doi:10.6041/j.issn.1000-1298.2024.S1.010

基于白平衡特征增强的秸秆目标分割方法

姜含露[1,2]　王飞云[1,2]　潘宇轩[1,2]　刘阳春[1,2]　汪凤珠[1,2]　周利明[1,2]　吕程序[1,2]

（1. 中国农业机械化科学研究院集团有限公司，北京 100083；2. 农业装备技术全国重点实验室，北京 100083）

摘要：针对图像中多种复杂环境干扰，本文结合秸秆在东北黑土地上具有的颜色优势，提出一种基于白平衡特征增强的秸秆目标分割模型。DLv3+/CPM/SEM模型采用编解码结构，在DLv3+模型基础上融合了颜色感知模块CPM与空间增强模块SEM，利用白平衡技术提高秸秆目标在图中的对比度使其在多种干扰因素的影响下仍能保持对秸秆目标检测的准确率。其中编码部分利用残差网络组成双分支特征提取结构，通过全反射算法增强秸秆颜色特征的同时，消除光线条件对图像颜色显现的干扰，双分支特征通过级联的感知方式并入颜色感知模块CPM，以加强补色的形式对图像中偏色严重的秸秆进行多层级的颜色特征增强，从而提取准确的秸秆特征表达；解码部分将整合的特征代入具有ASPP的解码模型中，加入空间增强模块SEM提高秸秆和农田背景的区分度，优化秸秆目标分割模型性能。经试验验证，提出的DLv3+/CPM/SEM改进模型在准确率和MIoU的模型整体评价指标上都高于其它对比模型，在不同光源条件、秸秆长度、垄沟深浅和土块大小的干扰条件下均有较好的分割效果，同时结合距离划分结果后，对非单一农田背景的秸秆监测图像的覆盖率计算精度更为准确。

关键词：秸秆；分割；DLv3+；空间增强模块；颜色感知模块

中图分类号：S24　　**文献标识码：**A　　**文章编号：**1000-1298(2024)S1-0092-09

Straw Target Segmentation Method Based on White Balance Feature Enhancement

JIANG Hanlu[1,2]　WANG Feiyun[1,2]　PAN Yuxuan[1,2]　LIU Yangchun[1,2]　WANG Fengzhu[1,2]

ZHOU Liming[1,2]　LÜ Chengxu[1,2]

(*1. Chinese Academy of Agricultural Mechanization Sciences Group Co., Ltd., Beijing* 100083, *China*

2. State Key Laboratory of Agricultural Equipment Technology, Beijing 100083, *China*)

Abstract: In response to the interference of various complex environments in images, this paper proposes a straw target segmentation model based on white balance feature enhancement, taking into account the color advantage of straw on black soil in Northeast China. The DLv3+/CPM/SEM model adopts an encoder decoder structure, which integrates the color perception module CPM and spatial enhancement module SEM on the basis of the DLv3+ model. The white balance technology is used to improve the contrast of straw targets in the image, so that they can still maintain the accuracy of straw target detection under the influence of various interference factors. The encoding part utilized a residual network to form a dual branch feature extraction structure, which enhances the color features of straw through total reflection algorithm while eliminating the interference of light conditions on the color display of the image. The dual branch features are merged into the color perception module CPM through a cascaded perception method to enhance the color features of straw with severe color cast in the image at multiple levels in the form of reinforced complementary colors, thereby extracting accurate straw feature expressions. The decoding part incorporates the integrated features into the decoding model with ASPP, and adds a spatial enhancement module SEM to improve the discrimination between straw and farmland background, optimizing the performance of the straw target segmentation model. Through experimental verification, the improved DLv3+/CPM/SEM model proposed in this paper has higher accuracy and

收稿日期：2024-07-19　修回日期：2024-09-16

基金项目：北京市科技新星计划项目(20220484066)

作者简介：姜含露(1991—)，女，高级工程师，主要从事农业信息化技术研究，E-mail：halo91@163.com

通信作者：吕程序(1985—)，女，研究员，博士，主要从事农业智能检测技术研究，E-mail：lvchengxu@caams.org.cn

overall evaluation indicators of MIoU than other comparative model models. lt has good segmentation effects under different light source conditions, straw length, ridge depth, and soil block size interference conditions. At the same time,combined with the distance segmentation results, the coverage calculation accuracy of straw monitoring images with nonsingle farmland backgrounds is more accurate.

Key words: straw; segmentation; DLv3 +; spatial enhancement module; color perception module

0　引言

黑土地是我国粮食生产的核心区域,其保护和利用直接关系到国家粮食安全和农业可持续发展。由于长期过度耕作和不合理的土地管理,黑土地面临着严重的退化问题,正以每年1 cm的速度流失,严重影响了黑土地可持续生产能力。秸秆覆盖还田是保护性耕作的一种形式,可以减少土壤侵蚀,增加土壤有机质含量,改善土壤结构,从而提高土壤保水和抗旱能力。为了加强黑土地保护,东北地区已经建立了覆盖超过300个国家级耕地质量监测点监测网络,对秸秆覆盖动态进行监测和精准计算,评估秸秆还田对土壤有机质提升和侵蚀控制的效果,为黑土地可持续管理和保护提供数据支持和科学指导。

早期的秸秆覆盖率计算方法是通过人工测量[1-6],图像处理系统成熟后,秸秆覆盖率检测方法可分为基于遥感影像检测和基于田间实拍图像检测。基于遥感手段可以快速客观地获取检测目标不同波段的遥感影像,视野范围大,能在有效反映田间区域尺度的同时,获得视野范围内的秸秆覆盖变化信息;通常采用基于多种光谱指数的秸秆覆盖度估算方法[7-12],但由于遥感采集的图像往往尺寸较大,对图像实时处理速度和秸秆检测效果均有较大影响。田间实拍图像可通过车载摄像头或人工拍摄,因其与检测目标距离更近,获取的图像具有更丰富的细节特征,视野相对较小、图像更为清晰。早期学者们通过对样本图像类型转换、灰度均衡化和中值滤波等方法实现覆盖率计算[13-18],此类方法对图像获取的环境要求较高,秸秆和土壤需要有较为明显的分界。后期学者们多利用图像处理系统和模式识别算法组成的机器视觉等方法[19-25],解决破碎秸秆纹理较差与土壤较难区分的问题。

