

doi:10.6041/j.issn.1000-1298.2024.12.030

基于一致性半监督学习的苹果叶片病斑分割模型研究

丁永军 杨文涛 赵一龙

(西北师范大学计算机科学与工程学院, 兰州 730070)

摘要: 快速准确的病斑分割对于病害严重程度评估及科学施药具有重要意义。基于深度学习的语义分割为构建高精度病斑分割模型提供了技术支撑。然而, 苹果病斑标注费时费力。为了解决这一问题, 以陇东苹果为研究对象, 提出了一种基于轻量级一致性半监督学习框架的苹果叶片病斑分割模型。首先, 遵循 Mean Teacher 半监督学习框架, 使用 2 个轻量化的 DeepLabV3+ 模型, 构建病斑语义分割模型, 以提高模型从有限标注数据中提取特征描述符的能力。其次, 对比 19 种一致性正则化方法, 发现 MSE + Huber 组合对图像的细微差异更敏感、抗噪性更高, 可提高模型对病斑过小、分布不均、边缘模糊的适应性。接着, 使用贝叶斯优化算法对模型涉及的 6 个超参数进行寻优, 以加快模型收敛速度和稳定性。结果表明, 优化后模型仅使用 30% 的标注数据, 病斑分割精确率达到 95.60%, 平均交并比为 94.85%, 平均像素准确率为 96.50%。效果均优于全监督和自训练半监督学习框架。

关键词: 苹果病害; 痘斑分割; 半监督学习; 一致性正则化; 贝叶斯优化; DeepLabV3+

中图分类号: S24 文献标识码: A 文章编号: 1000-1298(2024)12-0314-08

OSID: 

Apple Leaf Spot Segmentation Model Based on Consistency Semi-supervised Learning

DING Yongjun YANG Wentao ZHAO Yilong

(College of Computer Science and Engineering, Northwest Normal University, Lanzhou 730070, China)

Abstract: Rapid and accurate lesion segmentation was essential for assessing disease severity and ensuring precise pesticide application. Deep learning-based semantic segmentation offered the technical foundation necessary for developing high-precision disease detection models. However, the annotation of apple leaf spots was both time-consuming and labor-intensive. To address this issue, a model for apple leaf spot segmentation was proposed based on a lightweight consistency semi-supervised learning framework, using Longdong apples as the research subject. Firstly, following the Mean Teacher semi-supervised learning framework, two lightweight DeepLabV3+ models were utilized to build the lesion semantic segmentation model, which improved its ability to extract feature descriptors from limited annotated data. Secondly, a systematic comparison of 19 consistency regularization methods revealed that the combination of MSE and Huber was more sensitive to subtle image differences and exhibited higher noise resistance, thereby improving the model's adaptability to small, unevenly distributed, and blurred-edge lesions. Next, a Bayesian algorithm was utilized to optimize six hyperparameters involved in the model, which accelerated convergence speed and enhanced stability. The results demonstrated that the optimized model, using only 30% of the annotated data, achieved a precision of 95.60%, a mean intersection over union (mIoU) of 94.85%, and a mean pixel accuracy (mPA) of 96.50%. These outcomes surpassed those of fully supervised and self-training semi-supervised learning frameworks. The findings offered agricultural practitioners an efficient and reliable tool for disease detection.

Key words: apple diseases; disease spot segmentation; semi-supervised learning; consistency regularization; Bayesian optimization; DeepLabV3+

收稿日期: 2024-07-30 修回日期: 2024-09-02

基金项目: 国家自然科学基金项目(32360434)、甘肃省高校产业支撑计划项目(2023CYZC-10)和甘肃省自然科学基金项目(23JRRRA705)

作者简介: 丁永军(1978—),男,教授,博士,主要从事农业信息化技术研究,E-mail: dingyj@nwnu.edu.cn

0 引言

陇东黄土高原是中国苹果主产区^[1],但陇东苹果易受褐斑病、锈病和灰斑病影响^[2-3]。目前,苹果病害的控制主要依赖于传统化学药剂,主要包括甲基硫菌灵、吡虫啉、毒死蜱、戊唑醇和嘧菌酯等^[4]。然而,长期、过量、无差别的使用农药不仅会造成空气、水、土壤的严重污染,而且农药残留在非靶标动植物体内也可能导致动植物习性及生命规律发生变化^[5]。农业行业标准 NY/T 992—2006《风送式果园喷雾机 作业质量》规定,病斑面积占比是判定病害等级的重要标准,当占比小于 10% 为 1 级、11% ~ 25% 为 3 级、26% ~ 40% 为 5 级、41% ~ 65% 为 7 级、大于 65% 为 9 级^[6]。传统的病害调查方法存在工作量大、工作效率低等问题^[7]。因此,快速准确的病斑分割对于病害严重程度评估及科学施药具有重要意义。

