doi:10.6041/j.issn.1000-1298.2026.03.008

基于无人机遥感与作物分布感知的撂荒地种植推荐策略

刘淑俊[1,2]　郭佳希[2,3]

(1.河北农业大学理学院,保定 071001;2.河北省农业大数据重点实验室,保定 071001;
3.河北农业大学信息科学与技术学院,保定 071001)

摘要:近年来,受农田监测与管理手段滞后影响,部分农村地区撂荒现象频发,引发耕地资源利用率下降和粮食产能受限等问题。针对上述问题,提出一种融合作物监测与空间分布感知的撂荒地种植推荐策略。该策略以无人机航拍获取的复杂背景农田遥感影像为研究对象;在 DeepLabv3 + 模型基础上,使用轻量级 MobileNetv4 作为主干特征提取网络,以压缩模型参数量并降低计算复杂度;同时,在解码阶段引入自适应细粒度通道注意力机制,以增强作物轮廓边缘与纹理细节的特征感知;采用风车卷积替换传统 3×3 卷积,提升模型在无人机俯视视角下农田地块的小尺寸特征提取能力;此外,构建 FocalDiceLoss 复合损失函数,缓解类别不平衡及相似类别间难区分的负面影响。最后,结合遥感图像解析结果、地理位置及作物空间分布统计,在撂荒地邻域范围内整合周边作物信息,利用农时与邻域优势作物,对撂荒地进行种植推荐。实验结果表明,改进后的 DeepLabv3 + 模型的准确率、平均像素准确率和平均交并比分别为 96.64%、96.37%、92.82%,相比原模型分别提高 1.85、3.71、6.10 个百分点。该模型可为农田作物精准监测与撂荒地资源再利用提供关键技术支撑,促进农业智能化管理与可持续发展。

关键词:农田监测;无人机遥感;农作物分类;撂荒地;DeepLabv3 +

中图分类号:TP391.4　　**文献标识码**:A　　**文章编号**:1000-1298(2026)03-0077-10　　**OSID**:

Cropping Recommendation Strategy for Abandoned Farmland Based on UAV Remote Sensing and Crop Distribution Perception

LIU Shujun[1,2]　GUO Jiaxi[2,3]

(1. *College of Science*, *Hebei Agricultural University*, *Baoding* 071001, *China*
2. *Hebei Key Laboratory of Agricultural Big Data*, *Baoding* 071001, *China*
3. *College of Information Science and Technology*, *Hebei Agricultural University*, *Baoding* 071001, *China*)

Abstract: In recent years, due to the lag in farmland monitoring and management methods, abandoned land has become increasingly prevalent in some rural areas, resulting in decreased utilization efficiency of cultivated land and constraints on grain production capacity. To address this issue, a cropping recommendation strategy for abandoned farmland was proposed, which integrated crop monitoring with spatial distribution perception. The approach utilized UAV-acquired remote sensing imagery with complex farmland backgrounds as the primary research object. On the basis of the DeepLabv3 + semantic segmentation model, a lightweight MobileNetv4 network was introduced as the backbone feature extractor to reduce parameter complexity and computational cost. Additionally, an adaptive fine-grained channel attention mechanism was incorporated in the decoder to enhance the model's sensitivity to crop boundary contours and texture details. To improve the extraction of small-scale farmland features under UAV nadir perspectives, the conventional 3 × 3 convolution was replaced with windmill convolution. Furthermore, a hybrid focal-dice loss function was constructed to mitigate the effects of class imbalance and the difficulty in distinguishing between visually similar crop categories. Finally, by combining the remote sensing analysis results with geolocation data and crop spatial distribution statistics, the model aggregated surrounding crop information over a broad spatial domain and recommended suitable crops for abandoned plots based on seasonal farming schedules and regional crop dominance. Experimental results

收稿日期:2025 - 08 - 25　修回日期:2025 - 08 - 29

基金项目:河北省重点研发计划项目(22327405D)、中国高校产学研创新基金项目(2021LDA10005)和国家自然科学基金项目(U20A20180)

作者简介:刘淑俊(1968—),女,副教授,主要从事应用数学和神经网络研究,E-mail:2710848167@qq.com

demonstrated that the improved DeepLabv3 + model achieved an ACC of 96.64%, mPA of 96.37%, and MIoU of 92.82%, representing increases of 1.85, 3.71, and 6.10 percentage points, respectively, over the baseline model. This approach can provide a critical technical foundation for precision crop monitoring and abandoned land reutilization, promoting intelligent agricultural management and sustainable farmland development.