秸秆覆盖率检测本质上是一类复杂小目标分割问题,由于打碎的秸秆长度为10~20 cm,被抛撒到农田上重叠交错,很难看出明显的形状特征和规则的纹理特征,受到光线条件、摄像头角度和田间环境等条件影响,使得秸秆语义信息不明确,秸秆分割准确率较低。传统语义分割采用的是单一全卷积网络结构,提取的特征融合了颜色、形状、纹理等多种信息,但对于相似场景下复杂目标分割中某些重要信息没有突显出来。例如,农田信息中相同语义不同形态的完整秸秆和破碎秸秆,或具有相同形态不同语义的土块与秸秆等。因此,本文利用白平衡技术对图像偏色矫正的特点,提出基于白平衡特征增强的秸秆目标分割方法,针对图中存在光源、垄沟、土块等干扰,建立DLv3+/CPM/SEM秸秆分割模型,有目的地增强对秸秆图像的语义分割起重要作用的特征,以期有效控制各类干扰因素,提高秸秆覆盖率监测准确度。

1　基于白平衡的秸秆颜色校正

由于CCD等感光电子元器件按照等比例方式放大蓝绿红光线,因此在光线干扰下感受到的光线强度与物体真实颜色有一定偏差。为了消除这种偏差,可以采用白平衡校正方式,以图像中的白色物体作为颜色校正基准,通过将偏光的白色物体颜色还原,改变蓝绿红光线比例关系,从而达到还原图像中其他颜色的目的。其中全反射算法是最常用的白平衡算法。

全反射算法重点考虑颜色最亮的那部分,不需要图像颜色丰富。该方法假设图像中亮度最大(R+G+B)的点为白色,若此点不为白色,就针对此点偏离的数值进行修正,并以该点作为全图颜色校正的基准点。当处理颜色丰富的图像时,图中亮度最高的点不一定是白色,容易造成偏色,因此在处理颜色单调的图像时效果更为明显。该方法修正公式为

$$\begin{cases} R_N = \dfrac{R_W}{R_{\mathrm{MAX}}} R_O \\ G_N = \dfrac{G_W}{G_{\mathrm{MAX}}} G_O \\ B_N = \dfrac{B_W}{B_{\mathrm{MAX}}} B_O \end{cases} \tag{1}$$

式中　R_{MAX}、G_{MAX}、B_{MAX}——亮度值最大点的颜色分量值

R_W、G_W、B_W——白平衡后最大亮度值,取255

R_O、G_O、B_O——该点原始颜色分量值

图1为全反射算法的白平衡处理图像,由图1可知,图像中非镜面反射的物体平均色度和亮度都在光线的影响下产生了偏差,而表面光滑秸秆作为全图中亮度最高的点被作为图像校正的基准点,经过3次白

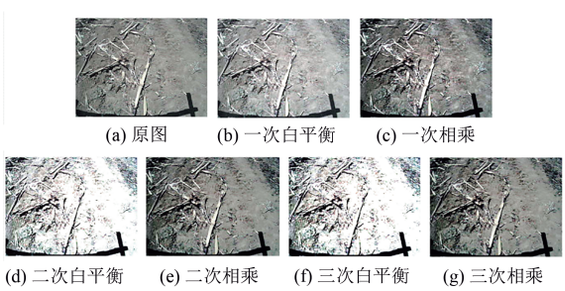

图1　全反射算法效果图

Fig. 1　Results of total reflection algorithm

平衡后能消除部分光源颜色，并逐渐将秸秆与农田及阴影的对比度拉开，融合后图像像素值趋于稳定，并保留了原图像丰富的细节信息，因此该方法作为去除光线干扰和秸秆特征增强是可靠的。

2 基于多通道特征增强的秸秆目标分割

2.1 模型总体结构

秸秆目标分割任务中，由于农田与秸秆具有更为相似的语义信息，因此本文构建了基于白平衡特征增强的秸秆目标分割模型（图2），用于降低光线干扰，并突出秸秆在田间检测的颜色特性，增强不同地物间语义差异。

模型整体为编解码结构，并在Deeplabv3+的基础上进行改进，其中编码部分引用轻量化残差网络结构，组成了双分支卷积神经网络作为编码器，分别包括3个特征提取模块用来提取原图特征和颜色增强特征，并利用颜色感知模块将原图的各级特征融入白平衡处理后的特征中，增强细节信息且丰富颜色特征。另外，双分支的特征输入到语义融合模块，用来整合原图特征与颜色特征相关的语义特征。然后，在解码部分对融合后的语义特征进行ASPP和上采样逐级恢复图像大小，由于多尺度特征因大尺度扩张像素间缺少连续性，从而导致对小目标的分割效果较差，在上采样之前增加空间增强模块，使得充分利用多尺度特征的空间特性，在上采样前细化大尺度目标的边界范围，并使得小目标区域在上采样后得到扩充。最后通过3×3卷积和4倍上采样恢复原图分辨率，利用Softmax函数逐像素预测图像分割结果，从而实现秸秆目标分割。