许多学者使用 Faster R-CNN、YOLO、SSD 等目标检测方法定位农作物病斑^[8-10]。这些方法的共同特点是通过深度卷积神经网络(CNN)提取图像特征,然后使用锚框(Anchor boxes)或区域提议(Region proposals)生成候选检测框。通过边界框回归(Bounding box regression)精确调整检测框的位置和尺寸,从而实现对目标的准确定位。但在复杂背景中,病斑边界模糊且形状多变,检测框很难严密覆盖病斑^[11]。语义分割能够对图像中的每个像素进行分类,具有精确分割病斑的潜力。DEEPAK 等^[12]使用 PSPNET 实现小麦叶锈病感染程度估计,但模型中的金字塔池化容易造成病斑细节丢失。王翔宇等^[13]利用 U-Net 构建了黄瓜褐斑病语义分割模型,其准确率达到 96.23% ~ 97.98%,但 U-Net 网络全局上下文捕捉能力相对较弱,复杂场景处理能力不足。LI 等^[14]使用改进的 BiSeNet 对黄瓜白粉病和霜霉病进行分割,每秒可以处理 94 幅图像,但模型 mIoU 仅为 82.39%。KAUR 等^[15]使用改进的 SegNet 对番茄单叶病斑进行分割,精度达到 94.91%,但模型使用最大池化索引进行上采样,容易忽略微小病斑。DeepLabV3+ 中的 ASPP 模块使用多个并行的空洞卷积分支,能有效捕捉不同尺度的病斑信息,而解码器能对浅层图像特征与深层语义特征进行融合,并多次使用双线性插值上采样,具有更强的细节恢复能力^[16-17]。

上述研究大都要求使用完全标注的数据进行模型训练。由于病斑具有不规则、无序、无结构、非均匀、易受噪声干扰等特点,使得大量的精准标注难度很大、费时费力。半监督学习可以从有限的标注数

据中提取特征描述符和局部几何结构,并生成高置信度的伪标签,从而降低模型训练对标注数据的依赖。因此,使用 DeepLabV3+ 构造苹果病斑分割的半监督学习框架是可行的。一致性正则化(Consistency regularization)是一种常见的半监督学习技术。其核心思想是通过在损失函数中添加一致性正则项,确保无标签数据在经过不同的扰动后,模型输出尽量保持一致。然而,不同的一致性正则化方法在各个数据集上具有不同的类内紧凑性和类间可分离性^[18-22]。另外,有标签数据的损失函数和未标注数据的一致性约束都需要设置相应的超参数,而且两者之间也需要进行权重分配。人工先验调整法和关联函数法是常见的超参数设置方法^[23-26]。人工先验方法相对简单,但试验流程较繁琐。ZENG 等^[27]利用关联函数进行动态权重调节,但该方法需要对各个约束项间的关联进行建模,流程复杂。

针对苹果病害分割中标注数据稀缺问题,本文提出一种基于 DeepLabV3+ 的轻量级半监督学习策略,并通过对比试验对一致性正则化进行最优选择,又通过贝叶斯优化(Bayesian optimization, BO)算法对有监督损失及一致性正则化进行超参数寻优,构建苹果病斑分割模型,以期为田间管理提供技术支持。

1 材料与方法

1.1 数据集

在自然光照条件下,分别在甘肃省庆阳市宁县现代农业产业园和正宁县榆林子镇海升苹果种植基地,使用 Realme 大师探索版智能手机采集褐斑病(brown spot)、锈病(rust)、灰斑病(grey spot)以及健康叶片(health)图像各 400 幅。使用 Labelme 软件对病斑及叶片进行多边形标记。如图 1 所示,受光照条件、叶片重叠、病斑过小、病斑分布不均及病斑边缘模糊等因素的影响,大量标注及精准病斑分割难度很大。

1.2 病斑分割模型

1.2.1 DeepLabV3+

DeepLabV3+ 通过多尺度特征提取以及浅层图像特征与深层语义特征的融合,具有较强的病斑细节恢复能力,是一个表现出色的语义分割模型。如图 2 所示,DeepLabV3+ 采用编码器-解码器结构。其中,编码层包括 MobileNetV2 和空间金字塔池化模块(Atrous spatial pyramid pooling, ASPP)。MobileNetV2 替换原始 DeepLabV3+ 中的 Xception 主干网络,MobileNetV2 使用深度可分离卷积和逐点