Key words: farmland monitoring; UAV remote sensing; crop classification; abandoned farmland; DeepLabv3 +

0 引言

确保国家粮食安全是做好“三农”工作的底线任务之一[1]。粮食安全作为国家发展的战略基石,事关社会稳定、经济发展与民生福祉[2-3]。在耕地资源有限的背景下,部分农村地区普遍出现单个农户撂荒甚至引发的“连带性”撂荒[4-5]现象。在粮食安全与耕地撂荒的双重压力下,如何基于现有农作物种植分布信息,实现撂荒地科学利用[6],优化闲置农田种植结构,提高粮食产能,成为智慧农业发展的核心课题之一。

传统农田监测依赖农户、技术人员或政府部门实地踏勘,记录农作物种类及撂荒地的分布情况。该方法费时费力,踏勘范围有限,仅适用于小规模种植地块,难以满足精准农业对信息高效、准确获取的需求。

随着空间探测技术的升级,无人机(UAV)遥感因其高效、低成本和广覆盖的优势,在农田监测领域得到广泛应用[7-8]。无人机通过搭载高分辨率相机,可观测大范围的农田影像。近年来,部分研究者将无人机遥感与深度学习相结合,应用于农田监测领域[9-11],并取得了较好的实验成果。文献[12]将改进后的轻量化 DeepLabv3 + 语义分割算法,用于实现无人机荞麦苗期图像的分割与识别,准确率达到了 97.02%。文献[13]基于无人机遥感图像数据,提出改进 U - Net 模型对研究区薏仁米、玉米等作物进行分类识别,整体准确率达到 88.33%。文献[14]针对卢旺达耕地小块化与作物多样化的问题,采用 VGG16 架构结合迁移学习对玉米、香蕉、豆类作物及撂荒地进行识别,其中香蕉与玉米的 F1 分数分别达到 96% 和 90%,但豆类和撂荒地的结果相对较低,F1 分数分别为 49% 和 62%。文献[15]在 U - Net 网络的基础上引入自注意力机制,有效增强模型对棉花、玉米、苗木、水稻和冬小麦等 5 种农作物及撂荒地的特征提取能力。该方法的整体分类精度为 86.4%。文献[16]将 Transformer 引入 DeepLabv3 + 模型,提出并行特征提取的 DeepTrans 网络,在 5 种农作物数据集上 MIoU 达到 81.2%,但玉米与柑橘的 IoU 均低于 80%。

基于上述研究成果,深度学习在农田监测领域已取得显著进展,但仍存在以下不足:受地区复杂性及作物种类多样性等因素影响,作物种类多时整体分类精度下降,部分类别的识别精度偏低;多数研究者对撂荒地关注不足,尽管文献[14 - 15]有所涉及,但受限于分割精度,难以实现对撂荒地的准确判别,缺乏对其后续利用的系统性考量。

针对上述问题,本文提出一种融合作物监测与分布感知的撂荒地种植推荐策略。该策略基于无人机遥感的航拍影像,采用改进后的 DeepLabv3 + 模型对农作物与撂荒地进行高精度识别与分割,实现农田地物的精细化监测。同时,结合作物空间分布特征与生长优势分析,构建撂荒地种植推荐机制,推动耕地资源再利用与科学配置。

1 实验数据

1.1 研究区域概况

农田实验地点位于河北省保定市蠡县(38°19′~38°41′N,115°27′~115°46′E),地处河北省中部,华北平原的中南部地带。该县地势总体平坦,略有起伏,以广阔的平原为主,局部地区分布有低洼地。蠡县属于典型的温带季风气候,年均气温 12.3℃,降水适中,年均降水量约为 522 mm。得益于适宜的气候条件和优越的地理环境,该县成为河北省重要的农业县之一,同时也是国家级粮食生产基地。

1.2 数据获取

实验航拍图像采集设备为大疆 DJI inspire 1 raw 型无人机。该无人机采用四轴旋翼设计,搭载了 Zenmuse X5R 型相机,支持 2.4 GHz 和 5.8 GHz 双频通信,配备 CMOS 传感器,具备高清图传和远程遥控功能,能够捕捉更多细节和色彩信息。最高可飞行至 4 500 m,飞行速度可达 22 m/s,续航时间 15 ~ 18 min,能够满足短时高质量航拍需求。

本研究航拍影像数据覆盖多个时间段,分别采集于 2023 年 5 月、6 月及 2024 年 8 月,图像分辨率为 4 000 像素 × 2 250 像素。通过不同季节和时间的影像,确保数据具有时序多样性。拍摄期间天气晴朗,地表光照条件稳定,风速较低,飞行高度设定

为 227 m，适合无人机进行航拍作业。为确保影像拼接精度，设定航向重叠度和旁向重叠度均为 70%。无人机采集影像时记录 POS 数据，将数据导入 PhotoScan 1.4.5 软件进行精准对齐与定位，确保几何一致性。随后，构建密集点云模型，利用纹理映射优化细节，生成高分辨率数字正射影像示例图，如图 1 所示。



