doi:10.6041/j.issn.1000-1298.2026.04.030

基于改进 U－KAN 的田间秸秆覆盖率检测技术

马　钦[1]　陈子霖[1]　王昊天[1]　刘　哲[2]　张　凯[1]　史晓晨[1]
李海龙[3]　张婧芳[3]　吴才聪[1]
（1. 农业农村部农机作业监测与大数据应用重点实验室，北京 100083；2. 中国农业大学土地科学与技术学院，北京 100083；
3. 潍柴雷沃智慧农业科技股份有限公司，潍坊 261206）

摘要：准确高效地检测秸秆覆盖率关乎土壤保护和农业可持续发展，然而现有的秸秆覆盖率检测模型易受光照或阴影等自然环境的影响，当秸秆与土地相似度较高时模型精度会大幅下降。针对车载相机拍摄的秸秆图像中秸秆形态各异、光照引起土地泛白、土地颗粒感强或阴影遮挡的问题，本文提出了一种在自然环境下检测不同尺度秸秆的语义分割方法（Unified attention mixed pooling pyramid U－KAN）。本文用深度膨胀可分离卷积替代传统空洞空间金字塔池化的空洞卷积以获取更多秸秆细节信息，并在自适应平均池化的基础上，增加条带池化分支以更好捕获间隔较大秸秆的特征，从而构建混合池化膨胀空间金字塔模块，将该模块应用于主干网络的最高语义层以获取零散分布秸秆的多尺度信息。同时在解码阶段引入统一注意力融合模块以有效恢复秸秆分割边缘的细节信息。试验结果表明，UMU－KAN 在本文构建的秸秆数据集上平均交并比为 85.36%，平均像素精度为 91.71%，优于经典算法 Unet、Swin－Unet 和 DeepLabv3＋，其平均交并比相比 DeepLabv3＋高 1.25 个百分点，该模型对自然环境下形态各异的秸秆具有更强的分割性能和良好的鲁棒性，此外本文也进一步证明了柯尔莫戈洛夫-阿诺尔德网络（Kolmogorov-Arnold network，KAN）在农业视觉领域的发展潜力。

关键词：秸秆覆盖率；语义分割；空洞空间金字塔
中图分类号：TP391.4　　**文献标识码**：A　　**文章编号**：1000-1298（2026）04-0309-08　　**OSID**：

Field Straw Coverage Detection Method Based on Improved U－KAN

MA Qin[1]　CHEN Zilin[1]　WANG Haotian[1]　LIU Zhe[2]　ZHANG Kai[1]　SHI Xiaochen[1]
LI Hailong[3]　ZHANG Jingfang[3]　WU Caicong[1]
（1. *Key Laboratory of Agricultural Machinery Monitoring and Big Data Applications, Ministry of Agriculture and Rural Affairs, Beijing* 100083, *China*
2. *College of Land Science and Technology, China Agricultural University, Beijing* 100083, *China*
3. *Weichai Lovol Smart Agriculture Technology Co., Ltd., Weifang* 261206, *China*）

Abstract: Accurately and efficiently detecting straw coverage is crucial for soil protection and sustainable agriculture, as straw coverage not only affects soil fertility and moisture retention but also plays a key role in controlling soil erosion and improving the ecological environment. However, existing straw coverage detection models are often susceptible to interference from natural environmental factors such as lighting and shadows in practical applications. When the similarity between the straw and the soil in terms of color and texture is high, the accuracy of these models significantly decreases, leading to inaccurate coverage assessments and ultimately affecting the efficiency and reliability of farmland management decisions. Aiming to address the challenges posed by the diverse morphology of straw in images captured by vehicle-mounted cameras, including issues of image reflection and shadows, a novel semantic segmentation method called UMU－KAN for detecting straw of varying scales in natural environments was proposed. The replacement of conventional dilated convolutions in the atrous spatial pyramid pooling module with depth-wise dilated separable convolutions was proposed to enhance the extraction of fine-grained straw-

收稿日期：2025－04－21　修回日期：2025－06－04
基金项目：国家重点研发计划项目（2024YFD1500803）
作者简介：马钦（1978—），女，副教授，博士，主要从事计算机视觉研究，E-mail：sockline@163.com
通信作者：吴才聪（1975—），男，教授，博士，主要从事农机作业大数据挖掘和农机导航与位置服务信息研究，E-mail：wucc@cau.edu.cn

related detail information. Additionally, a strip pooling branch captured features of widely spaced straw more effectively, integrating feature information from various branches through skip connections to reduce information loss. This series of improvements constructed a mixed pooling dilated spatial pyramid module, applied to the top semantic layer of the backbone network, thereby obtaining multi-scale information for sparsely distributed straw. Furthermore, a unified attention fusion module appeared during the decoding phase to effectively restore detailed edge information of straw segmentation, enabling the model to better learn features from different levels. Experimental results demonstrated that UMU - KAN achieved a mean intersection over union (mIoU) of 85.36% and a mean pixel accuracy (mPA) of 91.71% on the constructed straw dataset. Compared with the Unet, Swin - Unet, and DeepLabv3 + models, UMU - KAN improved mIoU by 4.20, 3.26, and 1.25 percentage points, respectively, and mPA by 3.58, 2.39, and 0.77 percentage points, respectively. Additionally, the parameter count of UMU - KAN was significantly lower than that of Swin - Unet and DeepLabv3 +. UMU - KAN successfully achieved accurate detection of straw in images captured by agricultural machinery cameras, ensuring high detection efficiency even under dynamic and uncontrolled outdoor conditions. This not only highlighted the model's adaptability and precision but also further demonstrated the significant developmental potential of the KAN architecture in the field of precision agriculture, contributing to the promotion of sustainable agricultural practices and enhancing the efficiency of agricultural management.

