DOI: 10.12398/j.issn.2096-7217.2026.01.002

小麦联合收获机导航路径识别方法研究

李加念, 吴坤澍, 李坤依, 陈绍民*

(昆明理工大学现代农业工程学院,云南昆明,650500)

摘要:针对小麦收获机导航路径识别方法难以兼顾准确性和实时性等问题,本研究在DeepLabv3+模型的基础上进行轻量化设计,采用MobileNetV3-Large替换原主干网络,并使用Leaky_ReLU替代ReLU激活函数;为了进一步减少网络计算量,将金字塔池化模块(atrous spatial pyramid pooling, ASPP)中的3个不同扩张率的空洞卷积替换为具有相同扩张率的深度可分离卷积(depthwise separable convolution, DSC)。为使小麦收获机导航路径识别研究具有较好的普遍性,采集了强光、弱光、逆光、顺光、阴影、地块边缘6种典型环境下的小麦收获区图像,使用Labelme工具对采集图像中的道路信息进行标注,构建小麦收获区域数据集。在路径提取阶段,通过水平扫描法从分割掩码图中获取关键点,并利用多段三次B样条算法拟合导航路径。试验结果表明,改进后的DeepLabv3+模型分割精度和交并比分别为98.04%和95.20%,视频图像处理帧率为7.5帧/s。6种小麦典型环境下,导航路径识别的平均像素误差和平均距离误差分别为7.4像素和37 mm,小麦收获机行驶速度约为1.5 m/s,单帧图像路径识别时间约为0.15 s,能够有效地满足小麦收获机实时性和准确性的需求。本研究可为提升小麦收获机自主导航能力提供理论基础和技术支撑。

关键词: DeepLabv3+;语义分割;导航路径;小麦收获机;路径识别;迁移学习

中图分类号:S24 **文献标识码:**A **文章编号:**2096-7217(2026)01-0008-11

李加念, 吴坤澍, 李坤依, 陈绍民. 小麦联合收获机导航路径识别方法研究[J]. 智能化农业装备学报(中英文), 2026, 7(1): 8-18

LI Jianian, WU Kunshu, LI Kunyi, CHEN Shaomin. Research on navigation path recognition method for wheat combine harvester [J]. Journal of Intelligent Agricultural Mechanization, 2026, 7(1): 8-18

0 引言

中国小麦产量居世界第一,但在收获过程中存在机械化程度低、农业劳动力短缺、劳动强度大等问题[1]。自动导航技术可以降低农业驾驶员的劳动强度,极大地提高田间作业的品质和效率,对小麦产业发展有重要价值[2]。目前智能农机田间路径导航主要依赖于两种技术:卫星定位系统导航和机器视觉导航[3]。基于卫星定位系统的导航技术适用于开阔的田地,但其性能极易受到天气条件和卫星信号的影响[4]。机器视觉导航技术利用安装在农机上的摄像头捕捉田地的图像,通过图像技术和计算机视觉算法识别作物,解决农机压苗问题的同时为农机提供实时自主导航信息[5-8]。目前机器视觉导航系统面临着光照和边缘干扰的挑战[9],以及收获机在作业中实时路径调整引发的图像处理延迟问题[10]。近年来,卷积神经网络在农业视觉任务中成效显著[11],基于深度学习的语义分割算法能够在复杂多变的环境中将目标与背景分离,避免人为选择的局限性[12-13],显著提高精确性与鲁棒性。

在农业场景的语义分割应用研究中,韩振浩等[14]采用U-Net网络分割果园图像,先通过道路分割掩码提取关键点,再结合多段B样条曲线拟合算法完成果园导航路径的识别。孟庆宽等[15]基于MobileNetV2轻量卷积神经网络,提出一种结合通道注意力和多尺度特征融合的语义分割模型,实现了在不同田间道路环境下的准确道路识别。吴伟斌等[16]在PSPNet模型的基础上构建了MS-PSPNet模型,像素准确率超过92%,能够实现准确分割果、茶园的道路。LI等[17]利用改进的ICNet快速语义分割模型分割未收割作物与已收割区域,实现了未收获作物边界的精确识别。侯文慧等[18]采用MobileNetV3-Large作为U-Net的主干特征提取网络,并加入注意力机制在草莓、蓝莓、葡萄果园垄间试验,平均像素准确率分别达到99.13%、98.75%和99.29%。

当前小麦收获机导航路径识别中,田间道路边缘

收稿日期:2025-07-09 修回日期:2025-09-27

基金项目:云南省"兴滇英才支持计划"青年人才项目(KKRD202223052);国家自然科学基金(52069008)

第一作者:李加念,男,1983年生,湖南道县人,博士,教授;研究方向为农业智能化检测与控制、水肥一体化智能装备与技术。E-mail: ljn825@163.com

*通信作者:陈绍民,男,1989年生,四川蓬溪人,博士,副教授;研究方向为水肥高效利用与农业遥感。E-mail: shaomin_ly24@126.com

不规则性、环境背景复杂以及光照条件变化大等因素，显著增加路径信息生成难度；现有导航线路生成方式局限于单一图像检测生成为主，缺乏一种实时连续的路径识别方法。

针对上述问题，本研究构建强光、弱光、逆光、顺光、阴影及地块边缘6种典型小麦收获区域数据集，对DeepLabv3+模型进行轻量化改进，对模型输出的道路掩码采用水平扫描法提取关键信息点，并构建多段三次B样条曲线拟合导航路径。最后采用平均像素误差和平均距离误差等评价指标检测该方法是否在实际收获场景中满足小麦收获路径导航需求。

1　图像采集与方法

1.1　图像采集

本研究图像采集地点在北京小汤山国家精准农业研究示范基地，采集时间为2021年6月18—22日。联合收获机采集平台如图1所示，机具行进速度保持在1.5 m/s，通过搭载的ZED2双目相机进行图像采集，并存储于车载计算机内。相机固定于收割机顶部，相机安装位置与水平面呈约30°向下倾斜角，相机采集分辨率为1 280像素×720像素的RGB图像，采集帧率为30帧/s。为了增强语义分割模型的鲁棒性和泛化性，基于光照强度、阴影、地块边缘等因素对小麦收获场景划分，如图2所示。