图 1　数字正射影像示例图

Fig. 1　Example of digital orthophoto image

1.3　数据预处理与制作

鉴于原始航拍图像分辨率较高，难以直接进行语义分割模型训练与预测，采用图像裁剪策略，按比例裁剪为 512 像素 ×512 像素子图。裁剪后的农田影像在类别上存在不均衡现象，如撂荒地样本相对较少，可能导致模型对少数类别的识别能力下降。此外，为增强数据多样性，确保模型能够从现有样本数据中学习到更多的特征，引入数据增强技术对影像进行优化。通过旋转、翻转、平移、缩放等多种增强策略丰富数据分布，增强模型的泛化能力。

将数据增强后图像使用 Labelme 软件进行标注，结合无人机拍摄的多时相作物样本进行目视解译，实地采集的样本共分为 8 类地物类型，农作物类包括玉米、小麦、山药、菜地；非农作物类包括乔木、大棚、麦茬地、撂荒地，如图 2 所示。最终共得到 8 456 幅图像，按照比例 7∶2∶1将数据集划分为训练集 5 919 幅、验证集 1 691 幅和测试集 846 幅。

2　撂荒地的种植推荐

2.1　农田地物的语义分割

2.1.1　MAP－DeepLabv3＋分割模型设计

DeepLab v3＋是一种典型的语义分割模型，其核心思想在于引入编码器和解码器架构，以实现对输入图像边缘的精细化分割[17]。在编码阶段，模型首先通过主干网络提取两类关键特征：浅层特征与深层特征。浅层特征经由编码器中的 1×1 卷积操作进行通道压缩后传入解码器；深层特征则通过空洞空间金字塔池化进行多尺度特征采样，从而有效捕获上下文信息。随后，模型对深层特征进行上采样，并与浅层特征融合。最后，利用双线性插

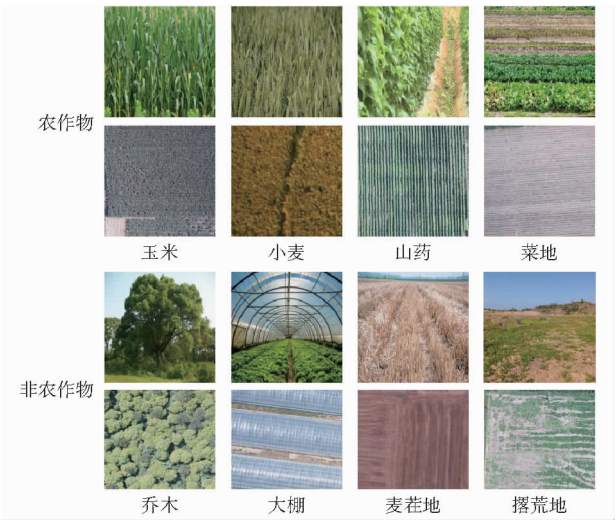

图 2　数据集地物样例

Fig. 2　Examples of land cover types in dataset

值将特征图的分辨率恢复至原始图像尺寸，输出预测结果。

本研究以 DeepLabv3＋为基础模型，选用 MobileNetv4 作为主干网络，并引入自适应细粒度通道注意力机制、风车卷积结构以及复合损失函数等多项结构优化策略，提出了一种轻量化改进的 MAP－DeepLabv3＋模型，实现对农田地物的精准分割与识别，其结构图如图 3 所示。

2.1.2　主干网络 MobileNetv4

DeepLab v3＋默认采用 Xception[18] 作为主干特征提取网络，存在网络层次深、结构复杂、参数量大等问题。在无人机等计算资源受限的平台上，过多的参数量可能导致推理时间增加，影响设备的响应速度。为提高模型在实际应用中的适应性，选用 MobileNetv4[19] 作为主干网络，以减小模型参数量与复杂度并提升推理速度。MobileNetv4 是新一代的 MobileNet 系列模型，基于 MobileNet 的经典组件深度卷积和逐点卷积扩展和投影的倒瓶颈结构，MobileNetv4 设计了一种新的结构单元——通用倒瓶颈模块 UIB（Universal inverted bottleneck），以实现模型轻量化，如图 4 所示。

相较于传统倒瓶颈结构，UIB 结构在扩展阶段引入了两个可选的深度卷积，分别位于扩展层之前，以及扩展层与投影层之间。前者用于对输入特征进行初步处理，提取浅层局部信息；后者则增强模型对深层语义特征的建模能力。基于两个可选位置的深度卷积配置，UIB 模块可实例化为 4 种结构变体：附加深度卷积变体（ExtraDW）、标准倒瓶颈结构（Inverted bottleneck，IB）、ConvNext 以及前馈网络（Feed-forward network，FFN）结构。不同的实例化方式可根据具体任务需求灵活组合，以在模型精度、计