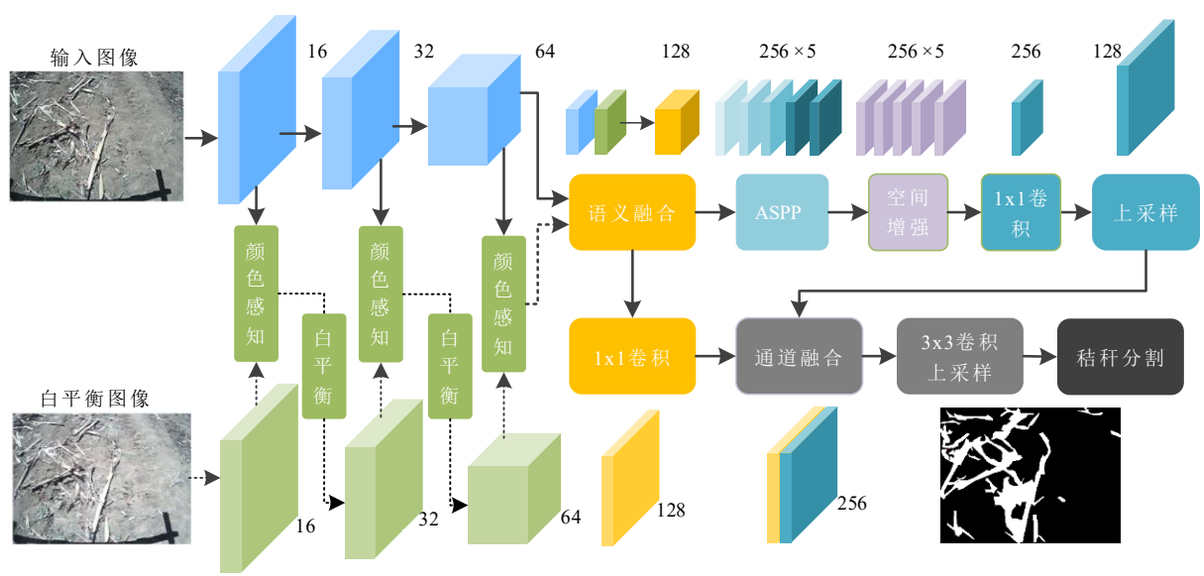

图2 秸秆目标分割模型结构

Fig. 2 Structure diagram of straw segmentation

2.2 颜色感知模块

在自然环境光线下土块、车辙或杂草等地物也是秸秆分割的干扰因素，卷积神经网络在编码阶段可以由浅入深提取图像中不同物体的语义信息，包括点、角、边缘、颜色、纹理等。其中，原图提取特征更倾向于边缘和纹理的变化，在车辙、阴影或杂草中的秸秆不易被编码；而白平衡处理过的图像削弱了光源偏色，特征更关注于有颜色变化的区域，可以弥补原图因光线忽略的颜色信息，从而锁定秸秆空间位置。因此，本文提出一种颜色感知模块，通过颜色增强和特征融合，实现两类特征相互补足可以更准确地判定秸秆区域。

颜色感知模块（Color perception module，CPM）结构如图3所示，在当前阶段该模块输入包括原图和白平衡两路分支，其中白平衡分支起到颜色区域掩膜作用。分别用X_i^{ORI}和X_i^{WHITE}表示编码器中第i个颜色感知模块原图特征和白平衡特征输入，两类特征当前尺寸均为$L_i \times W_i$，通道数为T。首先对两类特征进行一组非线性映射

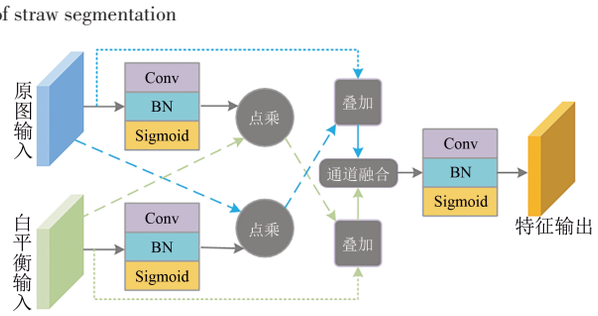

图3 颜色感知模块结构

Fig. 3 Color perception module structure

使残差网络的特征相互作用，分别得到原图特征映射和白平衡特征映射，即

$$N_i^{ORI} = \mathrm{Sigmoid}\left(BN\left(f\left(X_i^{ORI}\right)\right)\right) \tag{2}$$

$$N_i^{WHITE} = \mathrm{Sigmoid}\left(BN\left(f\left(X_i^{WHITE}\right)\right)\right) \tag{3}$$

其中，f为卷积核为3×3且步长为1的卷积操作，通常情况下卷积操作会减小特征图尺寸，为了保持操作后特征图尺寸的一致性，在X_i^{ORI}和X_i^{WHITE}特征图外侧填充尺度

为1且数值为0的像素后再进行处理；BN为批量标准化操作；Sigmoid为特征取值(0, 1)范围内的激活函数。

颜色感知的颜色特征增强是通过原图特征图和颜色区域掩膜中对应像素的点乘和叠加操作来实现的，对于同阶段两个特征图N_i^{ORI}和N_i^{WHITE}，与原特征交叉相乘可以在图像偏色和细节模糊方面相互补足，从原特征构造跳跃连接并与点乘后的特征叠加可以明确两类特征图差异性，分别得到恒等映射下更新后的特征图，即

$$EP = \frac{667M(1 - 10/L)^2}{(T_o - T_i)V_{ave}} \tag{4}$$

由于N_i^{ORI}和N_i^{WHITE}特征值范围为0~1，C_i^{ORI}与C_i^{WHITE}在N_i^{ORI}和N_i^{WHITE}的作用下加强图中对应位置的像素值，当取值为接近0时，更新后特征值更接近原特征，当取值为接近1时特征值增大，表明该位置为残差网络感兴趣区域。因此，将两类特征按通道进行融合，既保留了原图浅层细节特征，同时丰富了颜色变化显著的区域，使得相同位置相同语义的颜色特征增强。

经过通道融合后组成的新特征通道数变为原来的两倍$2T$，经过一组非线性映射后，得到颜色感知模块输出特征为

$$F_i^{CPM} = \mathrm{ReLU}\left(BN\left(f'\left(concat\left(C_i^{ORI}, C_i^{WHITE}\right)\right)\right)\right) \tag{5}$$

其中，f'为卷积核为1 × 1且步长为1的卷积操作，$concat$为按照通道拼接的方式组合特征，经过特征映射后，特征尺寸仍为$L_i \times W_i$，通道数也减小为T。

2.3　空间增强模块

在深度卷积神经网络中，模型层数越多表示获得的特征层级越深，但由于秸秆单体目标较小，相对于农田背景像素占比较少，高级语义特征模糊往往不利于小目标的分割。通过分析Deeplabv3+编码器中ASPP模块特征提取规律，发现虽然每一个特征提取通道都对应了不同尺度的语义信息，在语义信息融合后图像分割结果常倾向于大尺度特征。因此，本文提出了一个空间增强模块添加在ASPP模块之后，通过双线性插值上采样强化不同尺度下目标的空间位置关系，防止大目标分割边界外溢，同时确保小目标有较明显的分割特征。空间增强模块(Spatial enhancement module，SEM)结构如图4所示。

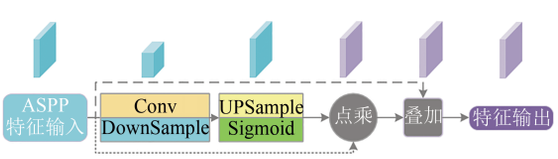

图4　空间增强模块结构

Fig. 4　Space enhancement module structure

对于整个模块而言，ASPP多尺度特征的每一个通道的特征图F_j^{ASPP}都是模块输入，输入特征图尺寸为$L_j \times W_j$，则通过重新学习空间关系得到的空间区域掩膜，即

$$M_j = \mathrm{Sigmoid}\left(Up\left(Down\left(f\left(F_j\right)\right)\right)\right) \tag{6}$$

其中，f为卷积核为3 × 3且步长为1的卷积操作，$Down$为步长为1且尺度为2的下采样操作，Up为双线性插值上采样操作，Sigmoid为空间区域掩膜的激活函数，使掩膜取值范围落于0~1。