Key words: straw coverage; semantic segmentation; atrous spatial pyramid

0 引言

保护性耕作(Conservation tillage, CT)是旨在减少土壤侵蚀和提升土壤健康的农业管理实践,其核心理念是通过在土壤表面保留一定量的作物残茬减少土壤干扰,从而保护土壤结构和养分循环。保护性耕作的重要性体现在多方面:①有助于减少土壤侵蚀,特别是在多风和多雨的地区,覆盖作物残茬可以有效防止土壤被冲刷。②保护性耕作能够增加土壤有机质含量,提高土壤结构,从而增强土壤的持水能力和肥力[1]。③长时间使用保护性耕作还能提高作物产量,减少对化肥和水资源的依赖[2]。

秸秆覆盖率是评估保护性耕作效果的重要指标,秸秆覆盖率的检测对于农业管理和政策实施具有重要意义。但传统人工秸秆覆盖率检测方法如拉绳法、采样法和目测法均需要消耗过多的人力物力且更易受到主观因素影响[3]。随着计算机图像处理技术的快速发展,众多国内外学者致力于研究利用图像法快速准确地进行秸秆覆盖率检测。RIEGLER 等[4]利用快速傅里叶变换提取图像的频率特征,并结合支持向量机进行分类,将图像从空间域转换到频率域,从而减少环境对秸秆检测的影响。WU 等[5]提出一种根据图像的灰度分布动态调整阈值并采用迭代法优化阈值选择的方法,可以在不需要高质量图像的情况下,有效地检测低分辨率农田图像中的秸秆。YANG 等[6]提出一种结合传统 Otsu 方法和最小交叉熵分割算法的方法,通过引入自适应权重参数调整阈值大小,从而对秸秆图像进行有效检测。安晓飞等[7]提出一种基于 K-means 和彩色空间距离灰度化方法相结合的秸秆检测方法,降低了细碎秸秆对覆盖率检测的影响。以上研究均为传统图像处理方法,主要利用颜色、纹理等图像浅层特征,依赖于图像数据中秸秆与土地的灰度差异,在光照不均或背景复杂的情况下对秸秆的检测精度会大幅下降。

在秸秆覆盖率的检测中,遥感技术可以有效识别和估算覆盖在农田上的秸秆。NAJAFI 等[8]结合地面真实数据和卫星图像,利用作物残留的光谱和空间特性,开发出基于规则集的 3 个分类,包括平均指数、耕作指数和灰度共生矩阵纹理特征对作物残渣覆盖进行评估。MEMON 等[9]结合 Sentinel - 2B 和 Landsat - 8 2 种不同的多光谱卫星数据,并应用作物残留物指数估算小麦秸秆覆盖率。这些指数包括归一化差异耕作指数、简单耕作指数以及归一化差异残留指数。研究表明 Sentinel - 2B 的光谱数据对小麦秸秆覆盖率的映射更为准确。DONG 等[10]通过结合 Landsat 和中分辨率成像光谱仪数据估算玉米秸秆的覆盖率,为保护性耕作和黑土保护的监控提供了技术支持。遥感技术可以快速、准确地覆盖广阔的地区并提供重复观测能力,但遥感数据获取成本较高且存在一定滞后性,此外遥感技术无法对田间秸秆进行精确检测。

由于深度学习强大的特征提取能力,深度学习技术在农业领域的应用正在为传统农业实践方式带来新的变革。近年来,已经有许多学者利用深度学习中的语义分割技术对田间秸秆的精确检测开展了相关研究工作。ZHOU 等[11]通过集成改进的残差网络和 Unet 模型进行秸秆覆盖率的精确检测,但在

阴影或光照变化的条件下，检测精度有所下降。刘媛媛等[12]改进了 Inception 结构，加入条纹池化和高效空间金字塔空洞卷积模块，形成新的 Gception 结构，以提高秸秆覆盖率检测的准确性和效率。马钦等[3]在 Unet 网络的基础上通过添加注意力机制和融合多种尺度的信息增强模型的识别能力，使得在复杂背景下的秸秆覆盖率检测更为准确有效。XU 等[13]替换 Unet 网络中编码器部分的前 5 层为 VGG19 网络的对应层，并引入并行双线性注意力模块，此方法有助于改善复杂背景下模型对断裂秸秆边缘的分割性能，但模型的鲁棒性差，在复杂背景下对秸秆与土地的区分仍有难度。LI 等[14]融合深度可分离卷积和多尺度特征提取模块，提高了模型的分割精度和效率，但此方法对光照条件依旧敏感，在逆光或阴影下会影响秸秆的识别。