图1　小麦收割机收集图片场景

Figure 1　A scene of pictures of wheat harvesters collecting wheat



图2　小麦场景划分

Figure 2　Scene division of wheat

1.2　数据增强

为提升模型的鲁棒性并扩充样本容量，采用±10°旋转、水平翻转和图像色彩调整操作进行数据增强。如图3所示，旋转是对图像任意选择±10°，空白区域填0像素值，水平翻转为图像左右对称变换，通过旋转和翻转操作提高小麦导航路径方向的复杂性。图像色彩调整在像素空间位置保持不变的基础上对图像的像素值进行调整，模拟实际环境中光照不均匀及天气变化等情况。

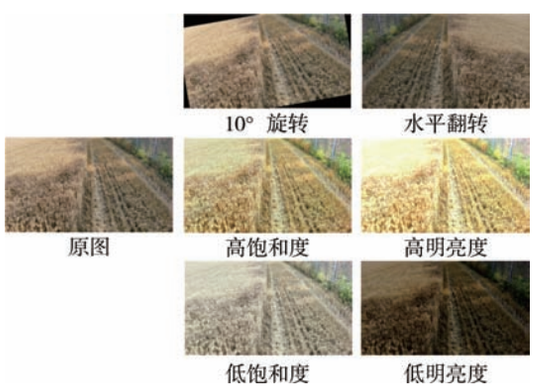


图3　数据增强

Figure 3　Data enhancement

1.3　数据集制作

从采集数据中随机选取2 340张图像进行小麦数据集制作，其中训练集为1 394张图片，478张用于验证集，478张用于测试集。利用Labelme软件对未收获区域和已收获区域进行标注，得到未收获区域、已收获区域和背景3分类标签，如图4所示，将未收获区域标为红色区域，已收获图像为绿色区域，背景为黑色区域。在6种环境下训练集、验证集和测试集按3∶1∶1比例划分，以构成小麦收获场景数据集。

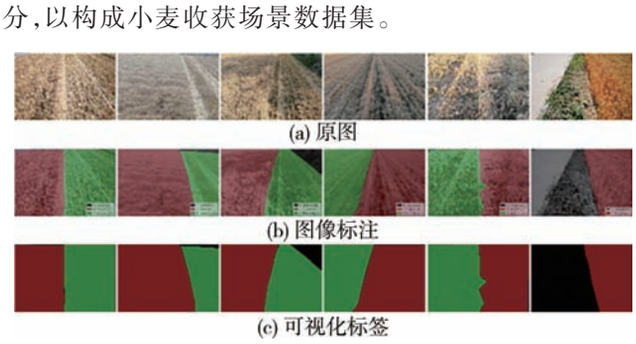


图4　小麦收获场景原图及标签图

Figure 4　Original image and label image of wheat harvest scene

2　基于语义分割的小麦收获机导航路径提取方法

2.1　网络改进

2.1.1　改进的DeepLabv3+语义分割网络

DeepLabv3+是在DeepLabv3的基础上增量更

新,其通过空洞卷积来提高分割的精度,使用深度可分离卷积替代传统标准卷积来提高分割效率,并采用ASPP模块使得网络能够更好地处理复杂场景中的多尺度目标。然而,DeepLabv3+相对复杂的网络结构赋予网络强大学习能力的同时,也面临较高的计算负担。

为了实现对小麦图像高精度分割与实时性需求,对DeepLabv3+网络进行改进:

1)为了保证分割精度的同时提高网络模型分割的实时性,采用MobileNetV3-Large替代DeepLabv3+的骨干网络,并将网络做了以下调整:保留MobileNetV3-Large的前14层结构,将Bneck2操作之后输出作为浅层特征,将Bneck9之后的输出作为深层特征。使用Leaky_ReLU(L_RE)函数替换ReLU激活函数。

2)为了进一步降低网络计算量,提高模型推理速度,降低对硬件资源的需求,将ASPP中3个不同扩张率的空洞卷积更改为具有相同扩张率的深度可分离卷积。

改进后的DeepLabv3+结构如图5所示,包括了MobileNetV3的多次特征提取层的结构示意图。

2.1.2 主干特征提取网络结构

MobileNetV3是由谷歌提出的一种轻量级图像分类网络[19],MobileNetV3网络以MobileNetV2和MobileNetV1这两代模型为基础,在Bneck结构模块引入了一种轻量级注意力模块(SE),并用H-Swies激活函数(hard version of Swies)代替Swish激活函数,使得网络保持较高的分类精度的同时使用更少的网络参数。

MobileNetV3有MobileNetV3-Large和MobileNetV3-Small两个版本。相较于Small版本,Large版本在检测速度上稍慢,但Large版本通过增加网络深度和通道宽度,显著增强了特征提取能力,在面对光照、阴影、地块边缘植被等干扰的导航道路检测中具有较高的准确性[20],其检测速度也足以应对小麦收获区路径检测。本研究采用MobileNetV3-Large作为DeepLabv3+的主干网络,结构详情如图6所示。