经过双线性插值上采样，空间区域掩膜M_j反映了特征图局部区域的权重差异，借助空间区域掩膜对特征图加权可以增强特征图的空间区域特征，与原特征图叠加可得到更精细的特征表达，即

$$F_j^{LEM} = F_j^{ASPP} M_j + F_j^{ASPP} \tag{7}$$

其中，F_j^{ASPP}特征图中每一个像素都根据空间区域掩膜M_j的权值范围进行加强。

2.4　损失函数

对于秸秆目标分割任务，通常将其分为秸秆和背景两种类别，普通的二分类交叉熵损失函数公式为

$$L_{BCE} = -\lg p_t \tag{8}$$

其中，当分割结果与秸秆目标真值一致时，p_t等于秸秆检测概率p，若不一致，p_t为$1 - p$。

由于田间秸秆目标的像素数量占比较低，在参数迭代优化时每个像素权重相同，模型会更倾向于大目标特征提取，不利于小目标的秸秆检测。因此该模型的损失函数采用针对样本类别不均衡问题的Focal Loss函数

$$L_{FL} = -\alpha_t(1 - p_t)^r \lg p_t \tag{9}$$

其中，α和r都是调整样本权重占比的超参数，α通常根据目标样本占比选择小于0.5数值，本文取0.2，当分割结果与秸秆目标真值一致时，α_t等于α，若不一致，α_t为$1 - \alpha$；r更关注于样本错分的难易程度，降低损失函数中易分样本的影响，取2。

2.5　评价指标

采用准确率和平均交并比作为评价指标。准确率为符合条件的测定值数量占总测定数量的百分比；平均交并比为分割结果实际区域和预测区域的交集占二者并集比例。

3　试验

3.1　试验数据与相关设置

为获取试验数据，采用分辨率为320像素×240像素的YB-DB015A型车载相机，将其安装在驾驶室车顶前部，初始安装角度向地面方向倾斜60°，用来获取播种机前方15 m范围内的秸秆覆盖图像，如图5所示。

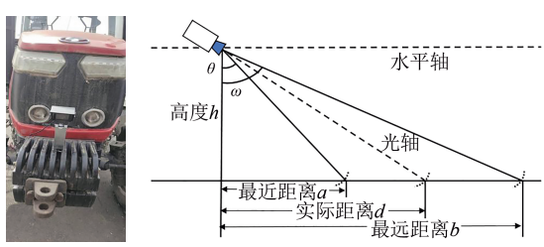

图5　摄像头安装示意图

Fig. 5　Installation diagram of camera

试验数据总计1 051幅，训练集501幅，验证集150幅，测试集350幅。由于每幅图像在多种不同干扰因素下采集得到，根据主要影响因素将图像测试集按照3种类型划分，从不同角度评价模型。数据集图像和标注如图6所示。

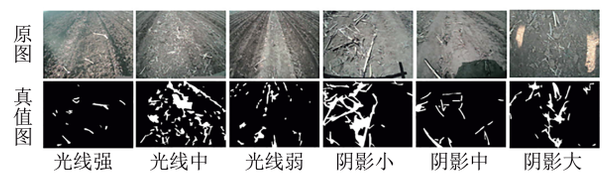

(a) 第1类测试数据

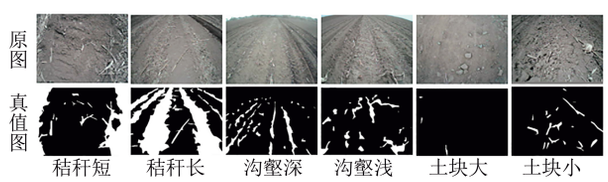

(b) 第2类测试数据

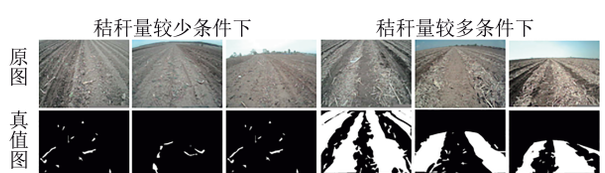

(c) 第3类测试数据

图6 秸秆目标分割试验测试数据

Fig. 6 Experimental test data of straw quantitative detection

第1类测试数据(F1)100幅，按照行驶方向与光源位置分为面向光源与背向光源，在图像中表现为光线强弱和阴影面积影响，用于对比模型整体秸秆检测精度。第2类测试数据(F2)190幅，从秸秆长度、沟壑深度和土块大小分成6类图像，用于定性分析农田秸秆形态与相似地物的对秸秆检测的影响，并且更全面地评估模型的检测能力。第3类测试数据(F3)60幅，按照摄像头角度高低，分为标准图像与角度过高图像，用于分析在不同秸秆覆盖量下，摄像头角度对覆盖率的影响。

3.2 试验参数设置

试验使用的硬件设备均为戴尔Precision T7920塔式图形工作站，带有两个至强SP系列处理器，配备Nvidia Quadro P2200显卡，操作系统为Ubuntu Linux 18.04，开发软件为PyCharm和PyTorch架构。

试验采用Nadam参数优化算法加速模型收敛，该方法考虑了一阶和二阶动量累积，动态调整学习率的约束范围，避免模型陷入局部最优或提前结束训练。模型使用PyTorch默认的参数设置：初始学习率为0.002，β_1为0.9，β_2为0.999，ε为1×10^{-8}，参数更新后学习率的衰减率为0.004，训练周期为40次。

3个特征提取模块卷积核均为3×3，特征数分别为(16、32、64)；ASPP共5个分支，分支1为卷积核1×1，通道2~4为卷积核3×3扩张率分别为1、3、5，分支5为全局平均池化，所有分支输出特征数均为256，总特征256×5；5个分支在通道维度上叠加，通过1×1的卷积融合不同尺度的特征，ASPP最终输出256个特征；特征空间增强后仍为256个特征。

模型定量评价方法采用准确率与平均交并比。由于秸秆图像中目标较小且不清晰，因此秸秆标注工作误差较大，为了降低由于标注准确性带来的误差，允许模型分割误差在1个像素的距离之内，即若某像素判定为真，包含其在内的9个像素中存在真值，则该像素判定正确。