由于秸秆图像是在农机日常作业过程中拍摄，常因光照影响导致图像中出现土地泛白、颗粒感增强、阴影或车辙印等干扰因素；同时，在自然环境下，秸秆分布零散且形态各异。为解决上述复杂情况检测问题，本文提出一种全新的田间秸秆覆盖率检测方法。针对秸秆形态多样、尺度差异显著的特征，提出混合池化膨胀空间金字塔模块（Mixed pooling dilated spatial pyramid module，MPDSPM），将其加入到 U－KAN 网络中，以扩展感受野更有效地学习秸秆的多尺度特征。此外，在编码阶段引入统一注意力融合模块（Unified attention fusion module，UAFM），使模型能够充分利用全局上下文信息捕捉更细致的秸秆边缘特征，以实现自然环境下田间秸秆的精确分割，并验证柯尔莫戈洛夫-阿诺尔德网络（Kolmogorov－Arnold network，KAN）在农业视觉任务中具有应用潜力。

1　材料与方法

1.1　图像采集与数据集构建

所使用秸秆图像数据通过安装在农机设备上的摄像头采集，摄像头固定在农机车头前方，镜头垂直向下，以捕捉农机作业过程的地面图像。目前获取的图像数据是由潍柴雷沃智慧农业科技股份有限公司在内蒙古扎兰屯地区采集，图像分辨率为 640 像素×480 像素，采集时间为 2024 年 4 月 30 日和 5 月 1 日。为了使构建的模型算法能够适应自然环境，根据田间实际情况和自然光照条件，在多种环境下进行了图像采集。如图 1 所示，采集到的秸秆图像包含多种复杂情况，如秸秆分布零散、形态各异，此外还有土地颗粒感强、土地泛白、阴影干扰以及车辙印干扰等问题，共采集自然环境下田间秸秆图像 1 729 幅，将数据集按比例 8∶1∶1 划分为训练集、验证集与测试集。这些多样化的数据为算法在实际应用中的适应性提供了支持。使用 Labelme 工具对采集的秸秆图像进行人工标注，标注时将标签分为秸秆类和背景类 2 类。

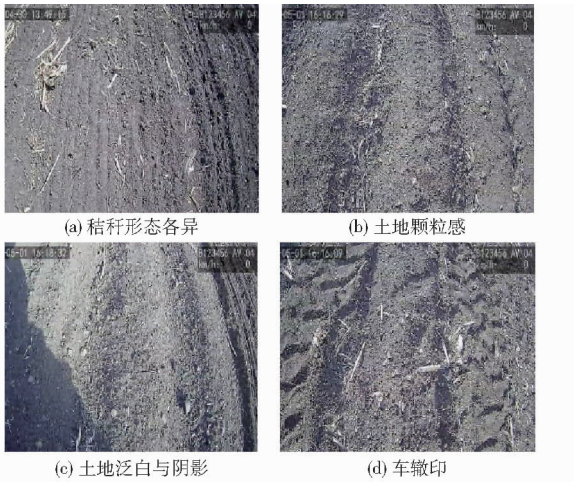

(a) 秸秆形态各异　(b) 土地颗粒感　(c) 土地泛白与阴影　(d) 车辙印

图 1　秸秆数据集示例

Fig. 1　Examples of straw dataset

1.2　数据增强

为了进一步提高模型在不同田间环境下的泛化能力以及鲁棒性，在训练模型前对数据集的每幅图像随机使用旋转、翻转、亮度修改其中 1 种图像增强方法[15]，如图 2 所示，通过数据增强将图像总数扩充到 3 458 幅，其中训练集 2 766 幅、验证集 346 幅和测试集 346 幅，保证了数据多样性。

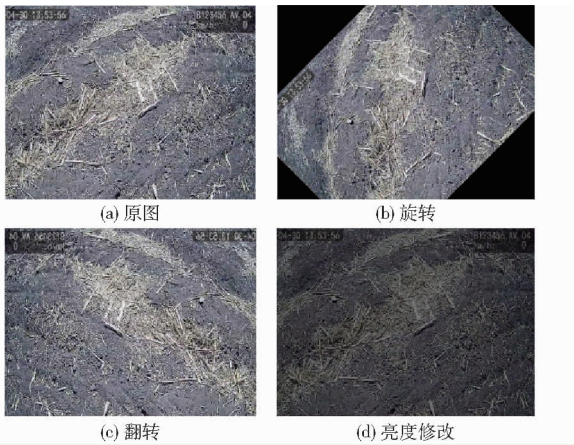

(a) 原图　(b) 旋转　(c) 翻转　(d) 亮度修改

图 2　数据集增强示例

Fig. 2　Examples of dataset augmentation

1.3　秸秆覆盖率检测模型构建

1.3.1　改进 U－KAN 网络结构

Unet[16]的对称编码器-解码器卷积网络结构被广泛应用于农业领域[17]，专家学者针对各种实际问题对 Unet 的改进也层出不穷[18-21]，该系列网络在背景相对简单、目标间差异较小的分割任务中有很好的性能表现。然而，对于车载相机拍摄的具有复