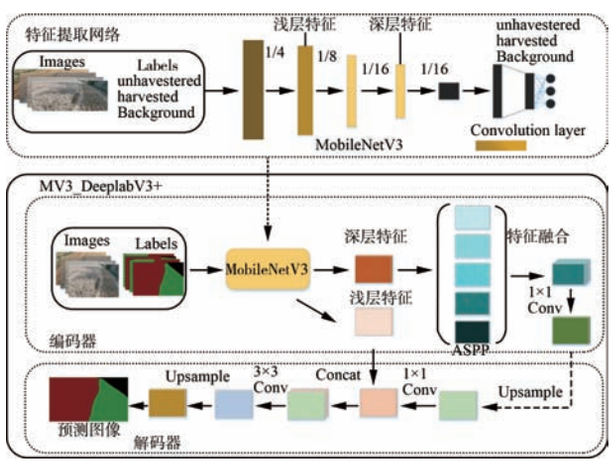


图5 MobileNetV3-DeepLabv3+结构图

Figure 5 MobileNetV3-Deeplabv3+ structure diagram

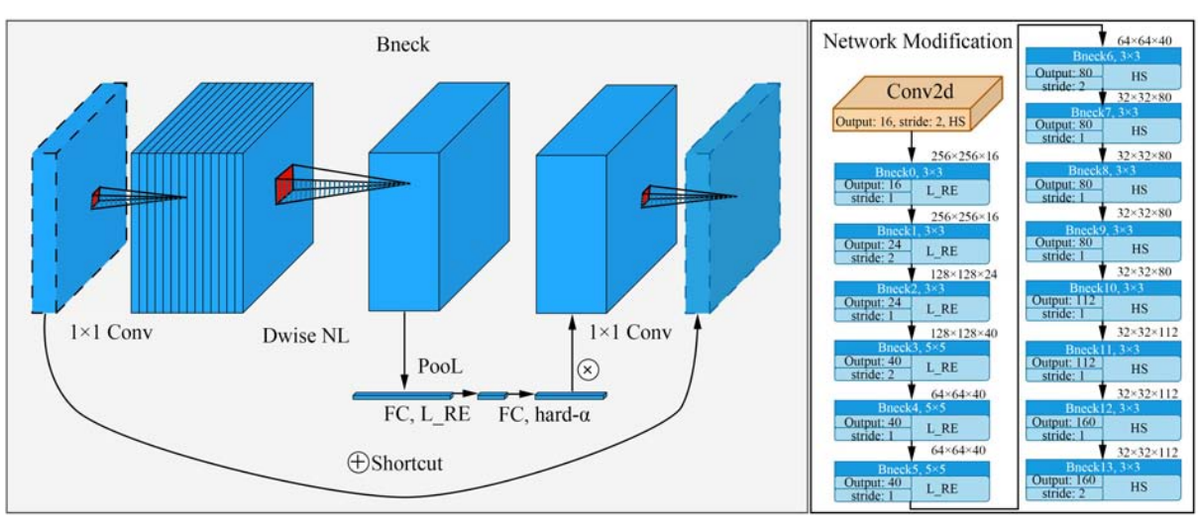


图6 改进后的MobileNetV3-Large结构图

Figure 6 The improved structure diagram of MobileNetV3-Large

2.1.3 空洞卷积

经过MobileNetV3-Large主干网络提取的深层特征,进一步交由ASPP模块进行多尺度信息的提取与融合。

该模块由5个结构构成,具体包括:1个1×1尺寸的卷积层、3个具有不同扩张率的空洞卷积层,以及1个平均池化层。

为了控制模型的计算复杂度,本研究将原本3个不同扩张率的空洞卷积更改为具有相同扩张率的3×3深度可分离卷积,如图7所示。

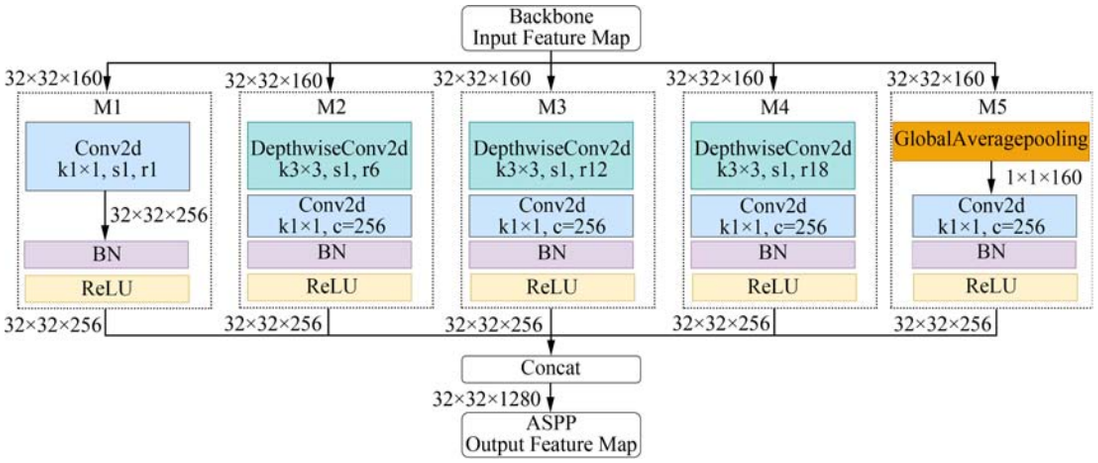


图 7　ASPP 结构图

Figure 7　ASPP structure diagram

2.2　模型训练与测试

2.2.1　试验平台

试验平台硬件参数：AMD Ryzen 7 5800H CPU（3.4 GHz），16 GB 内存，Nvidia GeForce RTX 3060 GPU。软件环境为 Windows 10，采用 Python 3.7 和 PyTorch 1.7.1 进行试验。

2.2.2　迁移学习

在深度学习应用场景中，模型的性能优化通常面临两个关键挑战：第一，训练样本数量不足容易引发网络泛化能力下降，表现为训练误差与测试误差之间的显著差异；第二，参数更新过程中的梯度优化效率低下，导致模型需要更长的迭代周期才能达到稳定状态。由于现实条件下获取大规模标注数据的成本较高，尤其在农业场景中。

本研究数据集有限，采用迁移学习策略，以高质量、大规模相似任务预训练模型为起点，通过冻结与微调特征提取网络，结合少量自有数据训练，提升模型性能。

2.2.3　模型评价指标

本文采用模型推理速度（*FPS*）、平均交并比（*MIoU*）和平均像素准确率（*MPA*）评估网络模型。计算公式为：

$$MIoU=\frac{1}{k+1}\sum_{i=0}^{k}\frac{p_{ii}}{\sum_{j=0}^{k}p_{ij}+\sum_{j=0}^{k}p_{ji}-p_{ii}}\times 100\% \tag{1}$$

$$MPA=\frac{1}{k+1}\sum_{i=0}^{k}\frac{p_{ii}}{\sum_{j=0}^{k}p_{ij}}\times 100\% \tag{2}$$