3.3 秸秆目标分割模型性能对比

为了验证改进模型各部分对秸秆目标分割的分割性能，本节将颜色感知模块和空间增强模块分步融入Deeplabv3+(简写为DLv3+)模型中，进行DLv3+、DLv3+/CPM、DLv3+/SEM、DLv3+/CPM/SEM模型对比试验，在秸秆监测图像数据集上完成参数训练，并用本章划分的F1测试集进行模型整体性能验证，不同模型秸秆检测定量和定性试验结果分别如表1和图7所示。

表1 秸秆目标分割模型结果对比

Tab. 1 Comparison results of straw quantitative detection models %

F1测试数据		DLv3+	DLv3+/CPM	DLv3+/SEM	DLv3+/CPM/SEM
面向光源准确率	光线强	69.47	85.32	76.64	82.14
	光线中	72.21	86.27	71.21	79.31
	光线弱	78.78	82.96	76.45	80.26
背向光源准确率	阴影小	78.26	85.24	82.14	86.34
	阴影中	75.54	79.34	80.36	88.24
	阴影大	80.41	75.34	84.94	85.48
准确率		75.77	82.41	78.62	83.79
MIoU		72.53	64.38	76.12	79.45

首先通过秸秆检测定量结果对不同模型的分割精度和效果进行客观地评价和分析，由表1可知，本文提出的DLv3+/CPM/SEM改进模型在准确率和MIoU的模型整体评价指标上都高于其它对比模型，相比于DLv3+，分别加入CPM和SEM模块的模型也能够小范围地提升秸秆目标的准确率，但CPM增强了秸秆目标的影响范围导致错分像素较多，平均交并比表现较差。当车辆面向光源行驶时，带有CPM模块的模型可以抑制光线强弱变化带来的影响；而背向光源时，带有SEM模块的模型在不同阴影遮挡下的准确率更加稳定。

图7列举了3种光线干扰样本和3种阴影遮挡样本，由图7可知，DLv3+对于田间秸秆分割能实现基本吻合，但在对一些零散分布的单体秸秆或边缘重叠的秸秆群落，存在小目标漏检和群落边缘错分等问题。将两类改进的特征增强模块分别融入模型后，从分割效果图直观看出，两种结构相比于DLv3+均有提升。CPM模块的分割图存在一些离散点，恰好对应了零散分布的小目标秸秆，这是由于CPM模块在编码阶段增强了图像颜色对比

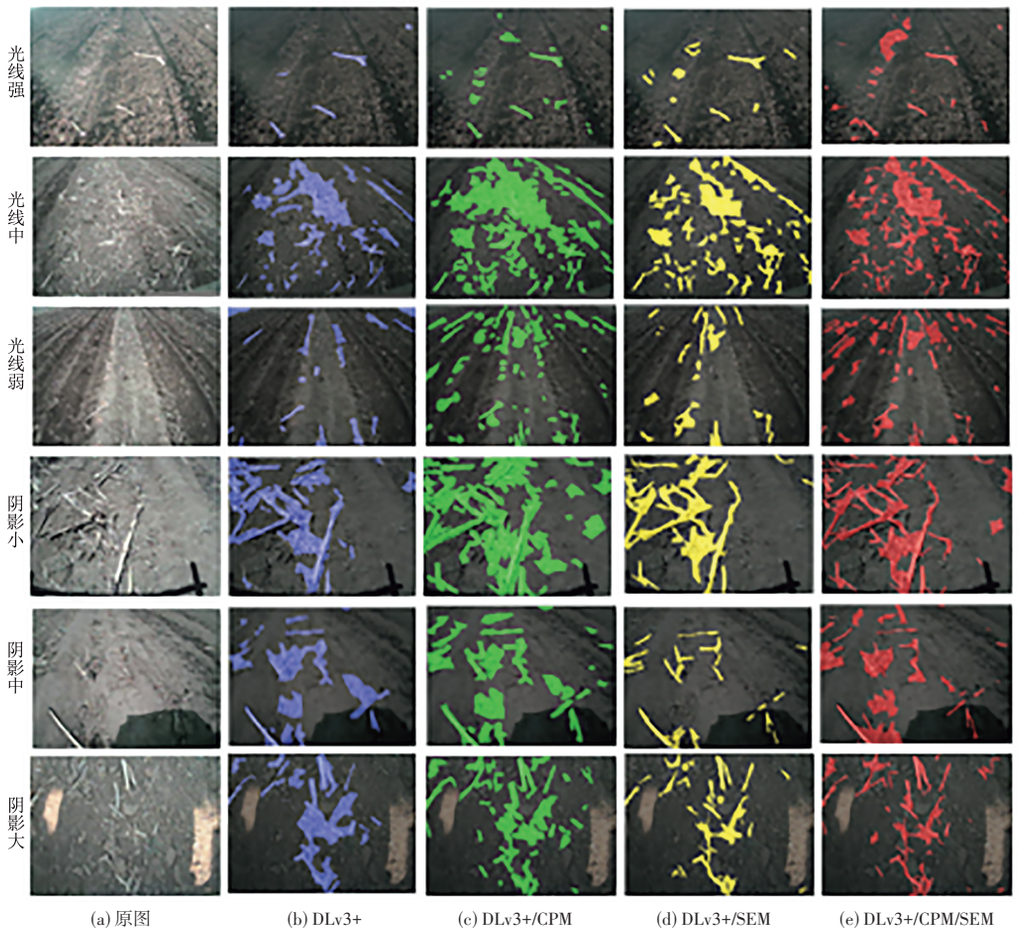

图7　秸秆目标分割效果

Fig. 7　Results of straw quantitative detection

度，凸显了图像中秸秆目标的分布位置，但由于小目标样本占比较小，在高阶语义中被弱化，多尺度特征均衡后模糊了底层的信息，使其在最终结果中表现为离散点。相比于DLv3+，加入SEM模块后多尺度特征继承了各级特征的空间连续性，特征堆叠后使得结果图有明显秸秆特征的较大单体和秸秆群落的分割边界更为清晰，但更难分割的小目标秸秆被漏分。因此，CPM模块和SEM模块的融合模型在颜色和空间语言特征间相互补充，在分割图主观表现中更为优异。

3.4　其他干扰因素对秸秆检测影响

试验分析农田背景下可能存在的干扰因素，分别讨论秸秆长度、沟壑深度和土块大小对秸秆目标分割的影响。由于同一种影响因素的不同干扰属性通常同时存在于图像中，例如图中同时存在不同长度的秸秆、不同深度的垄沟或不同大小的土块，无法进行准确地定量分析。因此，针对每一种影响因素分别选择3幅有代表性的测试样本，通过可视化的秸秆分割图中漏分部分（在图中用黄圈标识）与错分部分（在图中用绿圈标识）分析不同干扰属性的影响。