杂背景的田间秸秆图像,特别是面对光照影响下秸秆与土地相似度较高、秸秆形态各异且分布零散无序的情况时,此类模型对秸秆的分割效果明显下降。LI 等[23]受到柯尔莫戈洛夫-阿诺尔德网络[22]在准确性和可解释性方面显著成果的启发,将 KAN 模块集成到 Unet 结构中,从而构建 U-KAN,包括卷积阶段和 KAN 阶段。输入图像经过编码器中卷积阶段处理后,再通过 KAN 阶段提取中间特征,并在解码器中进行重建。KAN 模块的加入可提升模型参数效率以及使模型能更好捕获图像中复杂的非线性模式,因此当秸秆与土地灰度差异较小且土地存在阴影或颗粒感较强时,U-KAN 网络对于田间秸秆的分割具有明显优势。由于田间秸秆形态各异且分布零散无序,而 U-KAN 网络的感受野有限,导致对于不同尺度特征秸秆的提取能力不够强,从而造成 U-KAN 网络秸秆检测精度下降。因此,本文提出一种 UMU-KAN 网络,网络结构如图 3 所示,将提出的 MPDSPM 集成到模型网络的最高语义层,以扩大模型的感受野,从而更好地捕捉图像中多尺度的秸秆特征信息。为进一步增强模型的分割能力,在编码阶段引入 UAFM,通过丰富秸秆特征的融合表达,强化模型对全局上下文信息的学习能力,从而提高秸秆边缘细节的分割效果,实现秸秆的精准分割。

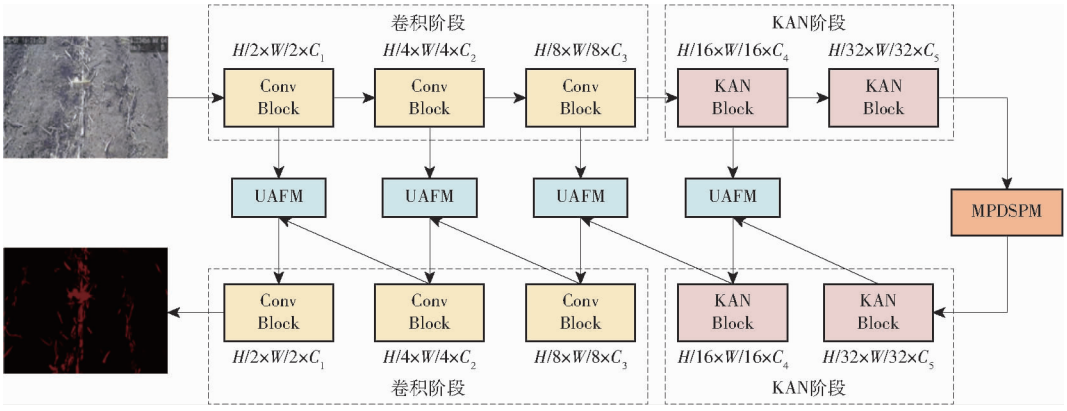

图 3 UMU-KAN 结构

Fig. 3 Structure of UMU-KAN

1.3.2 MPDSPM 模块

针对自然田间场景中秸秆分布零散且形态多样的特点,采用混合池化膨胀空间金字塔模块使模型在获取秸秆多尺度特征信息的同时,能获取更多的秸秆细节信息。

图 4 为 MPDSPM 结构,图中 DConv 表示膨胀卷积;DDConv 和 PConv 分别表示深度膨胀可分离卷积结构中的深度膨胀卷积和逐点卷积。由图 4a 可知,传统空洞空间金字塔池化(Atrous spatial pyramid pooling,ASPP)包含多个并行的具有不同膨胀率的空洞卷积分支以及一个自适应平均池化分支,自适应平均池化和多尺度空洞卷积结合使得模型能够获取不同尺度的特征信息[24-26],但 ASPP 结构难以有效反映秸秆图像中秸秆杂乱无序的分布特征。本文所提出的混合池化膨胀空间金字塔模块结构如图 4b 所示,采用 3 个 3×3 深度膨胀可分离卷积(Depth-wise dilated separable convolution,DDSC)替换传统 ASPP 结构中 3 个 3×3 膨胀卷积[27],DDSC 将标准卷积拆分为 2 层,第 1 层使用深度膨胀卷积以提高空间特征捕捉能力,第 2 层使用逐点卷积(Point-wise convolution)将各通道的特征进行线性组合。相比单纯的膨胀卷积,该结构能够在保持模型参数量较少的同时,通过堆叠更深的网络层级增强对图像中秸秆边缘等细粒度特征的提取能力,从而兼顾局部细节捕捉与多尺度特征表达的平衡性。此外,传统 ASPP 结构每个分支在前馈过程不共享任何信息[28],这会使特征融合时损失大量秸秆的细节特征,从而影响模型对细小秸秆的检测。为此本文采用跳跃连接拼接各个分支之间的特征信息,以提高模型对于不同尺度语义信息的理解能力,使模型能够更好地提取秸秆的详细特征。同时,在 ASPP 原有自适应平均池化的基础上,增加条带池化(Strip pooling)分支,条带池化分支通过沿水平与垂直方向分别执行狭长型池化核($1\times N$ 与 $N\times 1$)操作,捕获秸秆目标的带状延展特性与跨区域空间依赖性,以提高模型捕获长距离空间依赖性和利用信道间依赖性的能力[29],从而使模型在学习秸秆带状特征的同时也能够捕获到间隔较远秸秆的细节特征,有助于对复杂土地背景中秸秆的精确分割。