图 1 受多种不利条件影响的试验样本示例

Fig. 1 Examples of experimental samples affected by various adverse conditions

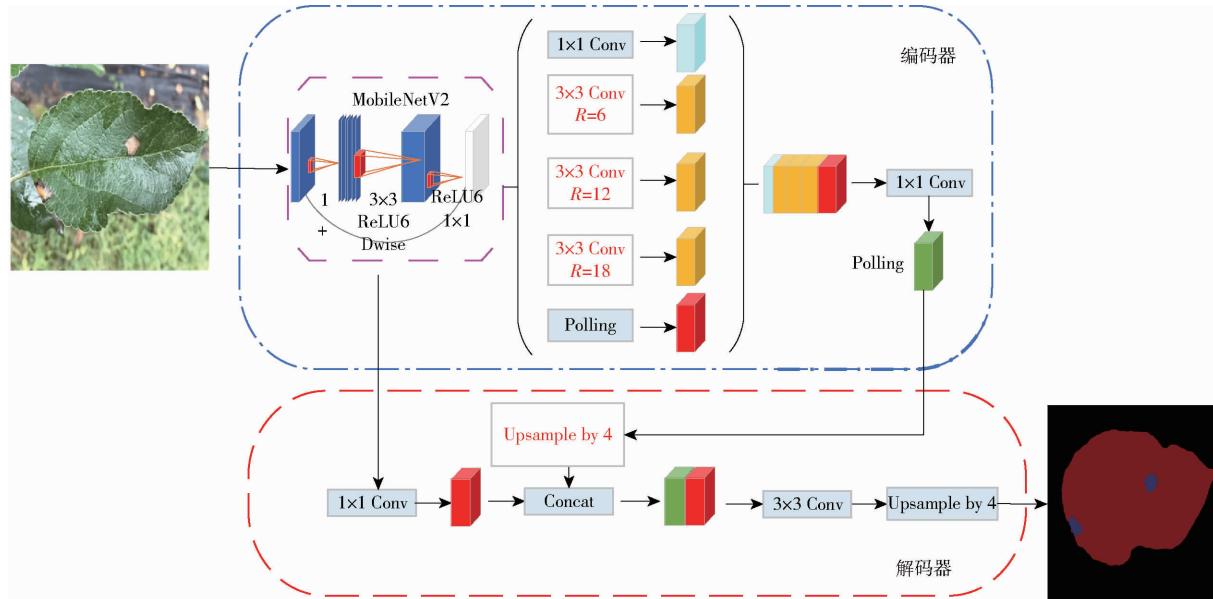


图 2 DeepLabV3 + 模型结构图

Fig. 2 Structure diagram of DeepLabV3 + model

卷积,有效减少参数量,模型规模约为 Xception 的 10%,而且卷积模块间使用反向残差连接,有助于模型提高性能。MobileNetV2 对规格为 $512 \times 512 \times 3$ 的彩色图像进行特征化处理,将第 4 层倒残差结构提取到的规格为 $128 \times 128 \times 256$ 的特征图作为浅层图像特征送入解码器,同时将第 17 层倒残差结构提取到的规格为 $32 \times 32 \times 512$ 的特征图作为高层语义特征送入 ASPP 模块。ASPP 中包含 1 个 1×1 卷积层,空洞率分别为 6、12 和 18 的空洞卷积以及 1 个全局平均池化层,从多种尺度对高层语义特征进行空间金字塔池化处理,最后又通过 1×1 卷积对各尺度特征进行降维,并整合成规格为 $32 \times 32 \times 512$ 的特征图送入解码器。在解码器部分,首先将深层语义特征进行 4 倍双线性插值上采样,并与浅层图像特征融合,再经过 3×3 卷积进行细节恢复,最后再使用上采样恢复空间信息。

1.2.2 基于一致性正则化的半监督学习框架

Mean Teacher 是一种基于一致性正则化的半监督学习方法^[28],本文主要从一致性正则化函数及超参数寻优两方面对 Mean Teacher 进行改进。Mean Teacher 框架如图 3 所示,整个框架由教师模型(Tmodel)和学生模型(Smodel)构成,每个模型结构

一致,均使用 DeepLabV3 + ,但模型参数不完全相同。

图 3 中 M^l 和 M^u 表示有标签数据和无标签数据, Y 表示监督学习使用的标签。 M^l 经过 Smodel 后得到 N^l ,与真值 Y 做交叉熵监督损失 $L_{\text{supervised}}$,即

$$L_{\text{supervised}} = -\frac{1}{n} \sum_{i=1}^n \sum_{c=1}^C y_i \text{clg}(\hat{y}_i, c) \quad (1)$$

式中 C ——类别数

y_i ——真实标签

\hat{y}_i ——模型预测值

c ——具体类别索引

n ——样本总数

无标签数据 M^u 分别输入 Smodel 和 Tmodel,输出 N^l 和 N^{lu} ,并进行一致性正则化计算 $L_{\text{consistently}}(N^l, N^{lu})$ 。半监督学习框架的总损失值函数 L_{total} 定义为监督损失值和一致性损失值的加权和

$$L_{\text{total}} = \varepsilon L_{\text{supervised}} + \gamma L_{\text{consistently}} \quad (2)$$

式中 ε ——监督损失值权重

γ ——一致性损失值权重

在训练过程中, L_{total} 经过反向传播对 Smodel 进行参数更新,Tmodel 的参数更新则通过原 Tmodel 参数与更新后的 Smodel 参数加权求和