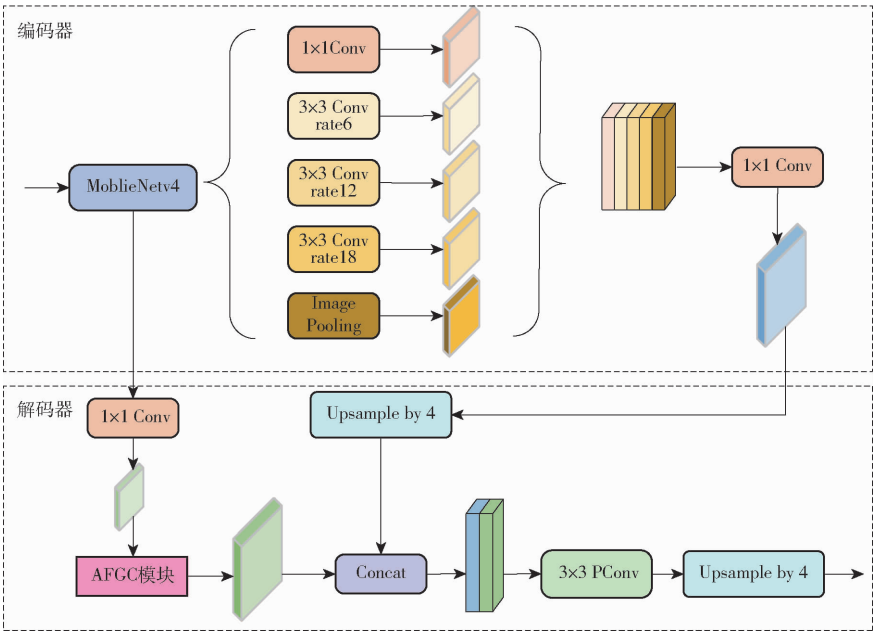

图 3 MAP－DeepLabv3＋模型结构

Fig. 3 MAP－DeepLabv3＋ model structure

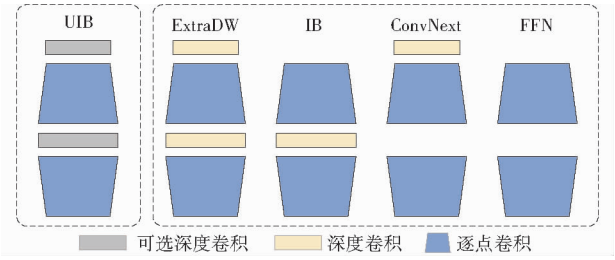

图 4 UIB 模块及结构变体

Fig. 4 UIB module and structural variants

算量与推理速度之间实现权衡。

2.1.3 自适应细粒度通道(AFGC)模块

低空作业下的无人机在农田影像采集过程中可能会受到复杂天气条件的干扰,导致图像质量下降。如阴天自然光照不足,光学传感器所采集图像的对比度偏低;有风天气下,无人机机体容易产生抖动,图像出现模糊和失真现象。DeepLabv3＋的浅层特征主要关注轮廓边缘与纹理特征,本研究在对主干网络提取的浅层高分辨率特征进行 1×1 卷积通道压缩后,引入自适应细粒度通道(Adaptive fine-grained channel, AFGC)注意力模块[20]。该模块利用相关矩阵捕获全局和局部不同粒度层面上的特征关联,促进信息交互,从而实现有效的特征权重分配,如图 5 所示。

首先,特征图 F 通过全局平均池化转换为通道描述符 U,将每个通道的空间信息压缩为单一数值,提取各通道的全局特征表示。其次,为降低模型参数量,采用带状矩阵提取局部通道信息,对角矩阵获取全局通道依赖。然后,通过交叉相关操作融合局部与全局信息,捕获其在不同粒度下的关联性,生成相关矩阵。最后,从相关矩阵及其转置中提取行向量与列向量,作为全局与局部通道信息的权重表示。引入自适应融合策略动态整合权重,并将融合后的通道权重与原始输入特征图 F 逐通道相乘,从而实

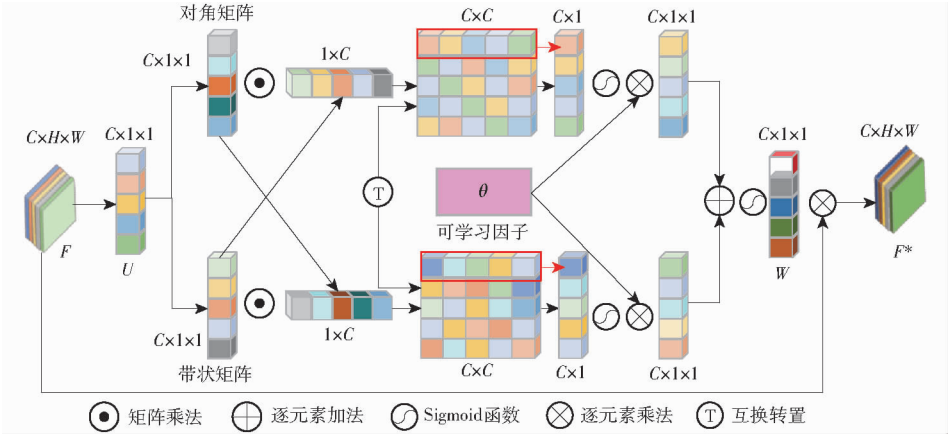

图 5 AFGC 模块结构图

Fig. 5 AFGC model structure

现特征增强，最终输出特征图 F^*。

2.1.4　风车卷积(PConv)