式中：k——目标类别数量；

p_{ii}——预测正确的样本个数；

p_{ij}——预测错误的样本个数。

$$FPS=\frac{N}{T} \tag{3}$$

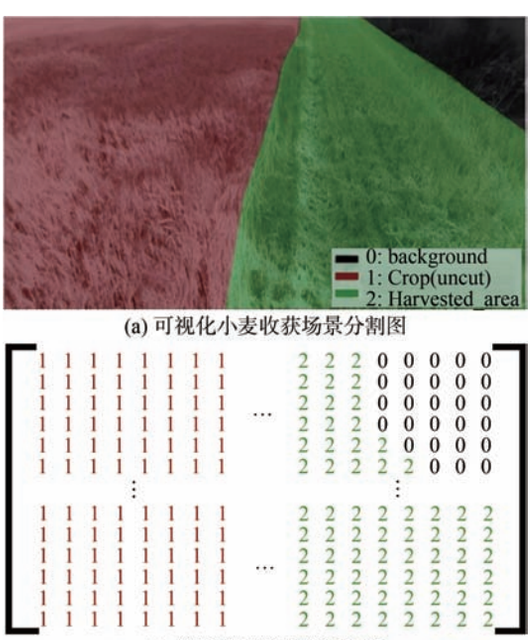
式中：N——处理图像的帧数；

T——消耗的时间。

2.3　导航路径识别

2.3.1　路径关键点提取

根据已收获小麦、待收获小麦、背景 3 种类别制作小麦收获场景标签。图 8(a)展示了融合原图与分割图的场景，直观展示了分类效果（红：待收获，绿：已收获，黑：背景），图 8(b)为单通道数字掩码矩阵，像素值 0、1、2 分别代表背景、待收获小麦、已收获小麦。



(a) 可视化小麦收获场景分割图

(b) 单通道的像素掩码矩阵

图 8　像素掩码示意图

Figure 8　Pixel mask schematic diagram

鉴于把所有的边界信息点都提取耗资较大，为了提高导航路径识别的效率，本研究提出仅提取具有特征信息的关键点，并通过插值方法拟合导航路径，设定(x_i, y_i)为拟合关键点，如图9所示。

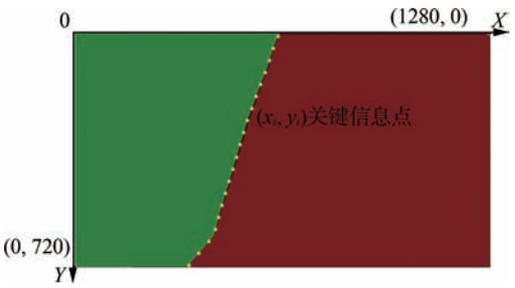


图9 像素坐标示意图

Figure 9 Pixel coordinate diagram

首先设定导航起始点，沿着分割图X轴水平扫描，将未收获区域和已收获区域的交汇处设定为关键点，流程如图10所示。

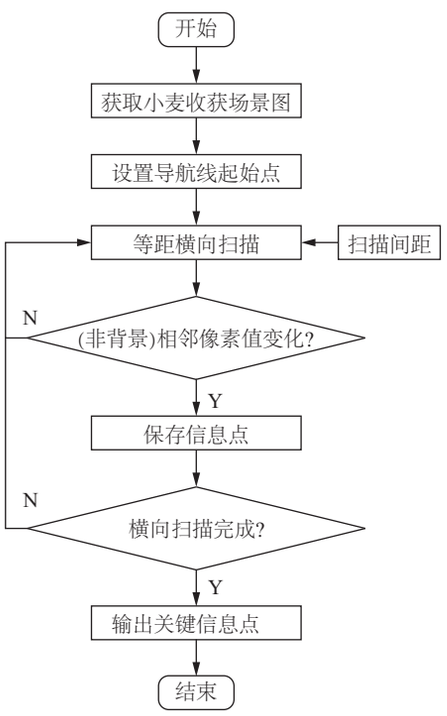


图10 水平扫描法提取关键点

Figure 10 Extracting key points using the horizontal scanning method

本研究每间隔l行扫描1行，若在该行中像素值由1变2或由2变1，将记录1个关键点，则关键信息点数量

$$m=\frac{n}{l} \tag{4}$$

式中：n——图像行数；

l——间隔行数。

2.3.2 基于B样条曲线的导航路径拟合算法

将提取的路径关键点设为B样条节点，采用多段三次B样条完成导航路径的拟合。路径的拟合需要$n+1$个控制顶点$P_i(i=0, 1, 2, \cdots, n)$，每选取4个相邻控制顶点，就能生成一条样条曲线，第i段的三次B样条曲线表达式为：

$$P(u)=\sum_{i=0}^{n}P_iB_{i,4}(u),u\in(0,1) \tag{5}$$

$$\begin{cases}B_{i,1}(u)=\begin{cases}1 & u_i<u<u_{i+1}\\0 & \text{Otherwise}\end{cases}\\B_{i,4}(u)=\dfrac{u-u_i}{u_{i+3}-u_i}B_{i,3}(u)+\dfrac{u_{i+4}-u}{u_{i+4}-u_{i+1}}B_{i+1,3}(u)\end{cases} \tag{6}$$

式中：u——曲线参数；

$B_{i,4}(u)$——基函数。

将B样条基函数代入，可以得到：

$$\begin{cases}B_{1,4}(u)=\dfrac{-u^3-3u^2-3u+1}{6}\\B_{2,4}(u)=\dfrac{-3u^3-6u^2+4}{6}\\B_{3,4}(u)=\dfrac{-3u^3-3u^2+3u+1}{6}\\B_{4,4}(u)=\dfrac{u^3}{6}\end{cases} \tag{7}$$

第i段三次B样条曲线对应的矩阵形式：

$$\boldsymbol{p}_{i,4}(u)=\frac{1}{6}\begin{bmatrix}u^3 & u^2 & u & 1\end{bmatrix}\begin{bmatrix}-1 & 3 & -3 & 1\\3 & -6 & 3 & 0\\-3 & 0 & 3 & 0\\1 & 4 & 1 & 0\end{bmatrix}\begin{bmatrix}P_{i-1}\\P_i\\P_{i+1}\\P_{i+2}\end{bmatrix} \tag{8}$$

由于图像高为720像素，本研究选择设定扫描间距为37行($l=37$)间隔，共获得20($m=20$)个关键拟合点，并利用获取的关键信息点拟合导航路径，如图11所示。