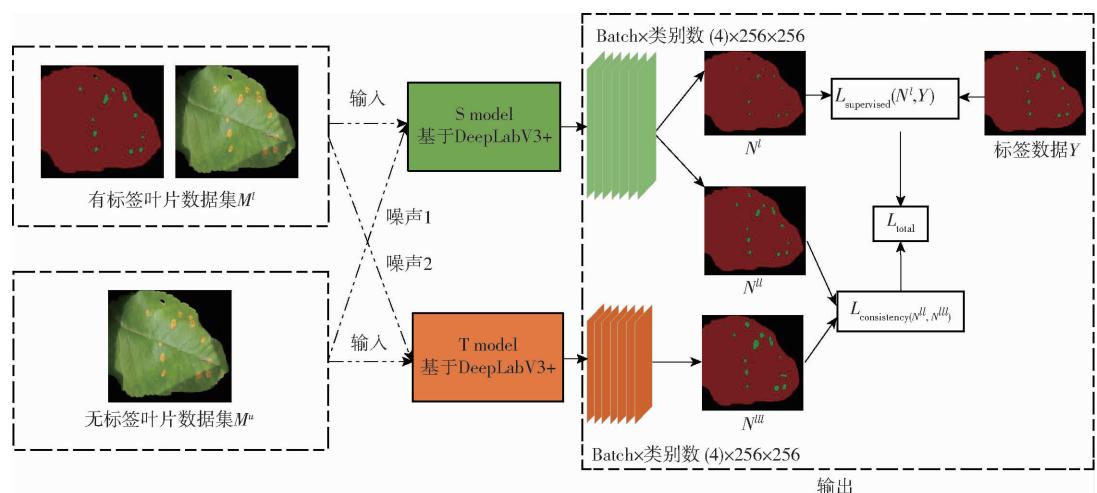


图 3 半监督学习框架

Fig. 3 Semi-supervised learning framework

$$\theta_t = \mu \theta'_{t-1} + (1 - \mu) \theta_t \quad (3)$$

式中 θ'_{t-1} —— 时间步 $t-1$ 时教师模型参数

θ_t —— 时间步 t 时学生模型参数

μ —— 教师模型参数更新权重

1.3 超参数调优

贝叶斯优化算法是一种基于概率模型的优化技术, 可以对有监督损失及一致性正则化进行超参数寻优, 其流程包括 5 个步骤^[29]:

(1) 定义目标函数 F 以及待优化超参数集 x 的定义域。目标函数是模型在验证集上的表现, 表示为

$$F = -(0.4P + 0.3mIoU + 0.3mPA) \quad (4)$$

式中 P —— 精确率

$mIoU$ —— 平均交并比

mPA —— 平均像素准确率

待优化的超参数包括监督损失权重 ε 、一致性损失权重 γ 、MSE 损失权重 α 、Huber 损失权重 β 、Huber 损失中的阈值 δ 、教师模型参数更新权重 μ 。

(2) 将各个超参数均设置为 0.5, 并训练网络, 求得对应的目标函数值 S 。

(3) 选择高斯过程(Gaussian process, GP)

$$f(x) \sim GP(m(x), k(x, x')) \quad (5)$$

式中 $m(x)$ —— 均值函数

$GP(\cdot)$ —— 高斯过程函数

$k(x, x')$ —— 核函数用于计算输入点之间的协方差

(4) $f(x)$ 作为代理模型, 并根据初始的评估结果 S 在超参数空间中进行插值, 估计目标函数 F 的可能分布。

(5) 使用采集函数 $EI(x)$ 决定下一步评估的超参数组合。

$$EI(x) = E[\max(f(x) - f(x^+), 0)] \quad (6)$$

式中 x^+ —— 当前观察到的最优超参数

重复步骤(2)~(4), 直到达到预设的迭代次数或满意的性能水平。

1.4 模型评价指标

使用像素准确率(Pixel accuracy, PA)、平均像素准确率(Mean pixel accuracy, mPA)、交并比(Intersection over union, IoU)、平均交并比(Mean intersection over union, mIoU)、精确率(Precision, P)和模型内存占用量、计算量、参数量等指标对模型性能进行评价。

1.5 实验平台

实验平台搭载 Xeon Gold 6142 处理器, GPU 为 RTX 3080, 64 GB 系统内存, 960 GB SSD 固态硬盘。软件环境为 Ubuntu 16.04 LTS 64 位操作系统, 安装 Python 3.8、Pytorch 等。

2 结果与分析

2.1 一致性正则化结果

考虑到不同光照条件下的病斑颜色、纹理变化、拍摄环境中存在的噪声或伪影、叶片姿态变化所导致的病斑形状改变、病斑边缘模糊以及图像分辨率低造成的病斑细节丢失, 使得病斑识别及分割困难。而 MSE 对小误差较敏感, 容易捕捉病斑和健康叶片之间的细微差异; Huber 对异常值具有较好的鲁棒性, 能减少噪声影响^[30]; Dice 用于衡量样本重叠程度, 可提升小区域病斑的分割精度; Focal 对于样本不平衡问题具有较强的适应性^[31]; Tversky 通过控制假阳性和假阴性的权重, 对边界模糊及细节丢失具有较好的鲁棒性; KL Divergence 可用于比较 2 个概率分布之间的相对信息量, 有利于提取重要图像特征^[32]; Boundary 有助于提高边界检测的精度^[33]; Entropy Minimization 可增强模型对未标注数据的利

用。因此,选用 Adam 优化器,设置初始学习率为 0.001,监督损失权重 ε 为 0.5、一致性损失权重 γ 为 0.5、教师模型参数更新权重 μ 为 0.5,有标签数据占比 30% 的情况下,对 MSE、Huber、Dice、Focal、Tversky、Jaccard、KL Divergence、Boundary、Entropy Minimization 及其组合进行对比实验,以达到选取最优一致性正则化函数的目的。如图 4 所示,原始图像中包含尺寸、分布、颜色、边缘清晰度各不相同的