受地形条件与耕作方式影响，华北平原地区农田多呈块状、形态不规则分布，地块面积因作物类型与种植模式差异呈现出多尺度、非均质的空间特性。在无人机俯视视角下，单幅图像中地块通常较小，普遍表现出明显的“小尺寸”特征。传统卷积受限于固定感受野，难以有效提取小目标的关键特征信息，限制了模型在复杂农田场景下的识别性能。为此，在 DeepLabv3 + 解码器阶段引入风车卷积(Pinwheel convolution，PConv)模块[21]，替换原有的 3 × 3 标准卷积操作。PConv 模块结构如图 6 所示。

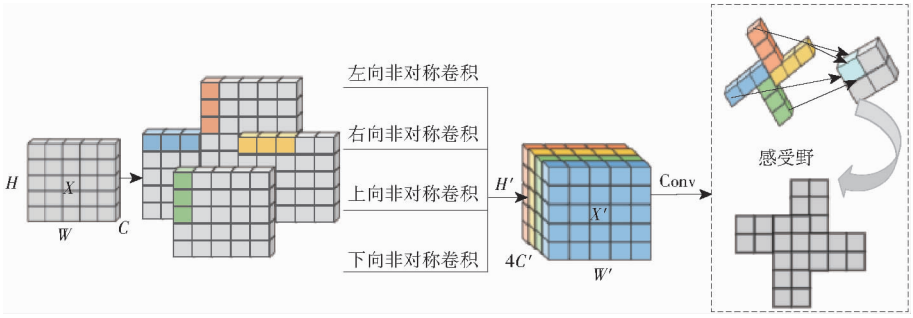

图 6　PConv 结构图

Fig. 6　PConv structure

与传统卷积不同，PConv 采用非对称填充策略来处理图像数据中的不同区域，生成具有特定方向性的水平和垂直卷积核。具体而言，输入 $H \times W \times C$ 特征图 X，在左、右、上、下 4 个方向上分别利用特定的填充参数，并行执行非对称卷积操作；每次卷积后均通过 SiLU 激活函数与批归一化操作增强非线性表达与训练稳定性。随后，将 4 个方向的卷积结果在通道维度上进行拼接，形成 $H' \times W' \times 4C'$ 融合特征图 X'，再通过卷积核对连接的张量进行归一化处理，输出特征图。PConv 构建的感受野呈现由中心向外扩散的高斯分布特性，中心特征权重更大，对于小目标具有更高的特征集中度。

2.1.5　复合损失函数(FocalDiceLoss)

样本不平衡是遥感图像地物分割中的一个难题。本研究所涉及的农田地物类别多达 8 种，其中农作物类样本较多，撂荒地样本相对较少，存在样本不平衡问题，导致模型训练过程中更倾向于预测样本数量多的地物。此外，撂荒地与麦茬地在遥感图像中外观相近，仅在地表覆盖物(荒草与麦茬)上存在细微差异，易导致模型产生混淆。

为缓解类别不平衡带来的影响，LIN 等[22]提出 FocalLoss 损失函数。该函数交叉熵损失构建，通过引入聚焦调制因子，引导模型在训练过程中更侧重于学习难分类样本的特征。针对撂荒地与麦茬地高度相似的判别难题，引入 DiceLoss 损失函数[23]。该损失函数是一种集合相似度度量函数，用以衡量预测结果与真实标签之间的相似性。

基于上述两种损失函数各自的优势，本文将 FocalLoss 与 DiceLoss 进行组合，构建复合损失函数 FocalDiceLoss，缓解类别不平衡问题并提升相似类别间的区分能力。其计算公式为