2.3.3 路径识别测试方法

以人工标注路径为真实值，在纵坐标上等距离均匀选取10点，对比多段B样条拟合的导航路径与实际路径的横坐标得到像素误差

$$e_p=abs(U_d-U_a) \tag{9}$$

式中：U_d——拟合路径横坐标；

U_a——真实路径横坐标；

$abs()$——绝对值。

将得到的像素误差与图像横向像素总数比较得到相对误差

$$e_r=\frac{e_p}{W}\times 100\% \tag{10}$$

式中：W——图像横向像素总数。

为了将像素误差转换成实际距离误差 e_d，需利用相机模型将拟合和实际的路径检测点转换至相机坐标系，通过欧式距离计算实际导航误差。相机标定获取内参矩阵与畸变系数，深度信息则基于立体视觉测距原理。误差率控制在1%之内。坐标转换公式为：

$$\begin{cases} x_{corrected}=x\left(1+k_1r^2+k_2r^4\right)+2p_1xy \\ \qquad\qquad +p_2\left(r^2+2x^2\right) \\ y_{corrected}=y\left(1+k_1r^2+k_2r^4\right)+2p_2xy \\ \qquad\qquad +p_1\left(r^2+2y^2\right) \end{cases} \tag{11}$$

$$\begin{cases} u=f_x x_{corrected}+c_x \\ v=f_y y_{corrected}+c_y \end{cases} \tag{12}$$

$$\begin{cases} x=\dfrac{bx_l}{x_l-x_r} \\ y=\dfrac{bx_l}{x_l-x_r} \\ z=\dfrac{bf}{x_l-x_r} \end{cases} \tag{13}$$

$$e_d=\sqrt{\left(x_a-x_b\right)^2+\left(y_a-y_b\right)^2+\left(z_a-z_b\right)^2} \tag{14}$$

式中：$(x_{corrected},y_{corrected})$——校正后坐标；

(u,v)——像素平面坐标；

(x,y,z)——相机坐标系；

(x_a,y_a,z_a)——真实路径中的检测点坐标；

(x_b,y_b,z_b)——预测路径中的检测点坐标；

f——相机焦距；

b——相机基线。

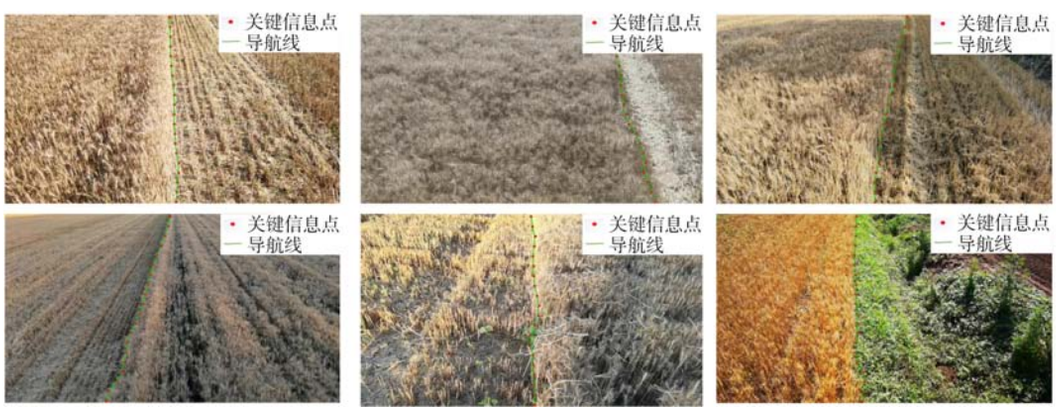


图 11　路径拟合效果图

Figure 11　Path fitting effect diagram

3　试验结果与分析

3.1　模型性能对比

选择 DeepLabv3+、UNet、PSPNet 为基础语义分割网络模型，使用 MobileNetV2 进行轻量化设计。损失值曲线图如图 12 所示。

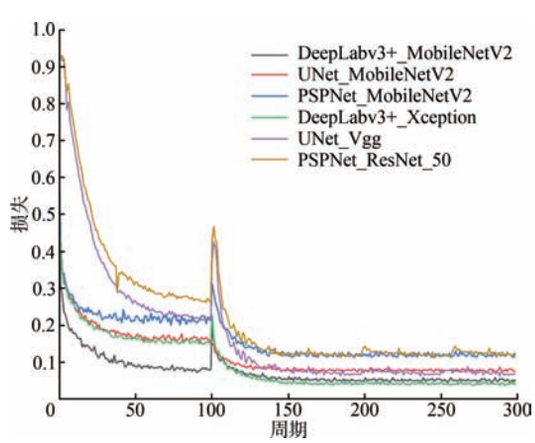


图 12　损失函数曲线图

Figure 12　Loss function graph

从图 12 中可以看出前 100 周期采用冻结训练，损失值快速下降后收敛。100 周期后进行解冻训练，加入特征提取网络，损失值持续下降并最终收敛。相较于 UNet 和 PSPNet，DeepLabv3+损失值最小，说明该模型预测值与真实值误差最小，该模型与小麦收获区域分割任务匹配度较高。

表 1 中 DeepLabv3+网络中使用 Xception 特征提取网络的 *MIoU* 为 96.5%，未收获区域分割交并比（Crop *IoU*）为 96.9%，*MPA* 为 96.2%，未收获区域的像素分割准确率（Crop *PA*）为 98.0%，4 项指标均在 3 种模型组合的 6 种网络中为最高，综合分割速度和分割效果，DeepLabv3+表现最好。PSPNet_MobileNetV2 具备最快的分割速度，达到 7.5 帧/s，但其分割精度最低。DeepLabv3+_MobileNetV2 的分割速度为 6.2 帧/s，且在分割精度方面表现更优，与 Xception 网络相比，DeepLabv3+_MobileNetV2 的推理速度提升约 1.6 倍。综合精度与速度指标，DeepLabv3+_MobileNetV2 在各模型中表现出较好的分割效果。

表 1 模型评估指标

Table 1 Model evaluation metrics

模型	特征提取网络	Crop *IoU*/%	*MPA*/%	*MIoU*/%	Crop *PA*/%	*FPS*/(帧·s^{-1})
U-Net	Vgg	93.66	93.66	91.30	97.42	2.9
	MobileNetV2	94.55	94.55	89.86	96.51	5.5
PSPNet	ResNet_50	90.90	92.64	78.85	92.86	5.8
	MobileNetV2	88.24	85.98	79.30	96.90	7.5
DeepLabv3+	Xception	96.90	96.20	96.5	98.00	3.8
	MobileNetV2	94.82	92.50	92.7	97.69	6.2