图8为不同方法在不同影响因素下秸秆的分割结果，以及与DLv3+方法的对比效果，其中黄色为漏分，绿色为错分。第1组针对不同长度秸秆的试验结果对比可以看出，相比于较长的秸秆，两类方法对目标较小的秸秆都存在漏分的问题，在标注数量上本文方法优于DLv3+，并且未出现错分的情况，这说明本章提出的模型可以有效检测田间不同姿态的秸秆，对小目标秸秆有一定的判别能力。第2组为不同深度垄沟影响结果，清晰地反映了若大量秸秆散落于某条垄沟中，模型在判别时会将垄沟错认为较长的秸秆，在2组模型对比图中呈或粗或细条状，其中本章方法因SEM模块对边界的约束条状更细，对秸秆检测结果影响更低。第3组对比不同大小土块的影响，如图所示形状完整的土块对2组模型的分割结果影响较小，但经过深松或深翻后土块纹理与秸秆群落外观相似，特别是松动过的土层中的秸秆与土块，两者容易混淆导致模型漏分和错分概率上升，在DLv3+表现为部分区域错分，但在本文方法中表现为像素点错分，这说明本文方法有效地整合了CPM和SEM模块，有助于提取更具代表性的语义信息。

3.5　距离划分对秸秆覆盖率的影响

试验从定量角度验证距离划分对秸秆覆盖率准确率的影响，利用F3测试数据分析摄像头角度导致的检测范围变化和秸秆覆盖量对秸秆覆盖率的影响，其中角

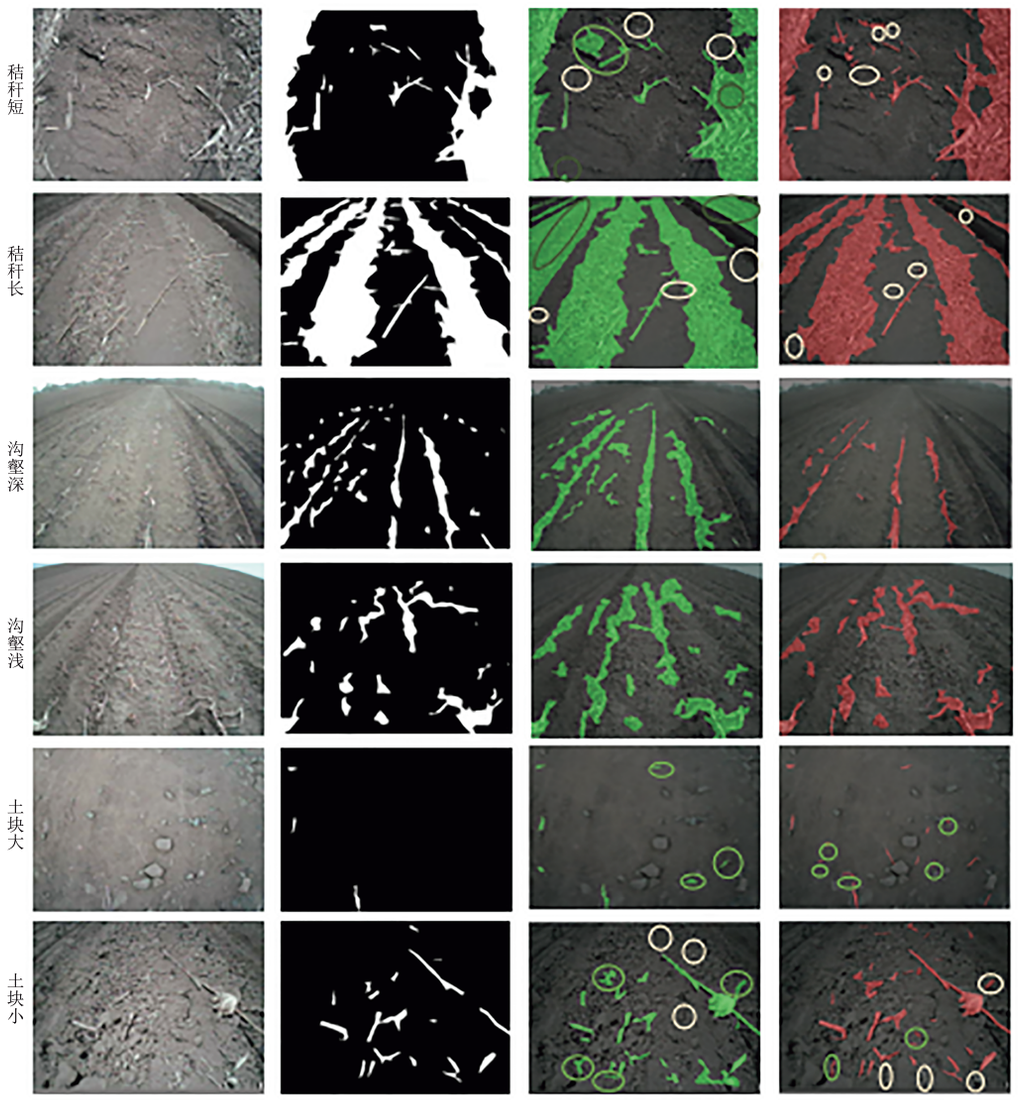

图8 其他干扰因素对检测影响结果

Fig. 8 Results of other interference factors

度过低的图像中基本不存在远距离农田,因此摄像度角度分为标准、较高和过高3挡,并用模型计算的覆盖率与真值图中秸秆覆盖率的比值和偏差作为距离划分影响结果的评价指标,若比值接近1说明检测结果与真值更接近,远离1说明秸秆存在明显的错分现象。

针对秸秆目标分割任务,由表2可以看出,各类图像距离划分后的平均偏差整体上更为均衡且优于分割前的结果。这是由于距离划分后,样本图像中不存在天空背景和远距离农田的干扰,使样本图像更接近标准图像。但在未划分的图像样本中,摄像头角度越高图中天空背景占比越大,在白平衡处理过程中颜色更接近白色的天空代替了秸秆作为偏色校正的基准,使模型中针对秸秆的颜色感知模块失效。因此,若无距离划分的前提下,田间大量秸秆覆盖时,角度过高会导致秸秆覆盖率结果偏大,而覆盖秸秆较少时,会使秸秆覆盖率结果偏小。

