见图 9。图 9 显示,使用最小外接矩阵加速子图选择算法能够在切取子图尺寸分别为 56、112、168、224、336、448 和 560 时,算法运行速度提升分别为 38.17%、39.43%、39.31%、38.88%、40.68%、45.77%和 47.38%。

上述实验结果均表明,使用最小外接矩阵能有效加速子图选择算法运行速度。




图 8 不同自适应因子 α 的算法时间

Fig. 8 Time cost with different adaptive factors α




图 9 不同子图尺寸的算法时间

Fig. 9 Time cost with different sub-image sizes

3.6 最佳实验结果

上述实验结果显示:实验 2 子图选择算法参数 α 设为 1 时,最能够均衡算法时间效率和识别准确率;实验 3 确定的最佳子图分辨率为 224×224 ;实验 4 包含阴影、空洞和裂缝的土壤子图训练网络模型,将影响识别结果;实验 5 表明使用最小外接矩阵均能有效加速子图选择算法;基于土壤子图选择算法的土种识别方法比实验 1 直接基于原图进行识别有大幅度性能提升。

最优子图选择算法的子图尺寸为 224×224 、算法参数 α 为 1,构成的土壤子图数据集 TrainSet,在 ResNet-18 模型下能得到最好的测试结果为 92.95%。土种识别最佳测试结果的分类评价指标见表 7。

表 7 最佳土种识别模型的分类评价指标

Tab. 7 Classification evaluation index of the best soil classification model

类标签	土种	精度	召回率	F1 值	样本数量/张
0	暗紫泥二泥土	0.750 0	0.750 0	0.750 0	8
1	暗紫泥大泥土	0.916 7	1.000 0	0.956 5	11
2	暗紫泥夹砂土	1.000 0	1.000 0	1.000 0	3
3	暗紫泥油石骨子土	1.000 0	1.000 0	1.000 0	6
4	灰棕紫泥半沙半泥土	1.000 0	1.000 0	1.000 0	6
5	灰棕紫泥大眼泥土	0.666 7	1.000 0	0.800 0	2
6	灰棕紫泥石骨子土	1.000 0	1.000 0	1.000 0	7
7	灰棕紫泥砂土	1.000 0	0.800 0	0.888 9	5
8	红棕紫泥红棕紫泥土	0.909 1	1.000 0	0.952 4	10
9	红棕紫泥红石骨子土	1.000 0	0.857 1	0.923 1	7
10	红棕紫泥红棕紫泥土	1.000 0	0.833 3	0.909 1	6

土种识别的精度、召回率和 F1 值的平均值分别为 93.11%、93.05% 和 92.54%，对应混淆矩阵结果如图 10 所示。




图 10 土种识别混淆矩阵

Fig. 10 Confusion matrix for soil classification

4 结束语

紫色土机器视觉土种识别,在三峡库区精准农业发展上有较高的应用价值。本文基于子图选择算法构建的土壤子图数据集,能够训练得到鲁棒性更强的识别模型,测试时基于子图识别概率最大决策识别结果,能得到稳定的识别结果,并有效提升机器视觉识别土种准确率。

提升土种识别精度,是机器视觉土种识别追求的目标。就网络特性而言,浅层的卷积神经网络似乎更能有效完成特征提取;新的网络模型 Vision in transformer 中提取土壤图像特征是否更高效,在将来值得深入探究。

参考文献:

[1] HE X B,BAO Y H,NAN H W,et al. Tillage pedogenesis of purple soils in southwestern China [J]. Journal of Mountain Science,2009,6:205.

[2] KHAN A,SOHAIL A,ZAHOORA U,et al. A survey of the recent architectures of deep convolutional neural networks[J]. Artificial Intelligence Review,2020,53(8):5455-5516.