3.2 特征提取网络优化

尽管基于MobileNetV2的DeepLabv3+轻量化效果表现较好,但其在车载平台难以同时兼顾导航路径识别对精度和实时性的双重需求。改用MobileNetV3作为模型特征提取网络。

如图13所示,前50个周期冻结特征提取网络,损失值降至0.5后收敛。后250周期解冻该特征网络,损失值显著下降,并在150周期后曲线逐渐趋于稳定。MobileNetV3-Large损失函数曲线最终稳定值比MobileNetV3-Small损失函数曲线稳定值小,在一定程度上也表明该网络与小麦收获区分割任务匹配度较高。

如图14所示,选用MobileNetV2和轻量化的MobileNetV3-Small作为对照模型,并在6种典型小麦收获场景中进行模型性能验证。基于MobileNetV3-Large的DeepLabv3+模型在弱光及阴影场景中表现优异,但在强光和逆光条件下边缘区域、顺光条件下已收获—未收获区域交界处以及地块边缘处存在轻微分割错误。MobileNetV2在顺光场景中的已收获区域表现较好。MobileNetV3-Small因网络层数和参数较少,特征提取能力受限,其在本数据集上的分割性能显著低于MobileNetV3-Large。

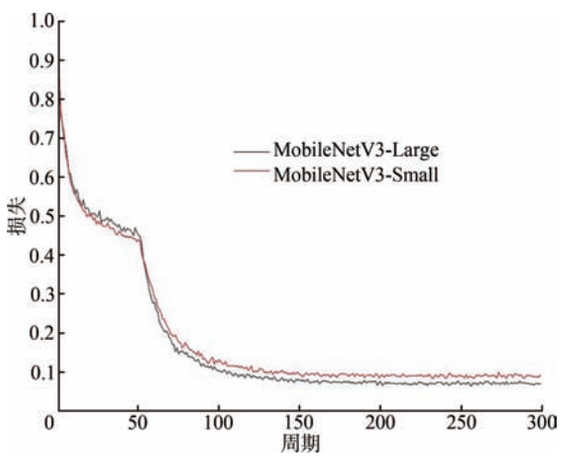


图 13 改进后的DeepLabv3+损失函数曲线图

Figure 13 The loss function curve graph of the improved DeepLabv3+

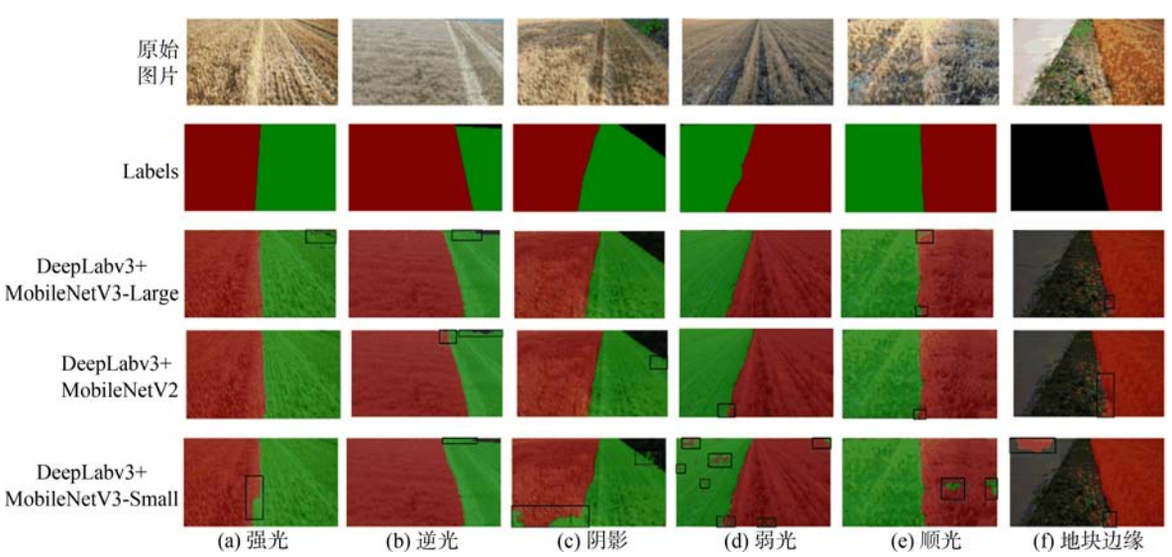


图 14 基于DeepLabv3+模型分割效果对比图

Figure 14 Comparison chart of segmentation effects based on the DeepLabv3+ model

模型评估结果如表2所示。特征提取网络为MobileNetV3-Large的Crop *IoU*和*MPA*分别为95.20%和93.45%均优于MobileNetV2,Crop *PA*为98.04%,在4种模型中表现最好。特征提取网络为

MobileNetV3-Small 的 *FPS* 为 8.3 帧/s，但分割精度较差。MobileNetV3-Large 的 *FPS* 为 7.5 帧/s，高于 Xception 的 3.8 帧/s 和 MobileNetV2 的 6.2 帧/s，对应单帧图像路径识别时间约为 0.15 s。

表 2　分割精度评估指标

Table 2　Segmentation accuracy evaluation index

模型	特征提取网络	Crop *IoU*/%	*MPA*/%	*MIoU*/%	Crop *PA*/%	*FPS*/(帧·s^{-1})
DeepLabv3+	MobileNetV3-Large	95.20	93.45	89.31	98.04	7.5
	Xception	96.90	96.20	96.5	98.0	3.8
	MobileNetV2	94.82	92.50	92.70	97.69	6.2
	MobileNetV3-Small	91.86	93.68	83.87	94.66	8.3

3.3　路径识别精度检测

在 6 种经典小麦收获区域场景中进行路径识别试验，如图 15 所示。

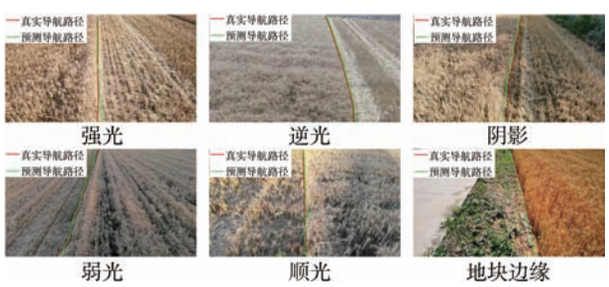


图 15　真实导航路径与预测导航路径对比图

Figure 15　Comparison chart of actual navigation path and predicted navigation path