1.3.3 统一注意力融合模块

在复杂自然场景中,尤其是当图像中土地出现泛白、颗粒感强或车辙印干扰时,秸秆的颜色和纹理特征与背景土地的相似度较高,模型难以对秸秆边缘进

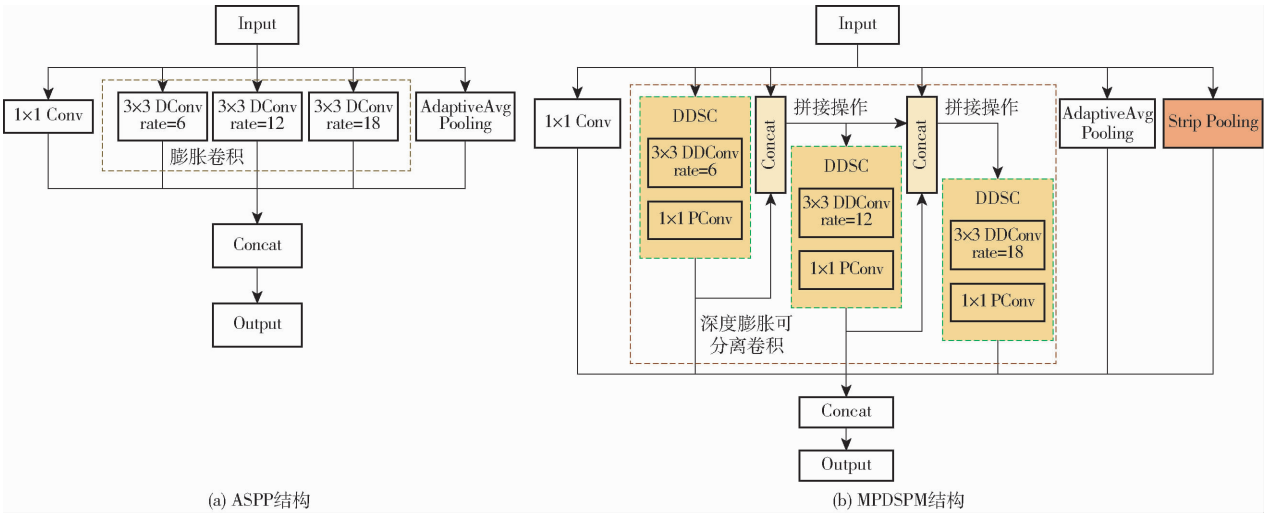

图 4　结构对比

Fig. 4　Structural comparison

行准确分割。为解决这一问题，引入统一注意力融合模块，通过整合编码阶段和解码阶段不同层次的特征提升模型对秸秆整体特征的表示能力[30]，UAFM 结构如图 5 所示。传统通道注意力模块一般仅通过单层特征图生成通道权重，而 UAFM 的通道注意力通过联合浅层特征与深层特征生成权重 α，然后再将不同层次的输入特征与权值进行融合，使得 UAFM 能够同时获取浅层细节的局部显著性与深层语义的全局指导，从而生成更具判别力的权重，实现跨层信息互补，以此增强语义分割的特征表示[31]，这对于区分秸秆与背景土地的细微差异尤其有效。

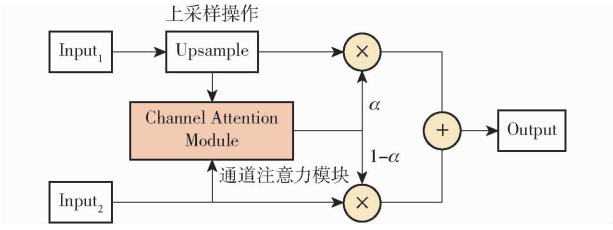

图 5　UAFM 结构

Fig. 5　Structure of UAFM

UAFM 在整合不同层次的特征时，利用通道注意力对秸秆的颜色、形态和纹理特征进行细化处理，确保模型能够在全局和局部上下文之间取得平衡，从而提高分割的鲁棒性。特别是在光照变化、背景干扰明显的田间场景时，UAFM 使模型能够更精细地分离秸秆与背景土地，有效提升模型的分割效果。

1.4　模型训练与评价指标

1.4.1　训练环境与参数

设备采用 Linux 操作系统，显卡型号为 NVIDIA GeForce RTX 3090；编程语言版本为 Python 3.9.17；模型训练架构为 Pytorch 2.0.1；模型训练采用 AdamW 优化器防止权重衰减导致模型过拟合，初始设置学习率为 1×10^{-4}、最小学习率为 1×10^{-6}、学习率下降方式为余弦下降、训练迭代次数为 600、批次大小为 8。在本文试验环境下模型训练平均每次迭代约需要 3.5 min，600 轮共计约 35 h。

1.4.2　评价指标

利用平均交并比（Mean intersection over union，mIoU）、平均像素精度（Mean pixel accuracy，mPA）以及模型参数量评估模型分割性能[32]。

2　结果与分析

2.1　UMU－KAN 消融试验

为了验证本文提出的 MPDSPM 和 UAFM 对 U－KAN 模型秸秆检测精度的影响，在自制田间秸秆数据集上进行消融试验，试验结果如表 1 所示。

表 1　消融试验结果

Tab. 1　Ablation experiment results

U－KAN	MPDSPM	UAFM	mIoU/%	mPA/%	参数量
√	×	×	84.52	91.08	9.38×10^{6}
√	√	×	85.13	91.47	1.32×10^{7}
√	√	√	85.36	91.71	1.38×10^{7}