表2 距离划分前后结果对比

Tab. 2 Comparison of results before and after effective region segmentation

F2测试集		原始图像		距离划分后	
		秸秆量多	秸秆量少	秸秆量多	秸秆量少
摄像头角度	标准	0.974	1.062	0.974	1.062
	较高	1.095	0.892	0.965	1.054
	过高	1.134	0.851	0.963	1.087
平均偏差		0.096		0.05	

3.6 距离划分前后效果

距离划分前后效果如图9所示,其中黄色为漏分,绿色为错分。对比第1行与第2行,当秸秆像素占比较少时,第3列原始图像中漏分部分(在图中用黄圈标识)明显多于第5列划分后的图像,由于位于远处的秸秆分辨率较低且特征不明显,易被农田像素同化导致秸秆目标分割结果偏低;当秸秆像素占比较多时(如第3行与第4行所示),因模型损失函数总体更偏向于秸秆目标,在第

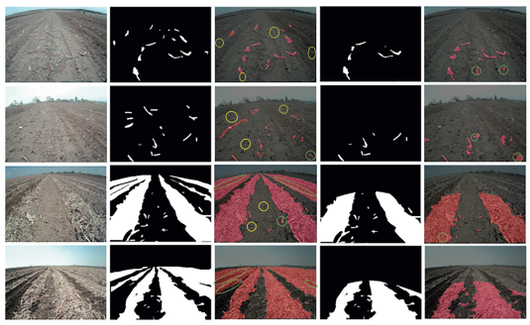

(a) 原图　(b) 划分前真值　(c) 划分前结果　(d) 划分后真值　(e) 划分后结果

图9　距离划分前后效果图

Fig. 9　Results before and after effective area division

3列图像中远处的未覆盖秸秆的垄沟被大量秸秆像素同化，导致秸秆目标分割结果偏高。另外秸秆高程对垄沟的遮挡影响随距离增加而变大，使得地物标注的准确性降低，因此距离划分可以提高图像质量，对提高秸秆目标分割准确率具有重要作用。

4　结论

（1）提出了基于白平衡特征增强的秸秆目标分割方法，该方法在DLv3+模型基础上融合了颜色感知模块与空间增强模块，利用白平衡技术提高秸秆目标在图中的对比度使其在多种干扰因素的影响下仍能保持对秸秆目标分割的准确率。

（2）DLv3+/CPM/SEM模型在秸秆目标分割模型性能对比试验结果表明，模型整体准确率和平均交并比分别为83.79%和79.45%，均优于其他对比方法。在不同光源条件、秸秆长度、垄沟深浅和土块大小的干扰条件下进行了定量和定性对比，DLv3+/CPM/SEM模型表现均优于改进前的DLv3+。

（3）DLv3+/CPM/SEM模型在不同干扰因素下均有较高检测精度，同时结合距离划分结果后，对非单一农田背景的秸秆监测图像覆盖率计算精度更为准确，为免耕播种监测秸秆覆盖率定量计算提供了技术支撑。

参　考　文　献

[1] MCNAIRN H, PROTZ R. Mapping corn field residue cover on agricultural fields in oxford county, ontario, using thematic mapper[J]. Canadian Journal of Remote Sensing, 2014, 19(2):152 - 159.

[2] MORRISON J E, HUANG C, LIGHTLE D T, et al. Residues cover measurement techniques[J]. Journal of Soil and Water Conservation, 1993, 48:479 - 483.

[3] 巩杰,黄高宝,陈利顶,等.旱作麦田秸秆覆盖的生态综合效应研究[J].干旱地区农业研究,2002,21(3):69 - 73.
GONG Jie, HUANG Gaobao, CHEN Liding, et al. Comprehensive ecological effect of straw mulch on spring wheat field in dryland area [J].Agricultural Research in the Arid Areas, 2002, 21(3): 69 - 73.(in Chinese)

[4] HARTWIG R O, LAFLEN J M. A meterstick method for measuring crop residues cover[J]. Journal of Soil and Water Conservation, 1978, 33(2):90 - 91.

[5] MORRISON J E, CHICHESTER F W. Still video image analysis of crop residues covers[J]. Soil Science Society of America, 1991, 34:2469 - 2474.

[6] 李志婷. 基于外部参数正交化法的秸秆覆盖度遥感估算中土壤影响校正研究[D]. 北京:中国科学院大学,2016.

[7] ZHENG B, CAMPBELL J B, SERBIN G, et al. Multitemporal remote sensing of crop residue cover and tillage practices: a validation of the min-NDTI strategy in the United States[J]. Journal of Soil & Water Conservation, 2013, 68(2):120 - 131.

[8] 张森,蒙继华,李强子,等.基于HJ-1B数据的冬小麦留茬覆盖度遥感估算[J].农业工程学报,2011,27(13):352 - 357.
ZHANG Miao, MENG Jihua, LI Qiangzi, et al. Estimation of winter wheat residue cover with HJ-1B data[J].Transactions of the CSAE, 2011, 27(13): 352 - 357.(in Chinese)

[9] 罗云霄. 山东禹城样区冬小麦作物茬覆盖度遥感估算研究[D]. 南京:南京大学,2013.

[10] 黄晋宇,刘忠,万炜,等.基于土壤异质背景的玉米秸秆覆盖度遥感反演[J].应用生态学报,2020,31(2):474 - 482.
HUANG Jinyu, LIU Zhong, WAN Wei, et al. Remote sensing retrieval of maize residue cover on soil heterogeneous background[J]. Chinese Journal of Applied Ecology, 2020, 31(2):474 - 482.(in Chinese)

[11] 刘媛媛,孙嘉慧,张书杰,等.用多阈值多目标无人机图像分割优化算法检测秸秆覆盖率[J].农业工程学报,2020,36(20):142 - 151.
LIU Yuanyuan, SUN Jiahui, ZHANG Shujie, et al. Detection of straw coverage based on multi-threshold and multi-target UAV image segmentation optimization algorithm[J]. Transactions of the CSAE, 2020, 36(20): 142 - 151.(in Chinese)

[12] 陶万成,张颖,谢芷萱,等. 基于时序Sentinel-2A影像的玉米秸秆覆盖区智能识别研究[J].光谱学与光谱分析,2022,42(6):1948 - 1955.
TAO Wancheng, ZHANG Ying, XIE Zixuan, et al. Intelligent recognition of corn residue cover area by time-series Sentinel-2A images [J].Spectroscopy and Spectral Analysis, 2022, 42(6): 1948 - 1955.(in Chinese)

[13] 赵丽,张晋国.地表秸秆覆盖度图像识别技术的研究[J].农机化研究,2005,27(4):240 - 242.
ZHAO Li, ZHAGN Jinguo. Study on the image identify methods about degree of soil straw cover[J].Journal of Agricultural Mechanization Research, 2005, 27(4): 240 - 242.(in Chinese)

[14] 李世卫,李洪文.基于计算机视觉的田间秸秆覆盖率计算[J].农机化研究,2009,31(1):20 - 22.
LI Shiwei, LI Hongwen. A counting method for residue cover rate in field based on computer vision [J]. Journal of Agricultural Mechanization Research, 2009, 31(1): 20 - 22.(in Chinese)

[15] PFORTE F, HENSEL O. Development of an algorithm for online measurement of percent residue cover[J]. Biosystems Engineering, 2010, 106(3):260 - 267.