表 3　像素误差检测结果

Table 3　Pixel error detection results　　Pixel

路径检测点	地块边缘	顺光	强光	弱光	逆光	阴影
1	−2	0	5	5	6	8
2	−4	−1	8	11	16	10
3	−4	−4	7	16	−8	1
4	5	2	9	10	15	0
5	6	7	6	4	17	−4
6	1	7	5	−1	8	−12
7	3	11	3	−9	13	−13
8	−5	−6	5	6	12	−8
9	−6	−3	−4	2	7	−11
10	−9	−9	−7	18	15	−16
平均像素误差	4.5	5	6.5	8.2	11.7	8.3
平均相对误差/%	0.35	0.39	0.51	0.64	0.91	0.65

注：“−”符号表示偏左，不带符号表示偏右，下同。

沿路径纵坐标均匀选取 10 个点，对比与真实路径的像素偏差。导航路径像素偏差的检测结果如表 3 所示，在地块边缘环境下平均像素误差和平均相对误差为 4.5 像素和 0.35%，顺光环境下为 5 像素和 0.39%，强光条件下为 6.5 像素和 0.51%，弱光条件下为 8.2 像素和 0.64%，逆光条件下为 11.7 像素和 0.91%，阴影条件下为 8.3 像素和 0.65%。

不同光照条件下距离误差测试如表 4 所示，强光为 33 mm，逆光为 62.8 mm，顺光为 14.9 mm，弱光为 50.5 mm，阴影为 38.8 mm，地块边缘条件下距离误差为 19.9 mm。不同环境下的平均距离误差为 37 mm。

表 4　距离误差检测结果

Table 4　Distance error detection result　　mm

路径检测点	地块边缘	顺光	强光	弱光	逆光	阴影
1	−24	0	59	68	74	102
2	−44	−9	80	132	184	118
3	−28	−26	48	136	−64	8
4	31	11	54	70	101	0
5	29	29	27	22	87	−21
6	3	21	16	−4	26	−42
7	7	25	16	−24	33	−34
8	−10	−11	9	13	23	−16
9	−10	−5	−10	4	12	−20
10	−13	−12	−11	32	24	−27
平均距离误差	19.9	14.9	33	50.5	62.8	38.8

预测的导航路径与真实的导航路径基本重合度较高，基于三次 B 样条采样拟合生成的导航路径能够有效减少不规则边缘对路径识别的干扰，但在阴影边界区域拟合的导航路径出现轻微整体性偏移。

4　结论

本研究根据小麦收获机路径自动导航问题，在兼顾实时性和准确性的基础上对 DeepLabv3+模型进行

轻量化改进。根据模型分割得到的像素掩码图提取关键点信息,再基于多端三次B样条算法拟合关键点生成导航路径。结论如下:

1)首先对U-Net、PSPNet、DeepLabv3+ 3种网络模型进行轻量化改进,得到基于MobileNetV2改进的DeepLabv3+取得了较好的效果,该模型在不同光照条件下试验得到 *MIoU* 为 92.7%,*MPA* 为 92.5%,Crop *IoU* 为94.82%,Crop *PA* 为97.69%,视频图像处理帧率 *FPS* 为6.2帧/s。

2)后续对DeepLabv3+网络进行进一步优化,采用MobileNetV3-Large作为特征提取网络,得到模型的 *MIoU* 为 89.31%,*MPA* 为 93.45%,Crop *IoU* 为95.20%,Crop *PA* 为98.04%,视频图像处理帧率 *FPS* 为7.5帧/s。

3)根据模型分割的小麦收获区图像,通过水平扫描法和多段B样条算法提取关键信息点并生成导航路径。在不同光照条件下最大像素误差为11.7像素,平均像素误差为7.4像素。最大距离误差为62.8 mm,平均距离误差为37 mm。

参 考 文 献

[1] 莫冬炎,杨尘宇,黄沛琛,等. 基于环境感知的果园机器人自主导航技术研究进展[J]. 机电工程技术,2021,50(9):145-150.
MO Dongyan, YANG Chenyu, HUANG Peichen, et al. Research progress on autonomous navigation technology of orchard robots based on environmental perception [J]. Mechanical & Electrical Engineering Technology, 2021, 50(9): 145-150.

[2] 张智刚,殷珍,吴潇,等. 农业机械自动导航技术研究进展[J]. 农业工程学报,2025,41(23):1-13.
ZHANG Zhigang, YIN Zhen, WU Xiao, et al. Research progress of automatic navigation technology for agricultural machinery [J]. Transactions of the Chinese Society of Agricultural Engineering, 2025, 41(23): 1-13.

[3] GAO X Y, LI J H, FAN L F, et al. Review of wheeled mobile robots' navigation problems and application prospects in agriculture [J]. IEEE Access, 2018, 6: 49248-49268.

[4] LI Y, IBANEZ-GUZMAN J. LiDAR for autonomous driving: The principles, challenges, and trends for automotive LiDAR and perception systems [J]. IEEE Signal Processing Magazine, 2020, 37(4): 50-61.

[5] 李晨阳,彭程,张振乾,等. 融合里程计信息的农业机器人定位与地图构建方法[J]. 农业工程学报,2021,37(21):16-23.
LI Chenyang, PENG Cheng, ZHANG Zhenqian, et al. Positioning and map construction for agricultural robots integrating odometer information [J]. Transactions of the Chinese Society of Agricultural Engineering, 2021, 37(21): 16-23.

[6] 魏新华,张敏,刘青山,等. 基于双目视觉的田间作物高度和收割边界信息提取[J]. 农业机械学报,2022,53(3):225-233.
WEI Xinhua, ZHANG Min, LIU Qingshan, et al. Extraction of crop field height and cut-edge information based on binocular vision [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(3): 225-233.

[7] 牛润新,张向阳,王杰,等. 基于激光雷达的农业机器人果园树干检测算法[J]. 农业机械学报,2020,51(11):21-27.
NIU Runxin, ZHANG Xiangyang, WANG Jie, et al. Orchard trunk detection algorithm for agricultural robot based on LiDAR [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(11): 21-27.