注：√表示引入该模块，×表示未引入该模块。

由表 1 可知，U－KAN 的 mIoU 和 mPA 分别为 84.52% 和 91.08%；在最高语义层添加本文提出的 MPDSPM 后，模型能够得到更密集的像素采样，同时使模型对不同尺度秸秆的特征信息产生更好的理解，从而使 mIoU 和 mPA 分别提升至 85.13% 和 91.47%；继续在编码阶段加入 UAFM 后，模型能够更好地融合来自不同层次的语义信息，模型特征表示能力进一步得到加强，mIoU 和 mPA 分别提升至 85.36% 和 91.71%。

消融试验预测结果如图 6 所示，图 6 第 3 行 U－KAN 模型对于图 6a、6b 原始图像中体积较大的秸

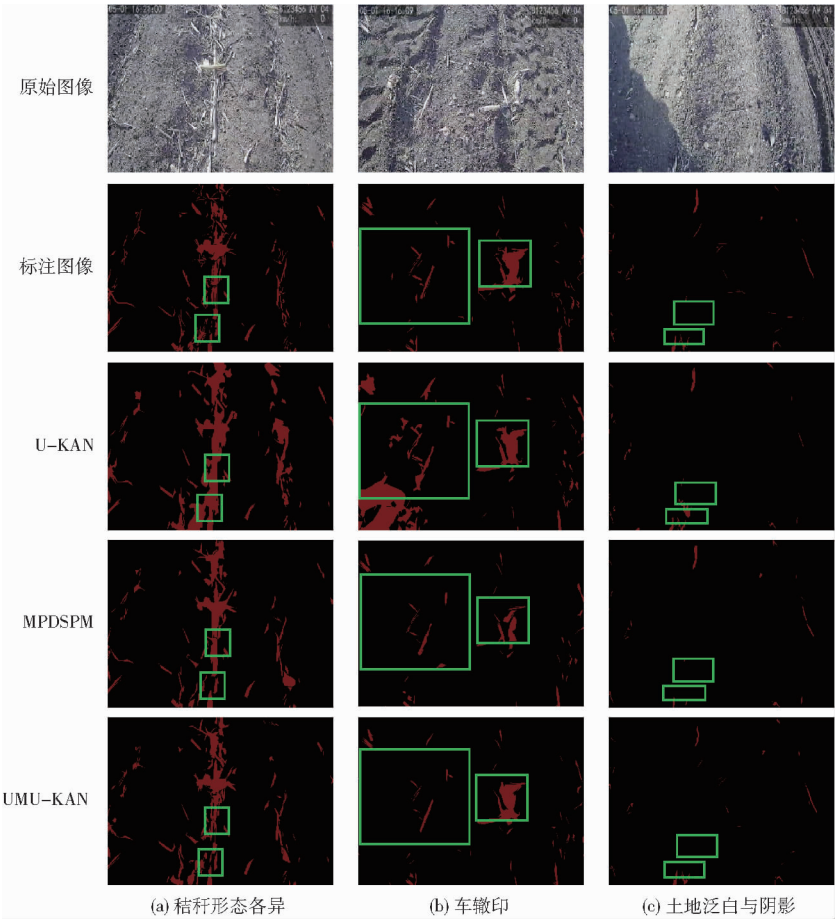

图 6 消融试验预测结果

Fig. 6 Predicted results from ablation experiment

秆具有良好的分割效果;当图 6c 原始图像中存在秸秆间有细小缝隙和细小秸秆零散分布以及土地泛白和阴影干扰时,模型的分割结果不够精确,无法准确分割出秸秆间的细小缝隙以及零散细碎秸秆。

此外,面对图 6b 原始图像车辙印及土地颗粒感强时,U-KAN 模型也会将部分土地错误识别成秸秆。图 6 第 4 行尽管模型分割精度有所改善,但分割结果中的秸秆边缘依旧较为模糊,且少量的误判仍然存在。图 6 第 5 行结合 MPDSPM 和 UAFM 后,UMU-KAN 模型能够更精细地分割秸秆,尤其是能够准确识别秸秆间的细小缝隙,突出秸秆的细小特征,显著提升了模型在自然环境下对于秸秆的分割效果。同时,这种改进也解决了秸秆与土地高度相似的问题,使得模型能够更好地区分秸秆与背景土地,从而提高了模型整体分割性能。

2.2 不同语义分割模型试验

为了更直观地验证 UMU-KAN 在田间秸秆检测上的性能优势,选用经典语义分割模型 Unet、Swin-Unet 和 DeepLabv3+进行对比试验,并使用相同秸秆数据集和相同训练参数进行训练测试,结果如表 2 所示。由表 2 可知,UMU-KAN 模型 mIoU 和 mPA 为 85.36% 和 91.71%,与 Unet、Swin-Unet 和 DeepLabv3+模型相比,mIoU 和 mPA 分别提高 4.20、3.26、1.25 个百分点和 3.58、2.39、0.77 个百分点。UMU-KAN 参数量也远小于 Swin-Unet 和 DeepLabv3+,同时在推理时间上也优于 Swin-Unet 和 DeepLabv3+。因此,本文提出的 UMU-KAN 模型能够在保证农机车载相机实时监测的情况下,有效提升田间秸秆覆盖检测精度。