- [3] 赵瑞,吴克宁,杨淇钧,等. 基于土壤功能与胁迫的耕地土壤健康评价方法[J]. 农业机械学报,2021,52(6):333-343.
ZHAO R, WU K N, YANG Q J, et al. Farmland soil health evaluation method based on soil function and soil threat[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(6): 333-343.
- [4] GANATRA N, PATEL A. Deep learning methods and applications for precision agriculture[J]. Machine Learning for Predictive Analysis, 2021: 515-527.
- [5] 张文,李林珂,吴焦焦,等. 引种玫瑰营养生长对重庆市3种土壤类型的响应[J]. 重庆师范大学学报(自然科学版),2020,37(3): 138-144.
ZHANG W, LI L K, WU J J, et al. Response of vegetative growth of introduced roses to three soil types in Chongqing[J]. Journal of Chongqing Normal University (Natural Science), 2020, 37(3): 138-144.
- [6] 谭雪,董智,张丽苗,等. 三峡库区消落带3种人工种植植物土壤理化性质、酶活性及细菌多样性季节变化特征[J]. 重庆师范大学学报(自然科学版),2023,40(4):59-69.
TAN X, DONG Z, ZHANG L M, et al. Seasonal dynamics of soil physicochemical properties, enzyme activity and bacterial diversity of three re-vegetation species in the riparian zone of the Three Gorges Reservoir Area[J]. Journal of Chongqing Normal University (Natural Science), 2023, 40(4): 59-69.
- [7] WU W, LI A D, HE X H, et al. A comparison of support vector machines, artificial neural network and classification tree for identifying soil texture classes in southwest China[J]. Computers and Electronics in Agriculture, 2018, 144: 86-93.
- [8] AZIZI A, GILANDEH Y A, MESRI-GUNDOSHMIAN T, et al. Classification of soil aggregates: a novel approach based on deep learning[J]. Soil and Tillage Research, 2020, 199: 104586.
- [9] SRIVASTAVA P, SHUKLA A, BANSAL A. A comprehensive review on soil classification using deep learning and computer vision techniques[J]. Multimedia Tools and Applications, 2021, 80(10): 14887-14914.
- [10] ABIMALA T, SASHYA S F, SRIPRIYA K. Soil classification and crop suggestion using image processing[EB/OL]. (2020-06-03)[2023-02-28]. <https://easychair.org/publications/preprint/5gZm>.
- [11] SHIVHARE S, CECIL K. Automatic soil classification by using gabor wavelet & support vector machine in digital image processing[C]//2021 Third International Conference on Inventive Research in Computing Applications, September 2-4, 2021, Coimbatore, India. New York: IEEE, 2021: 1738-1743.
- [12] PANDEY A, KUMAR D, CHAKRABORTY D B. Soil type classification from high resolution satellite images with deep CNN [C]//2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS, July 11-16, 2021, Brussels, Belgium. New York: IEEE, 2021: 4087-4090.
- [13] DUAN M, ZHANG X. Using remote sensing to identify soil types based on multiscale image texture features[J]. Computers and Electronics in Agriculture, 2021, 187: 106272.
- [14] SAGAYARAJ A S, KABILESH S K, MOHANAPRIYA D, et al. Determination of soil moisture content using image processing: a survey[C]//2021 6th International Conference on Inventive Computation Technologies, January 20-22, 2021, Coimbatore, India. New York: IEEE, 2021: 1101-1106.
- [15] SMITH A G, PETERSEN J, SELVAN R, et al. Segmentation of roots in soil with U-Net[J]. Plant Methods, 2020, 16(1): 1-15.
- [16] MANIYATH S R, HEBBAR R, AKSHATHA K N, et al. Soil color detection using KNN classifier[C]//KELLENBERGER P. Proceedings of 2018 International Conference on Design Innovations for 3Cs Compute Communicate Control. Piscataway: IEEE, 2018: 52-55.
- [17] BARMAN U, CHOUDHURY R D. Soil texture classification using multi class support vector machine[J]. Information Processing in Agriculture, 2020, 7(2): 318-332.
- [18] INAZUMI S, INTUI S, JOTISANKASA A, et al. Artificial intelligence system for supporting soil classification[J]. Results in Engineering, 2020, 8: 100188.
- [19] RONALDO A D. Effective soil type classification using convolutional neural network[J]. International Journal of Informatics and Computation, 2021, 3(1): 20-29.
- [20] 刘颖,雷研博,范九伦,等. 基于小样本学习的图像分类技术综述[J]. 自动化学报,2021,47(2):297-315.
LIU Y, LEI Y B, FAN J L, et al. Survey on image classification technology based on small sample learning[J]. Acta Automatica Sinica, 2021, 47(2): 297-315.
- [21] 曾绍华,唐文密,詹林庆,等. 基于自适应密度峰值聚类的野外紫色土彩色图像分割[J]. 农业工程学报,2019,35(19):200-208.
ZENG S H, TANG W M, ZHAN L Q, et al. Color image segmentation of field purple soil based on adaptive density peaks clustering[J]. Transactions of the Chinese Society of Agricultural Engineering, 2019, 35(19): 200-208.
- [22] ZENG S H, WU Y L, WANG S, et al. Adaptive scale weighted fuzzy C-Means clustering for the segmentation of purple soil