12 个病斑,一致性正则化为 Entropy Minimization、Dice、MSE + Huber 时,分割效果较好,识别出的病斑个数分别为 11、12、12。再对整个测试集进行性能评价,结果如表 1 所示,MSE + Huber 组合精确率和平均交并比最高,分别达到 94.40% 和 89.31%,说明模型具有较高的准确性和召回能力,可以在较大范围内平滑分割结果,对病斑过小、分布不均、边缘模糊具有较强的适应性。

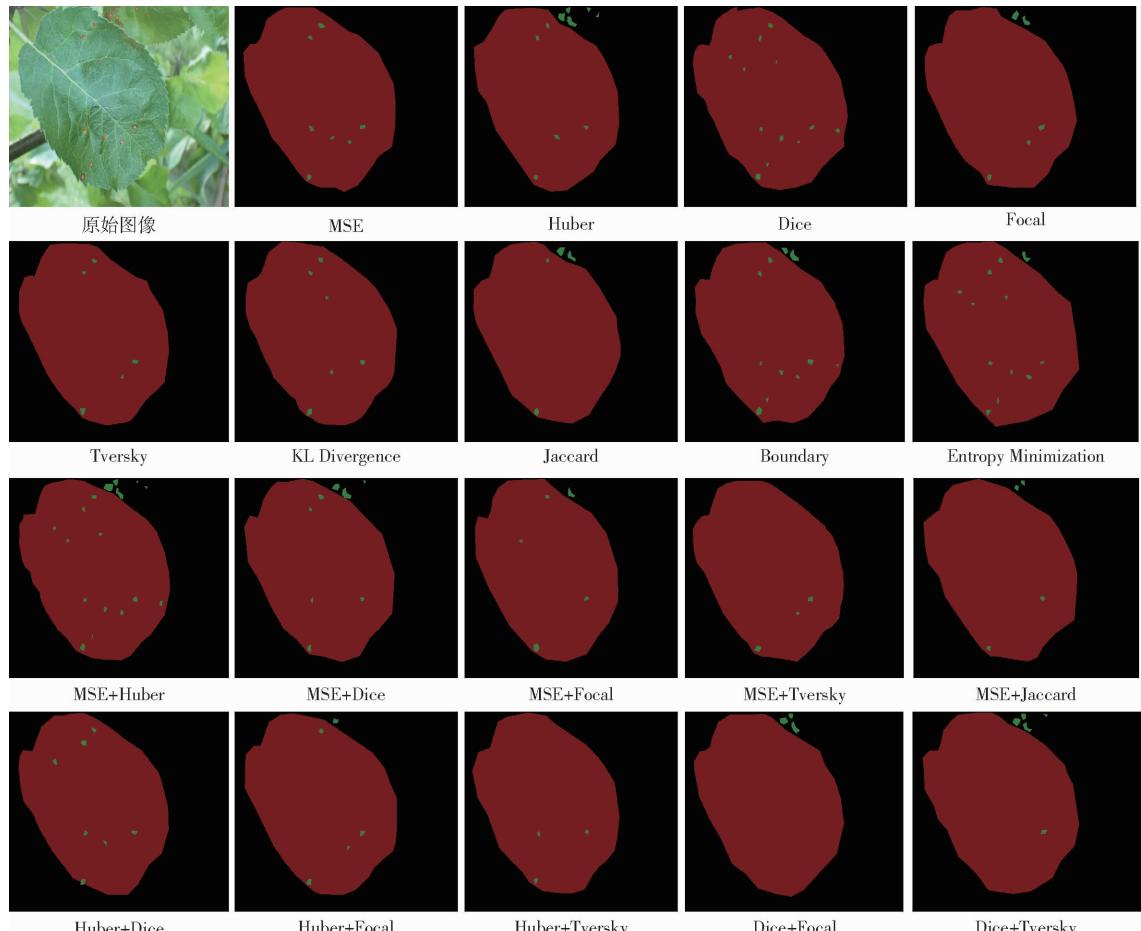


图 4 不同一致性正则化方法对应的病斑分割结果

Fig. 4 Results of spot segmentation using different consistency regularization methods

2.2 基于贝叶斯优化的超参数寻优

超参数设置对于优化分类边界、加快收敛速度和提升模型稳定性具有重要意义^[34],使用 Optuna 库中的贝叶斯算法,在参数更新步长为 0.1 的情况下,对监督损失权重 ε 、一致性损失权重 γ 、MSE 权重 α 、Huber 权重 β 、Huber 损失中的阈值 δ 、教师模型参数更新权重 μ 进行优化,结果如图 5 所示。

由图 5 可以直观地看到不同超参数对目标值的贡献和影响,每个超参数的取值在图中用线段连接,发现较低的 δ 有助于提升模型性能,而且 α 和 β 的组合对模型性能也有显著影响。最终,当 $\varepsilon = 0.6$ 、 $\gamma = 0.4$ 、 $\alpha = 0.6$ 、 $\beta = 0.4$ 、 $\delta = 0.3$ 、 $\mu = 0.5$ 时,目标值最高,对应的 P 为 95.60%,mIoU 为 94.85%,mPA

为 96.50%,比优化前分别提升 1.20、5.54、13.56 个百分点。如图 6 所示,超参数优化后模型收敛速度更快。

2.3 不同训练框架对病斑分割的影响

为了进一步说明基于一致性正则化的半监督训练框架的有效性,在使用 10%、20%、30%、40% 和 50% 标注数据的情况下,分别与全监督、自训练半监督进行比较,结果如表 2 所示。