$$L_{FocalDice} = L_{Focal} + \lambda L_{Dice} \tag{1}$$

其中

$$L_{Focal} = -\alpha(1-p_t)^{\gamma}\lg p_t \tag{2}$$

$$L_{Dice} = 1 - \frac{2|X \cap Y|}{|X| + |Y|} \tag{3}$$

式中　p_t——模型预测概率

α——平衡参数，平衡正、负样本的比例，取 0.25

γ——可调节的聚焦参数，用来减少易分类样本的损失，取 2

$|X \cap Y|$——真实值与预测值的交集

$|X|$、$|Y|$——真实值、预测值的个数

λ——L_{Focal} 与 L_{Dice} 间的权重，取 0.5

2.2　撂荒地种植推荐策略

为提升耕地资源利用率，本研究面向无人机遥感下的农田监测场景，提出一种基于作物分布感知的撂荒地种植推荐策略，如图 7 所示。

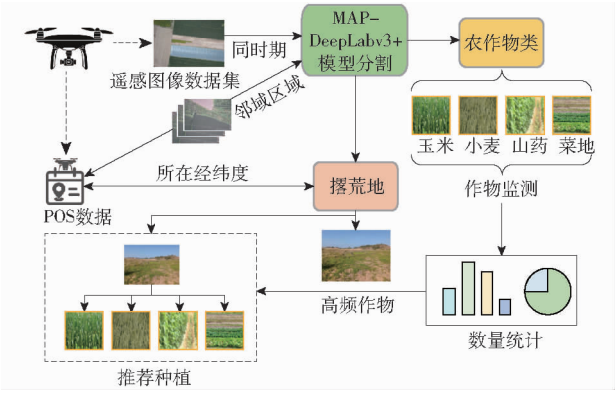

图 7　撂荒地种植推荐策略流程图

Fig. 7　Flowchart of recommended planting strategies for abandoned farmland

撂荒地种植推荐策略流程如下：

(1)首先，利用搭载 RGB 相机的无人机对目标农田区域开展低空航拍作业，结合飞行日志中的 POS(Position and orientation system)数据记录的经纬度坐标与时间戳信息，构建具备地理参考属性的遥感图像数据集。

(2)鉴于撂荒地的复耕目标主要为农作物类，对乔木、大棚等非农作物类不纳入推荐分析范围。采用改进的 MAP－DeepLabv3＋语义分割模型对图像序列进行逐帧处理，实现玉米、小麦、山药、菜地及撂荒地的高精度识别与分割。

(3)针对模型识别出的撂荒地像元，读取对应图像在本地 POS 日志中的经纬度坐标，以此为中心构建半径 200 m 的邻域区域(对应经纬度范围约为纬度 ±0.001 80°，经度 ±0.002 30°)，检索该空间范围内的所有航拍图像，构建邻域图像集。随后，利用 MAP－DeepLabv3＋模型对邻域图像进行逐帧分割。

(4)基于邻域图像集的分割结果，统计各类农作物的像素数及出现频次。结合当前农时与季节性播种规律，优选具备区域适应性的优势作物进行推荐，以实现“因地制宜、以邻为鉴”的撂荒地复耕策略，推动耕地结构优化与粮食产能提升。优势作物推荐公式为

$$C_{adv}=\underset{c_i\in C}{\operatorname{argmax}}\{\kappa N(c_i)+\beta F(c_i)\} \tag{4}$$

式中 C——邻域图像集中出现的作物类别集合

C_{adv}——优势作物类别

$N(c_i)$——第 i 类作物像素数占总像素数比例

$F(c_i)$——第 i 类作物出现频次占总频次比例

κ、β——权重系数，κ 取 0.7，β 取 0.3

3 结果与分析

3.1 实验环境配置及参数设置

实验环境配置如下：操作系统为 Windows 10，处理器为 AMD Ryzen R5－7500F，内存容量为 64 GB，显卡为 NVIDIA GeForce RTX 3090。实验采用 Python 3.8 与 PyTorch 2.2.2 深度学习框架进行实现。所有对比算法均在相同环境下运行，模型输入图像尺寸为 512 像素×512 像素，训练批次为 8，初始学习率为 0.000 1，优化器采用自适应梯度算法 Adam。模型迭代周期为 100 代，在确保训练过程收敛的前提上，对数据集进行性能评估。

3.2 评价指标

采用准确率(Accuracy)、平均像素准确率(Mean pixel accuracy，MPA)、交并比(Intersection over union，IoU)及平均交并比(Mean intersection over union，MIoU)作为语义分割模型的性能评估指标，以衡量模型在像素级分类任务中的表现。同时，采用参数量(Parameters)与浮点运算次数(Floating point operations，FLOPs)评估模型的计算复杂度，并结合帧速率(Frames per second，FPS)指标评估模型的实时推理能力，以验证其在实际应用场景中的可行性。

3.3 模型分割结果

3.3.1 损失函数对比

损失函数在模型训练与优化中具有关键作用，其损失值越小，通常表明模型具有更强的泛化性与鲁棒性。本文基于交叉熵损失(CELoss)、焦点损失(FocalLoss)和 Dice 损失(DiceLoss)，构建 6 组损失函数组合，采用平均交并比(MIoU)指标评估不同损失函数在模型性能上的表现。实验结果与训练过程变化曲线见表 1 与图 8。

表 1 不同损失模型性能对比

Tab.1 Performance comparison of different loss models %

CELoss	FocalLoss	DiceLoss	MIoU
√			86.72
	√		87.49
		√	87.54
√	√		87.97
√		√	87.85
	√	√	88.02