[16] JAFARI A, ASADI V. Precise measurement of residue cover by means of image processing techniques[J]. International Journal of Natural and Engineering Sciences, 2011, 5(3):53 - 56.
[17] 苏艳波,张东远,李洪文,等.基于自动取阈分割算法的秸秆覆盖率检测系统[J].农机化研究,2012,34(8):138 - 142.
SU Yanbo, ZHANG Dongyuan, LI Hongwen, et al.Measuring system for residue cover rate based on automation threshold[J]. Journal of Agricultural Mechanization Research, 2012, 34(8): 138 - 142.(in Chinese)
[18] 王丽丽,徐岚俊,魏舒,等.基于Sauvola与Otsu算法的秸秆覆盖率图像检测方法[J].农业工程,2017,7(4):29 - 35.
WANG Lili, XU Lanjun, WEI Shu, et al. Straw coverage detection method based on Sauvola and Otsu segmentation algorithm[J]. Agricultural Engineering, 2017, 7(4): 29 - 35.(in Chinese)
[19] 李洪文,李慧,何进,等.基于人工神经网络的田间秸秆覆盖率检测系统[J].农业机械学报,2009,40(6):58 - 62.
LI Hongwen, LI Hui, HE Jin, et al. Measuring system for residue cover rate in field based on BP neural network[J].Transactions of the Chinese Society for Agricultural Machinery, 2009, 40(6): 58 - 62.(in Chinese)
[20] 于国庆,郝若帆,马洪涛,等.基于图像处理和支持向量粉碎性秸秆覆盖率的图像识别方法研究[J].河南农业科学,2018,47(11):155 - 160.
YU Guoqing, HAO Ruofan, MA Hongtao, et al.Research on image recognition method based on SVM algorithm and ESN algorithm for crushed straw mulching rate[J]. Journal of Henan Agricultural Sciences, 2018, 47(11):155 - 160.(in Chinese)
[21] 李佳,吕程序,苑严伟,等.快速傅里叶变换结合SVM算法识别地表玉米秸秆覆盖率[J].农业工程学报,2019,35(20):194 - 201.
LI Jia, LÜ Chengxu, YUAN Yanwei, et al. Automatic recognition of corn straw coverage based on fast Fourier transform and SVM[J]. Transactions of the CSAE, 2019, 35(20): 194 - 201.(in Chinese)
[22] 冯为栋.双目视觉在田间秸秆覆盖率监测系统中的应用[J].南方农机,2019,50(20):17.
[23] 刘媛媛,周小康,王跃勇,等.改进U-Net模型的保护性耕作田间秸秆覆盖检测[J].光学精密工程,2022,30(9):1101 - 1112.
LIU Yuanyuan, ZHOU Xiaokang, WANG Yueyong, et al.Straw coverage detection of conservation tillage farmland based on improved U-Net model[J]. Optics and Precision Engineering, 2022, 30(9): 1101 - 1112.(in Chinese)
[24] 马钦,万传峰,卫建,等.基于U-Net和特征金字塔网络的秸秆覆盖率计算方法[J].农业机械学报,2023,54(1):224 - 234.
MA Qin, WAN Chuanfeng, WEI Jian, et al. Calculation method of straw coverage based on U-Net network and feature pyramid network[J].Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(1): 224 - 234.(in Chinese)
[25] 安晓飞,代均益,路振田,等.基于彩色空间距离优化的秸秆覆盖率检测算法研究[J].农业机械学报,2023,54(增刊2):229 - 234.
AN Xiaofei, DAI Junyi, LU Zhentian, et al. Development of rapid detection algorithm of straw coverage rate based on color spatial distance gray and K-means method[J].Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp. 2): 229 - 234.(in Chinese)

(上接第80页)

[24] 农敢网.冬小麦生长周期[EB/OL].(2022-10-28)[2023-1-16].https://www.nonggan.com/a/34887.html.
[25] GB/T 5262—2008 农业机械试验条件测定方法的一般规定[S].北京:中华人民共和国国家质量监督检验检疫总局、中国国家标准化管理委员会,2008.
[26] 孔建磊,金学波,陶治,等.基于多流高斯概率融合网络的病虫害细粒度识别[J].农业工程学报,2020,36(13):148 - 157.
KONG Jianlei, JIN Xuebo, TAO Zhi, et al. Fine-grained recognition of diseases and pests based on multi-stream Gaussian probability fusion network[J]. Transactions of the CSAE, 2020,36(13):148 - 157.(in Chinese)
[27] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2018:4510 - 4520.
[28] WOO S, PARK J, LEE J, et al. CBAM: convolutional block attention module[C]//Proceedings of the European Conference on Computer Vision (ECCV),2018:3 - 19.
[29] BAO W X, YANG X H, LIANG D, et al. Lightweight convolutional neural network model for field wheat ear disease identification[J]. Computers and Electronics in Agriculture, 2021,189:106367.
[30] CAI Y L, ZENG F G, XIAO J Y, et al. Attention-aided semantic segmentation network for weed identification in pineapple field[J]. Computers and Electronics in Agriculture, 2023,210:107881.
[31] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv Preprint, arXiv: 1409.1556, 2014.
[32] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016:770 - 778.
[33] MA N N, ZHANG X Y, ZHENG H T, et al. ShuffleNet V2: practical guidelines for efficient CNN architecture design[C]//Proceedings of the European Conference on Computer Vision (ECCV), 2018:116 - 131.
[34] MEHTA S, RASTEGARI M. MobileVit: light-weight, generalpurpose, and mobile-friendly vision transformer[J]. arXiv Preprint, arXiv: 2110.02178,2021.
[35] LIU Z, LIN Y T, CAO Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. IEEE, 2021:10012 - 10022.
[36] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: visual explanations from deep networks via Gradient-based localization[C]//IEEE International Conference on Computer Vision, 2017:618 - 626.