表 2 不同模型试验结果

Tab. 2 Experimental results of different models

模型	mIoU/%	mPA/%	参数量	推理时间/ms
Unet	81.16	88.13	7.770×10^6	23
Swin-Unet	82.10	89.32	2.715×10^7	42
DeepLabv3+	84.11	90.94	3.976×10^7	45
UMU-KAN	85.36	91.71	1.378×10^7	33

不同模型语义分割试验结果如图 7 所示,3 个原始图像中均存在秸秆分布不均匀、形态多样的情况,Unet 和 Swin-Unet 由于其网络结构相对简单,在捕捉图像多尺度特征方面表现不足,限制了在复杂自然环境下的秸秆检测能力。在图 7 第 3 行和第 4 行中,对图 7b 原始图像中土地泛白、强颗粒感以及图 7c 原始图像中阴影,Unet 和 Swin-Unet 易将土地误判为秸秆,导致大面积分割错误。在图 7 中

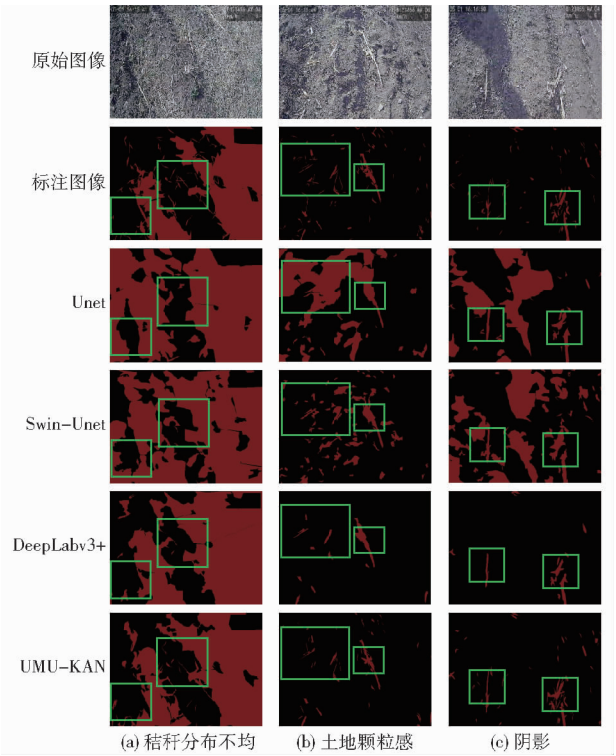

图 7　不同模型语义分割试验结果

Fig. 7　Results from different semantic segmentation models

第 4 行中，Swin－Unet 在自注意力机制的加持下，尽管对局部特征的学习有所改善，但其对分布稀疏且与土地高度相似的秸秆检测上仍然表现不佳。

由图 7 中第 5 行可知，由于 DeepLabv3＋在特征解码和边缘细节处理上的局限性，该模型对于细小秸秆和秸秆边缘的分割效果不佳，秸秆的细节特征被忽略。由图 7 第 6 行可知，UMU－KAN 对于成片分布和零散分布的秸秆都有着更为精细的分割效果。同时，UMU－KAN 在土地泛白和阴影干扰下依旧能够实现对秸秆的准确分割。本文 UMU－KAN 则在多方面实现了显著提升，UMU－KAN 能够捕获更为丰富的多尺度秸秆信息，进一步增强了对细小、零散秸秆的检测能力。此外，UMU－KAN 在特征融合和边缘处理上也有提升，模型能够有效结合不同层次的特征，准确捕获局部细节信息，从而能够反映高度相似的局部特征。

3　结论

（1）提出的 UMU－KAN 模型相较经典模型 Unet、Swin－Unet 和 DeepLabv3＋，表现出了最佳分割效果，其 mIoU 和 mPA 分别为 85.36% 和 91.71%。UMU－KAN 可以获取图像复杂的非线性信息且能更好地学习多尺度特征，因此当秸秆与土地对比度低或土地颗粒感强时，UMU－KAN 在秸秆检测上有明显优势。不仅进一步证明了 KAN 在视觉领域的发展潜力，也展示了其在农业应用中的独特优势。

（2）本文模型训练时间相对较长，在本文试验环境下模型训练平均每次迭代约需要 3.5 min，600 轮共计约 35 h。此外，当图像中秸秆细小不明显时会加大模型的检测难度。在未来研究中，需要考虑调整模型的内部结构来实现模型的轻量化处理，同时改进模型对于细小目标的检测能力，并进一步扩大测试数据集的多样性以验证模型的鲁棒性和泛化性。

参　考　文　献

[1] LÜ L, GAO Z, LIAO K, et al. Impact of conservation tillage on the distribution of soil nutrients with depth[J]. Soil & Tillage Research, 2023, 225: 105527.

[2] ZHANG W, YU Q, TANG H, et al. Conservation tillage mapping and monitoring using remote sensing[J]. Computers and Electronics in Agriculture, 2024, 218: 108705.

[3] 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)

[4] RIEGLER P, PRANKL J, BAUER T, et al. A machine learning approach for pixel wise classification of residue and vegetation cover under field conditions[J]. Biosystems Engineering, 2018, 169: 188－198.

[5] WU S, GUO X, LI J, et al. A straw coverage rate calculation method based on single image processing[C]// International Conference on Artificial Intelligence, Human-Computer Interaction and Robotics (AIHCIR), 2023: 483－490.