注：√表示使用该模块，下同。

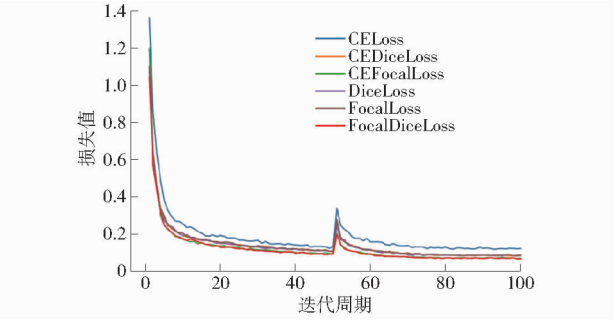

图 8 训练过程曲线

Fig.8 Training process curves

从表 1 可见，单独引入 FocalLoss 或 DiceLoss 均能在一定程度上提升模型的分割效果，MIoU 分别提高至 87.49% 和 87.54%，说明前者有效缓解类别不平衡，后者利于处理类别间特征相似性。将两者组合的复合损失函数 FocalDiceLoss 在性能上表现最优，MIoU 提升至 88.02%，相比模型默认 CELoss 提升了 1.3 个百分点。由图 8 可见，在采用 FocalDiceLoss 的训练过程中，模型在早期迭代阶段收敛速度更快，损失值在第 80 轮迭代时降至最低，

随后逐渐趋于平稳，未出现过拟合或欠拟合现象。

3.3.2　消融实验

为全面评估各优化策略在模型性能提升中的贡献，针对主干网络 MobileNetv4、AFGC 模块、PConv 以及复合损失函数 FocalDiceLoss，设计多组消融实验，从精度、参数量、计算复杂度与推理速度等多个维度对改进后的 MAP－DeepLabv3＋模型进行综合评价。

由表 2 可知，将原模型主干 Xception 替换为轻量化网络的 MobileNetv4 后，模型准确率、平均像素准确率和平均交并比分别提升至 95.42%、94.55%、89.14%；参数量和浮点运算次数分别降至原模型的 25.0%、33.5%。模型在保持较高精度的同时，显著降低了模型的参数量与计算复杂度。基于此，后续消融实验选择以 MobileNetv4 为主干特征提取网络构建基线模型，在此基础上依次引入 AFGC 模块、PConv 卷积与 FocalDiceLoss 损失等优化策略进行对比分析，实验结果表明，准确率、平均像素准确率和平均交并比均有不同程度提升。将三者综合应用于 DeepLabv3＋模型后准确率、平均像素准确率和平均交并比分别为 96.64%、96.37%、92.82%，较原模型分别提升了 1.85、3.71、6.10 个百分点。同时模型参数量和浮点运算次数分别降至 1.311×10^{7}、1.688×10^{10}，较原模型分别减少 76.04%、79.80%，帧速率达到 96.82 f/s。实验结果验证了 AFGC 模块在细粒度特征提取、PConv 在小目标识别，以及 FocalDiceLoss 在缓解类别不平衡方面的有效性。

表 2　消融实验对比结果

Tab.2　Comparative results of ablation experiments

MobileNetv4	AFGC	PConv	FocalDiceLoss	准确率/%	平均像素准确率/%	平均交并比/%	参数量	浮点运算次数	帧速率/($f\cdot s^{-1}$)
				94.79	92.66	86.72	5.471×10^{7}	8.345×10^{10}	52.99
√				95.42	94.55	89.14	1.367×10^{7}	2.798×10^{10}	70.83
√	√			95.56	95.33	90.03	1.368×10^{7}	2.230×10^{10}	81.30
√		√		95.59	95.79	90.54	1.310×10^{7}	2.110×10^{10}	88.19
√			√	95.83	96.12	91.22	1.367×10^{7}	2.798×10^{10}	70.83
√	√	√		96.35	96.24	91.86	1.311×10^{7}	1.688×10^{10}	96.82
√	√	√	√	96.64	96.37	92.82	1.311×10^{7}	1.688×10^{10}	96.82

3.3.3　不同分割模型性能比较

为进一步验证所提出 MAP－DeepLabv3＋模型在遥感影像分割任务中的性能优势，选取 FCN、PSPNet、U－Net、HRNet 及原始 DeepLabv3＋等经典语义分割模型作为基准，并在相同测试集上开展实验对比。不同模型实验结果见表 3。

表 3　不同模型实验结果

Tab.3　Different model experiment results

模型	参数量	MIoU/%	IoU/%							
			玉米	小麦	山药	菜地	乔木	大棚	麦茬地	撂荒地
FCN	3.531×10^{7}	83.44	93.77	93.75	86.29	73.47	90.50	83.18	84.35	72.18
PSPNet	4.671×10^{7}	85.61	93.94	93.10	87.94	79.47	90.76	89.53	82.69	77.44
U－Net	4.393×10^{7}	84.96	94.43	94.13	87.36	73.16	90.67	87.70	89.05	73.82
HRNet	6.585×10^{7}	86.00	95.13	95.02	89.07	75.87	91.78	88.82	87.34	74.86
DeepLabv3＋	5.471×10^{7}	86.72	95.69	93.73	92.24	83.33	92.90	91.63	75.40	81.05
MAP－DeepLabv3＋	1.311×10^{7}	92.82	97.22	95.91	92.78	89.57	94.95	95.95	93.18	89.88