由表 2 可以看出,随着标注数据比例的增加,全监督学习模型性能逐步提升,其 P 从 82.49% 提升至 94.45%,说明全监督学习非常依赖于样本数量及质量。自训练半监督学习在所有数据比例下,均优于全监督学习,特别是在低比例标注数据时,性能

表 1 各一致性正则化对比结果(有标签数据占比 30%)

Tab. 1 Comparison results of consistency regularization

(labelled data proportion was 30%) %

一致性正则化类型	P	mIoU	mPA
MSE	82.49	77.33	84.68
Huber	94.01	79.12	87.80
Dice	89.64	85.70	88.20
Focal	86.97	73.99	82.77
Tversky	78.12	80.28	94.54
KL Divergence	78.12	81.85	91.63
Jaccard	76.16	70.93	94.09
Boundary	92.32	82.15	93.42
Entropy Minimization	89.16	71.30	93.83
MSE + Huber	94.40	89.31	82.94
MSE + Dice	91.65	86.17	80.68
MSE + Focal	79.25	76.09	84.88
MSE + Tversky	78.64	71.95	85.83
MSE + Jaccard	78.67	83.68	84.07
Huber + Dice	81.08	78.80	92.43
Huber + Focal	85.50	72.44	85.35
Huber + Tversky	83.64	79.90	84.21
Dice + Focal	80.82	70.69	88.14
Dice + Tversky	87.24	88.19	82.11

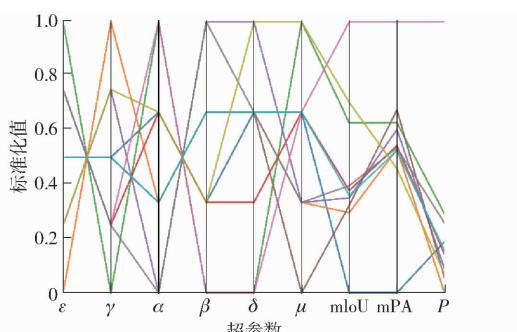


图 5 平行坐标图

Fig. 5 Parallel coordinate diagram

提升明显,说明自训练学习能够有效利用未标注数据。一致性半监督学习在所有数据比例下,均表现最佳,在仅使用 20% 标注数据的情况下,其 P 为 93.22%, $mIoU$ 为 92.67%, mPA 为 94.12%,说明该框架能确保各种扰动输入时的输出一致性,有效增强了模型的泛化能力和稳定性。

表 3 不同模型下的分割性能(标注数据占 30%)

Tab. 3 Segmentation performance under different models(annotated data accounts for 30%)

模型	内存占用量/MB	计算量	参数量	P/%	mPA/%	mIoU/%
LRASPP	84	1.9070×10^9	1.1025×10^7	94.00	94.85	92.00
FCN	270	2.8432×10^{10}	3.5310×10^7	92.30	92.80	89.25
U-Net	33	7.7600×10^9	4.3190×10^6	93.45	94.10	91.34
PSPNET	175	3.9540×10^{10}	4.5690×10^7	91.23	93.32	92.34
BiSeNet	45	1.1908×10^{10}	1.1403×10^7	93.43	93.45	93.22
SegNet	108	2.9892×10^{10}	2.5890×10^7	94.43	94.78	93.45
DeepLabV3 +	24	3.9900×10^8	3.2190×10^6	95.60	96.50	94.85

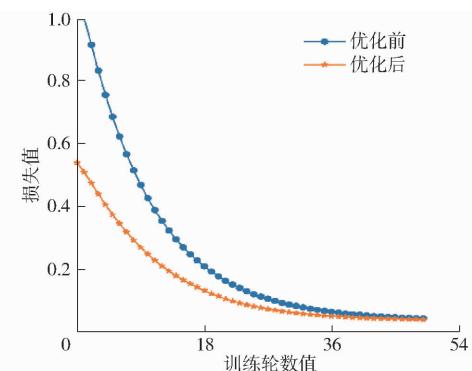


图 6 训练损失曲线

Fig. 6 Training loss curves

表 2 不同数据比例的训练指标

Tab. 2 Training indicators with different data

数据比例	模式	proportions			%
		P	mIoU	mPA	
10	全监督	82.49	77.33	84.68	
	自训练	86.02	79.41	86.83	
	一致性	87.34	86.52	89.96	
20	全监督	88.16	88.74	88.93	
	自训练	90.11	89.32	93.05	
	一致性	93.22	92.67	94.12	
30	全监督	92.12	89.21	89.89	
	自训练	92.45	92.33	93.56	
	一致性	95.60	94.85	96.50	
40	全监督	93.56	86.78	91.23	
	自训练	93.82	94.56	94.45	
	一致性	96.23	96.34	96.62	
50	全监督	94.45	88.23	91.34	
	自训练	95.12	95.23	95.12	
	一致性	97.60	96.85	97.00	