- color image[J]. Journal of Intelligent & Fuzzy Systems, 2021, 40(6): 11201-11215.
- [23] 余春燕, 曾绍华, 王帅, 等. 吸引权重加权 FCM 的土壤图像阴影检测[J]. 重庆师范大学学报(自然科学版), 2020, 37(6): 114-125.
- SHE C Y, ZENG S H, WANG S, et al. Shadow detection of soil image based on attraction-weighted FCM[J]. Journal of Chongqing Normal University (Natural Science), 2020, 37(6): 114-125.
- [24] ZENG S H, WANG Q, WANG S, et al. Density peak clustering for shadow detection of soil image[J]. Signal, Image and Video Processing, 2023, 17: 839-847.
- [25] ZENG S H, WANG Q, WANG S, et al. Shadow detection of soil image based on density peak clustering and histogram fitting [J]. Journal of Intelligent & Fuzzy Systems: Applications in Engineering and Technology, 2022(3): 2963-2971.
- [26] 曾绍华, 赵秉渝, 王帅, 等. 加权高斯减法拟合的亮度可控土壤图像增强[J]. 光子学报, 2022, 51(4): 356-375.
- ZENG S H, ZHAO B Y, WANG S, et al. Controllable brightness enhancement of the soil image based on weighted Gaussian subtraction fitting[J]. Acta Photonica Sinica, 2022, 51(4): 356-375.
- [27] 重庆市农业技术推广总站, 西南大学, 重庆土壤学会, 等. 重庆市地方标准 DB50/T 796-2017: 重庆土壤分类与代码[S]. 重庆: 重庆市质量技术监督局, 2017.
- Chongqing Agricultural Technology Extension Station, Southwest University, Chongqing Soil Science Society, et al. Chongqing local standard DB50/T 796-2017: classification and codes for Chongqing soil[S]. Chongqing: Chongqing Quality and Technical Supervision Bureau, 2017.
- [28] 周涓, 熊忠阳, 张玉芳, 等. 基于最大最小距离法的多中心聚类算法[J]. 计算机应用, 2006(6): 1425-1427.
- ZHOU J, XIONG Z Y, ZHANG Y F, et al. Multiseed clustering algorithm based on max-min distance means[J]. Journal of Computer Applications, 2006(6): 1425-1427.
- [29] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//O'CONNER L. Proceedings of the 29th IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2016: 770-778.

Resources, Environment and Ecology in Three Gorges Area

Soil Species Classification Based on Subgraph Selection: Take the Purple Soil in Bishan District, Chongqing City as an Example

CHEN Yida^{1,2}, ZENG Shaohua^{1,2}, WU Xue³, WANG Shuai⁴, LIU Guoyi⁵, ZHOU Peng⁶

(1. College of Computer and Information Science, Chongqing Normal University;

2. Chongqing Center of Engineering Technology Research on Digital Agricultural Service, Chongqing 401331;

3. The Center of Agricultural Technology Promotion of Nanchuan District, Nanchuan Chongqing 408400;

4. Chongqing Master Station of Agricultural Technology Promotion, Chongqing 400121; 5. Institute of

Agricultural Resources and Environment, Tibet Academy of Agricultural and Animal Husbandry Sciences, Lhasa 850032;

6. The Center of Agricultural Technology Service of Fengjie County, Fengjie Chongqing 404600, China)

Abstract: The presence of shadows, holes, and gaps on soil images collected under natural conditions has a significant negative impact on machine vision classification of soil species. And the sample size for machine vision-based soil species identification is generally insufficient due to the high cost of acquiring and labeling soil photographs. A soil species classification method is presented based on subgraph selection to address above problems. The proposed approach first constructs an optimal model to select the centers of soil subgraph according to the principles of local shadow minimization and spatial distance maximization. And then creates a soil sub-image dataset on the basis of a center set obtained by iteratively updating a distance matrix utilizing above optimization model. Experimental results demonstrate that soil subgraph datasets established by the subgraph selection algorithm exhibit excellent performance on three ResNet models with different depths. ResNet-18 performs best when setting the adaptive factor α to 1 and the sub-image size is 224, with a validation set classification accuracy of 92.48% and a test set classification accuracy of 92.95%. In addition, it is 46.65% superior than the best classification result of the soil species classification model trained with the original soil image dataset. These prove that the accuracy of soil classification based on the subgraph selection algorithm is promoted and the algorithm is effective.

Keywords: soil species classification; subgraph selection; deep learning; soil image

(责任编辑 黄 颖)