[8] 杨振宇,纪超,黄绍伟,等. 温室智能黄瓜收获机设计与试验[J]. 农机化研究,2014,36(6):76-81.
YANG Zhenyu, JI Chao, HUANG Shaowei, et al. Design and experiment of intelligent cucumber harvester in greenhouse [J]. Journal of Agricultural Mechanization Research, 2014, 36(6): 76-81.

[9] 李云伍,徐俊杰,王铭枫,等. 丘陵山区田间道路自主行驶转运车及其视觉导航系统研制[J]. 农业工程学报,2019,35(1):52-61.
LI Yunwu, XU Junjie, WANG Mingfeng, et al. Development of autonomous transport vehicle and its visual navigation system for field roads in hilly and mountainous areas [J]. Transactions of the Chinese Society of Agricultural Engineering, 2019, 35(1): 52-61.

[10] LIN Y K, CHEN S F. Development of navigation system for tea field machine using semantic segmentation [J]. IFAC-PapersOnLine, 2019, 52(30): 108-113.

[11] ALTUN M, TURKER M. Integration of convolutional neural networks with parcel-based image analysis for crop type mapping from time-series images [J]. Earth Science Informatics, 2025, 18: 303-331.

[12] KAMILARIS A, PRENAFETA-BOLDÚ F X. A review of the use of convolutional neural networks in agriculture [J]. The Journal of Agricultural Science, 2018, 156(3): 312-322.

[13] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 40(4): 834-848.

[14] 韩振浩,李佳,苑严伟,等. 基于U-Net网络的果园视觉

导航路径识别方法[J]. 农业机械学报，2021，52(1)：30－39.
HAN Zhenhao，LI Jia，YUAN Yanwei，et al. Vision navigation path recognition method for orchard based on U-Net network [J]. Transactions of the Chinese Society for Agricultural Machinery，2021，52(1)：30－39.

[15] 孟庆宽，杨晓霞，张漫，等. 基于语义分割的非结构化田间道路场景识别[J]. 农业工程学报，2021，37(22)：152－160.
MENG Qingkuan，YANG Xiaoxia，ZHANG Man，et al. Unstructured field road scene recognition based on semantic segmentation [J]. Transactions of the Chinese Society of Agricultural Engineering，2021，37(22)：152－160.

[16] 吴伟斌，唐婷，刘强，等. 基于语义分割的山地果茶园道路识别技术研究[J]. 华中农业大学学报，2022，41(1)：246－254.
WU Weibin，TANG Ting，LIU Qiang，et al. Research on road recognition technology of mountainous fruit and tea gardens based on semantic segmentation [J]. Journal of Huazhong Agricultural University，2022，41 (1)：246－254.

[17] LI Y，IIDA M，SUYAMA T，et al. Implementation of deep-learning algorithm for obstacle detection and collision avoidance for robotic harvester [J]. Computers and Electronics in Agriculture，2020，174：105499.

[18] 侯文慧，周传起，程炎，等. 基于轻量化U-Net网络的果园垄间路径识别方法[J]. 农业机械学报，2024，55(2)：16－27.
HOU Wenhui，ZHOU Chuanqi，CHENG Yan，et al. Orchard inter-row path recognition method based on lightweight U-Net network [J]. Transactions of the Chinese Society for Agricultural Machinery，2024，55(2)：16－27.

[19] 张宇，李相廷，孙雅琳，等. 基于边缘计算和改进MobileNet v3 的奶牛反刍行为实时监测方法[J]. 智慧农业(中英文)，2024，6(4)：29－41.
ZHANG Yu，LI Xiangting，SUN Yalin，et al. Real-time monitoring method for cow rumination behavior based on edge computing and improved MobileNet v3 [J]. Smart Agriculture，2024，6(4)：29－41.

[20] 张隆梅，刘岗微，齐彦栋，等. 农业机械无人驾驶系统关键技术研究进展[J]. 智能化农业装备学报(中英文)，2022，3(1)：27－36.
ZHANG Longmei，LIU Gangwei，QI Yandong，et al. Research progress on key technologies of agricultural machinery unmanned driving system [J]. Journal of Intelligent Agricultural Mechanization，2022，3 (1)：27－36.

Research on navigation path recognition method for wheat combine harvester

LI Jianian，WU Kunshu，LI Kunyi，CHEN Shaomin*

(*Faculty of Modern Agricultural Engineering*，*Kunming University of Science and Technology*，*Kunming* 650500，*China*)

Abstract: To address the challenges in balancing accuracy and real-time performance for navigation path recognition methods of wheat harvesters，this study introduces a lightweight design based on the DeepLabv3+ model. Specifically，the original backbone network is replaced with MobileNetV3-Large，and the ReLU activation function is substituted with Leaky_ReLU. To further reduce computational load，the three dilated convolutions with different dilation rates within the atrous spatial pyramid pooling (ASPP) module are replaced with depthwise separable convolution (DSC) employing identical dilation rates. To ensure the generalizability of the wheat harvester navigation path recognition research，images of wheat harvest areas were captured under six typical environmental conditions：strong light，low light，back lighting，front lighting，shadows，and field edges. The road information within the collected images was annotated by the Labelme tool，thereby constructing a wheat harvest region data set. In the path extraction stage，key points were acquired from the segmentation mask maps using the horizontal scanning method，and the navigation path was fitted utilizing a piece wise cubic B-spline algorithm. Experimental results demonstrate that the improved DeepLabv3+ model achieved a segmentation accuracy of 98.04% and intersection over union (*IoU*) ratio of 95.20%，respectively，with a video image processing frame rate of 7.5 frames per second . The average pixel error and average distance error for navigation path recognition were 7.4 pixels and 37

mm, respectively. The wheat harvester operated at a travel speed of approximately 1.5 m/s, and the path recognition time per single frame was only 0.15 seconds. This performance effectively meets the real-time and accuracy requirements for wheat harvester operation. This research provides a theoretical foundation and technical support for enhancing the autonomous navigation capabilities of wheat harvesters.

Keywords: DeepLabv3+; semantic segmentation; navigation path; wheat harvester; path recognition; transfer learning

Foundation items: Yunnan Revitalization Talent Support Program(KKRD202223052); National Natural Science Foundation of China(52069008)

First Author: LI Jianian, E-mail: ljn825@163.com

* **Correspondence Author:** CHEN Shaomin, E-mail: shaomin_ly24@126.com