2.4 与其他经典模型比较

将本文提出的分割模型与 LRASPP、FCN、U-Net、PSPNET、BiSeNet、SegNet 等经典模型^[5-8,35-36]进行对比,结果如表 3 所示。发现本文模型表现最佳,在标注数据同为 30% 的情况下,其 P 为 95.60%, $mIoU$ 为 94.85%, mPA 为 96.50%。同时,计算量为 3.99×10^8 ,参数量为 3.219×10^6 ,也是所有模型中最低的。进一步说明了所提出方法的有效性。

3 结论

(1) 选择陇东苹果作为研究对象,提出了一种基于轻量级一致性半监督学习框架的苹果叶片病斑分割模型,达到了使用少量标注数据训练高精度模型的目的。

(2) 对于苹果叶片病斑分割,由 2 个轻量化的 DeepLabV3+ 构造的一致性半监督学习框架,具有从有限标注数据中提取特征描述符的能力。构造的模型仅使用 30% 的标注数据,病斑分割的 P 达到 95.60%, mIoU 为 94.85%, mPA 为

96.50%。均优于全监督学习和自训练半监督学习。

(3) 不同的一致性正则化方法对病斑分割效果有显著影响。研究表明,MSE 与 Huber 组合能够更好地捕捉病斑和健康叶片之间的细微差异,具有较强的抗噪性,提高了模型对病斑过小、分布不均和边缘模糊的适应性。

(4) 超参数优化可以显著加快模型的收敛速度并提升稳定性。通过贝叶斯算法进行超参数寻优,优化后模型 P 、mIoU 和 mPA 分别提升 1.20、5.54、13.56 个百分点。

参 考 文 献

- [1] 胡化涛,费丽彬,邓明江,等. 陇东地区苹果园应用生物活性素的效果[J]. 干旱地区农业研究,2022,40(4):88–98.
HU Huatao, FEI Libin, DENG Mingjiang, et al. Effects of bioactive agents on apple orchard in eastern Gansu area [J]. Agricultural Research in the Arid Areas, 2022, 40(4): 88–98. (in Chinese)
- [2] 韩菊红,岳德成,柳建伟,等. 甘肃平凉苹果病虫害调查初报[J]. 植物保护,2021,47(4):221–227.
HAN Juhong, YUE Decheng, LIU Jianwei, et al. A preliminary investigation report on apple diseases and pests in Pingliang City, Gansu Province [J]. Plant Protection, 2021, 47(4): 221–227. (in Chinese)
- [3] 张鼎新,徐秉良,陈臻,等. 近 20 年甘肃省苹果 4 种主要病害发生分析及趋势预测[J]. 土壤与作物,2021,10(2):237–244.
ZHANG Dingxin, XU Bingliang, CHEN Zhen, et al. Analysis on the four major diseases of apple in the past 20 years and occurrence prediction in Gansu Province [J]. Soils and Crops, 2021, 10(2): 237–244. (in Chinese)
- [4] 聂继云. 我国果品农药残留限量新变化[J]. 中国果树,2017(3):96–100.
- [5] 周蒙. 中国生物农药发展的现实挑战与对策分析[J]. 中国生物防治学报,2021, 37(1): 184–192.
ZHOU Meng. The realistic challenge and countermeasure analysis of the development of biological pesticide in China [J]. Chinese Journal of Biological Control, 2021, 37(1): 184–192. (in Chinese)
- [6] 农业农村部. 风送式果园喷雾机作业质量: NY/T 992—2006[S]. 北京: 中国农业出版社, 2006.
- [7] 郭伟,党梦佳,贾箫,等. 基于深度学习的小麦条锈病病害等级识别[J]. 华南农业大学学报,2023,44(4):604–612.
GUO Wei, DANG Mengjia, JIA Xiao, et al. Grade classification of wheat stripe rust disease based on deep learning [J]. Journal of South China Agricultural University, 2023, 44(4): 604–612. (in Chinese)
- [8] BARI B S, ISLAM M N, RASHID M, et al. A real-time approach of diagnosing rice leaf disease using deep learning-based Faster R-CNN framework[J]. PeerJ Computer Science, 2021, 7: e432.
- [9] MATHEW M P, MAHESH T Y. Leaf-based disease detection in bell pepper plant using YOLO v5[J]. Signal, Image and Video Processing, 2022, 16: 841–847.
- [10] TIAN L, ZHANG H, LIU B, et al. VMF-SSD: a novel V-space based multi-scale feature fusion SSD for apple leaf disease detection[J]. IEEE/ACM Transactions on Computational Biology and Bioinformatics, 2022, 20(3): 2016–2028.
- [11] 王璨,武新慧,张燕青,等. 基于双注意力语义分割网络的田间苗期玉米识别与分割[J]. 农业工程学报,2021,37(9):211–221.
WANG Can, WU Xinhui, ZHANG Yanqing, et al. Recognition and segmentation of maize seedlings in field based on dual attention semantic segmentation network [J]. Transactions of the CSAE, 2021, 37(9): 211–221. (in Chinese)
- [12] DEEPAK K, VINAY K. Application of PSPNET and fuzzy logic for wheat leaf rust disease and its severity[C]//International Conference on Data Analytics for Business and Industry (ICDABI), 2022: 547–551.
- [13] 王翔宇,李海生,吕丽君,等. 基于 U-Net 和可见光谱图像的黄瓜褐斑病分割[J]. 光谱学与光谱分析,2021, 41(5): 1499–1504.
WANG Xiangyu, LI Haisheng, LÜ Lijun, et al. Segmentation of cucumber target leaf spot based on U-Net and visible spectral images [J]. Spectroscopy and Spectral Analysis, 2021, 41(5): 1499–1504. (in Chinese)
- [14] LI Kaiyu, SONG Yuzhaobi, ZHU Xinyi, et al. A severity estimation method for lightweight cucumber leaf disease based on DM-BiSeNet[J]. Information Processing in Agriculture, 2024, 8.
- [15] KAUR P, HARNAL S, GAUTAM V, et al. Performance analysis of segmentation models to detect leaf diseases in tomato plant [J]. Multimedia Tools and Applications, 2024, 83(6): 16019–16043.
- [16] ZENG W, HE M. Rice disease segmentation method based on CBAM-CARAFE-DeepLabV3+[J]. Crop Protection, 2024, 180: 106665.
- [17] ZHU S, MA W, LU J G, et al. A novel approach for apple leaf disease image segmentation in complex scenes based on two-