[6] YANG X, ZHANG W. Enhanced detection of straw coverage using a refined AdaBoost algorithm and improved Otsu method[J]. Traitement du Signal, 2023, 40(3): 927－937.

[7] 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 method[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp. 2): 229－234. (in Chinese)

[8] NAJAFI P, NAVID H, ESKANDARI I, et al. Object-based satellite image analysis applied for crop residue estimating using Landsat OLI imagery[J]. International Journal of Remote Sensing, 2018, 39(19): 6117－6136.

[9] MEMON M, CHEN S, NIU Y, et al. Evaluating the efficacy of Sentinel－2B and Landsat－8 for estimating and mapping wheat

straw cover in rice-wheat fields[J]. Agronomy, 2023, 13(11): 2691.
[10] DONG Y, XUAN F, HUANG X, et al. A 30-m annual corn residue coverage dataset from 2013 to 2021 in Northeast China [J]. Scientific Data, 2024, 11(1): 216.
[11] ZHOU D, LI M, LI Y, et al. Detection of ground straw coverage under conservation tillage based on deep learning[J]. Computers and Electronics in Agriculture, 2020, 172: 105369.
[12] 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)
[13] XU X, GAO Y, FU C, et al. Research on the corn stover image segmentation method via an unmanned aerial vehicle (UAV) and improved U-Net network[J]. Agriculture, 2024, 14(2): 217.
[14] LI M, QI J, TIAN X, et al. Smartphone-based straw incorporation: an improved convolutional neural network[J]. Computers and Electronics in Agriculture, 2024, 221: 109010.
[15] CAI X, ZHU Y, LIU S, et al. FastSegFormer: a knowledge distillation-based method for real-time semantic segmentation of surface defects in navel oranges[J]. Computers and Electronics in Agriculture, 2024, 217: 108604.
[16] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[J]. Medical Image Computing and Computer-Assisted Intervention, 2015, 9351: 234-241.
[17] SARKAR M, MANDAL A, TUDU A. DC-UNet: looking for follicles in the ovarian ultrasound images[J]. Computers and Electronics in Agriculture, 2024, 8: 100149.
[18] CAO H, WANG Y, CHEN J, et al. Swin-Unet: Unet-like pure transformer for medical image segmentation[J]. Proceedings of the ECCV Workshops, 2022, 2: 205-218.
[19] HE X, ZHOU Y, ZHAO J, et al. Swin transformer embedding UNet for remote sensing image semantic segmentation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-15.
[20] MA J, LI F, WANG B. U-Mamba: enhancing long-range dependency for biomedical image segmentation[J]. arXiv Preprint, arXiv: 2401.04722,2024.
[21] HU Z, YANG H, LOU T, et al. Concurrent channel and spatial attention in fully convolutional network for individual pig image segmentation[J]. International Journal of Agricultural and Biological Engineering, 2023, 16: 232-242.
[22] LIU Z, WANG Y, VAIDYA S, et al. KAN: kolmogorov-arnold networks[C]// 13th International Conference on Learning Representations, ICLR, 2025:66342-66388.
[23] LI C, LIU X, LI W, et al. U-KAN makes strong backbone for medical image segmentation and generation[J]. Association for the Advancement of Artificial Intelligence, 2025,39(5): 4652-4660.
[24] YU Q, WANG H, KIM D, et al. CMT-DeepLab: clustering mask transformers for panoptic segmentation[C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2022: 2550-2560.
[25] SUN X, XIE Y, JIANG L, et al. DMA-Net: DeepLab with multi-scale attention for pavement crack segmentation[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23: 18392-18403.
[26] YANG J, TU J, ZHANG X, et al. TSE DeepLab: an efficient visual transformer for medical image segmentation[J]. Biomedical Signal Processing and Control, 2023, 80: 104376.
[27] SUN J, ZHOU J, HE Y, et al. RL-DeepLabv3+: a lightweight rice lodging semantic segmentation model for unmanned rice harvester[J]. Computers and Electronics in Agriculture, 2023, 209: 107823.
[28] KANG S, LI D, LI B, et al. Maturity identification and category determination method of broccoli based on semantic segmentation models[J]. Computers and Electronics in Agriculture, 2024, 217: 108633.
[29] HOU Q, ZHANG L, CHENG M, et al. Strip pooling: rethinking spatial pooling for scene parsing[C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 4002-4011.
[30] PENG B, LIU Y, ZHU X, et al. Femoral segmentation of MRI images using PP-LiteSeg[C]// IEEE-EMBS International Conference on Biomedical and Health Informatics (BHI), 2022: 1-4.
[31] PENG J, LIU Y, TANG S, et al. PP-LiteSeg: a superior real-time semantic segmentation model[J]. arXiv Preprint, arXiv: 2204.02681,2022.
[32] 俞高红,王一淼,甘帅汇,等. 改进 DeepLabV3+算法提取无作物田垄导航线[J]. 农业工程学报, 2024, 40(10): 168-175.
YU Gaohong, WANG Yimiao, GAN Shuaihui, et al. Extracting the navigation lines of crop-free ridges using improved DeepLabV3+[J]. Transactions of the CSAE, 2024, 40(10): 168-175. (in Chinese)