- stage DeepLabV3 + with adaptive loss[J]. Computers and Electronics in Agriculture, 2023, 204: 107539.
- [18] KIM T, OH J, KIM N Y, et al. Comparing Kullback-leibler divergence and mean squared error loss in knowledge distillation [J]. arXiv Preprint, arXiv: 2105. 08919, 2021.
- [19] MILLETARI F, NAVAB N, AHMADI S A. V - Net: fully convolutional neural networks for volumetric medical image segmentation[C]//2016 Fourth International Conference on 3D Vision (3DV). IEEE, 2016: 565 – 571.
- [20] ABRAHAM N, KHAN N M. A novel Focal Tversky loss function with improved attention U - Net for lesion segmentation[C]// 2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019). IEEE, 2019: 683 – 687.
- [21] OGWOK D, EHLERS E M. Jaccard index in ensemble image segmentation: an approach[C]// Proceedings of the 2022 5th International Conference on Computational Intelligence and Intelligent Systems, 2022: 9 – 14.
- [22] GRANDVALET Y, BENGIO Y. Semi-supervised learning by entropy minimization [J] // Advances in Neural Information Processing Systems. 2004, 17: 529 – 536.
- [23] LAINE S, AILA T. Temporal ensembling for semi-supervised learning[J]. arXiv Preprint, arXiv: 1610. 02242, 2016.
- [24] CHEN Y, TAN X, ZHAO B, et al. Boosting semi-supervised learning by exploiting all unlabeled data[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7548 – 7557.
- [25] LEE D H. Pseudo-label: the simple and efficient semi-supervised learning method for deep neural networks[C]// Workshop on Challenges in Representation Learning, ICML, 2013: 896.
- [26] MIYATO T, MAEDA S, KOYAMA M, et al. Virtual adversarial training: a regularization method for supervised and semi-supervised learning[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 41(8): 1979 – 1993.
- [27] ZENG Q, XIE Y, LU Z, et al. Pefat: Boosting semi-supervised medical image classification via Pseudo-loss estimation and feature adversarial training [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 15671 – 15680.
- [28] 陈理, 韩毅, 杨广, 等. 基于改进半监督模型的空间异质性农田特征提取研究[J]. 农业机械学报, 2023, 54(12): 173 – 185.
CHEN Li, HAN Yi, YANG Guang, et al. Spatially heterogeneous cropland characteristic extraction based on improved semi-supervised models[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54 (12): 173 – 185. (in Chinese)
- [29] 雷志鹏, 彭川, 许子涵, 等. 基于改进 Deformable DETR 模型的多源局部放电识别方法及其应用[J]. 中国电机工程学报, 2024, 44(15): 6248 – 6261.
LEI Zhipeng, PENG Chuan, XU Zihan, et al. Pattern recognition methods of multi-source partial discharge based on the improved Deformable DETR model and its application [J]. Proceedings of the CSEE, 2024, 44 (15): 6248 – 6261. (in Chinese)
- [30] BALASUNDARAM S, PRASAD S C. Robust twin support vector regression based on Huber loss function [J]. Neural Computing and Applications, 2020, 32(15): 11285 – 11309.
- [31] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]// Proceedings of the IEEE International Conference on Computer Vision, 2017: 2980 – 2988.
- [32] WEI H, CHEN L, GUO L. Divergence-based fuzzy cluster ensemble for image segmentation[J]. Entropy, 2018, 20(4): 273.
- [33] MARMANIS D, SCHINDLER K, WEGNER J D, et al. Classification with an edge: improving semantic image segmentation with boundary detection[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2018, 135: 158 – 172.
- [34] MARTIN G M, FRAZIER D T, ROBERT C P. Approximating Bayes in the 21st century[J]. Statistical Science, 2024, 39(1): 20 – 45.
- [35] LIN X. Research on remote sensing image segmentation network based on improved LRASPPHead [C] // 2023 IEEE International Conference on Sensors, Electronics and Computer Engineering (ICSECE). IEEE, 2023: 864 – 871.
- [36] GONG H, LIU T, LUO T, et al. Based on FCN and DenseNet framework for the research of rice pest identification methods [J]. Agronomy, 2023, 13(2): 410.