对比基准模型可知，FCN、PSPNet 和 U－Net 等模型虽参数量相对较小，但其整体 MIoU 均未超过 DeepLabv3＋模型。其中菜地作物与撂荒地等类别的 IoU 均低于 80%，难以满足对地物类别分割精度的实际需求。综合分割精度与模型计算复杂度，DeepLabv3＋在保证分割精度的同时具备适中的参数量，是传统模型中的较优选择方案。基于 DeepLabv3＋改进的 MAP－DeepLabv3＋，相比原模型参数量降低了 76.04%，MIoU 提升了 6.1 个百分点。尤其对于麦茬地与撂荒地等特征相似的地物类别，其 IoU 均提升至约 90%。原因是复合损失 FocalDiceLoss 有效缓解了样本不平衡和类别间特征相似性所带来的负面影响。

不同模型的分割结果如图 9 所示。FCN、PSPNet、U－Net 及 HRNet 等模型在处理菜地、山药及麦茬地等地物时，预测结果碎片化严重，普遍存在

掩膜边缘细粒度缺失、形状不连贯,大面积的颗粒状伪影等问题。相比之下,DeepLabv3 + 整体分割精度较高,但在复杂背景或类别边界模糊区域,仍出现少量误分与掩膜遗漏的现象。例如:样本 2 中右下角杂草被误判为菜地;样本 4 中撂荒地掩膜存在部分缺失。改进后的 MAP - DeepLabv3 + 模型地物识别掩膜覆盖完整、边缘轮廓清晰细腻,未出现锯齿状边界和分类混淆的现象。

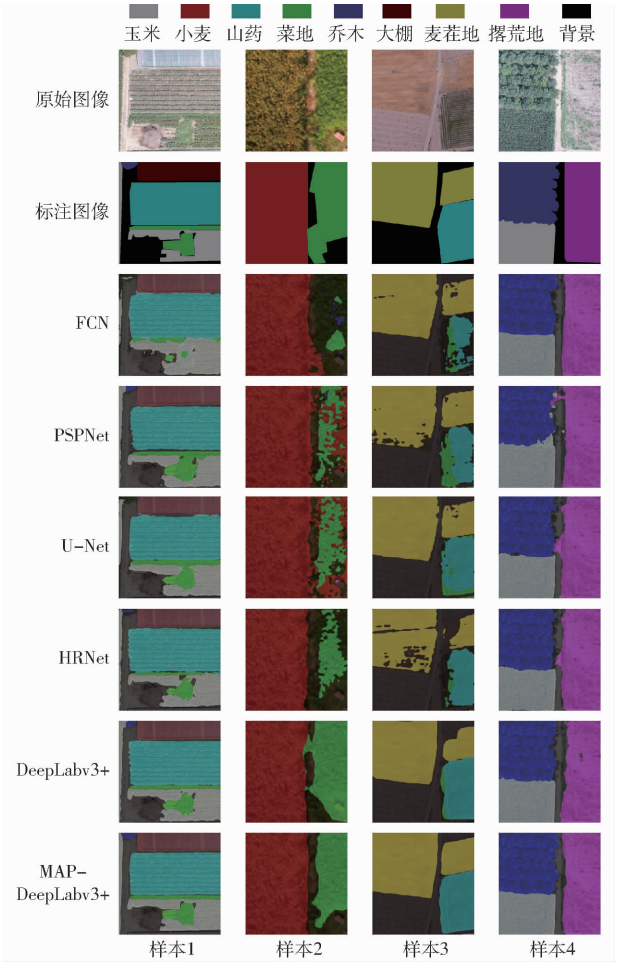

图 9 不同模型分割对比结果

Fig. 9 Comparison of segmentation results of different models

3.3.4 低质量样本识别测试

在无人机图像采集过程中,低质量样本可能对农作物监测任务产生干扰。如,在航拍作业中会采集到房屋、建筑等非农区域,形成对作物识别无效的空白区域;受风力干扰,图像易出现模糊现象;飞行姿态变化可能引发几何畸变,影响影像的空间一致性。为探究所提改进模型在复杂样本条件下的泛化能力,从原始航拍图像中选取空白区域、残影模糊和几何畸变的低质量样本进行测试分析,低质量样本测试效果如图 10 所示。

由图 10 可知,在包含空白区域的低质量样本中,MAP - DeepLabv3 + 模型将高速公路、农田道路及房屋设施正确识别为背景区域;对于残影模糊的

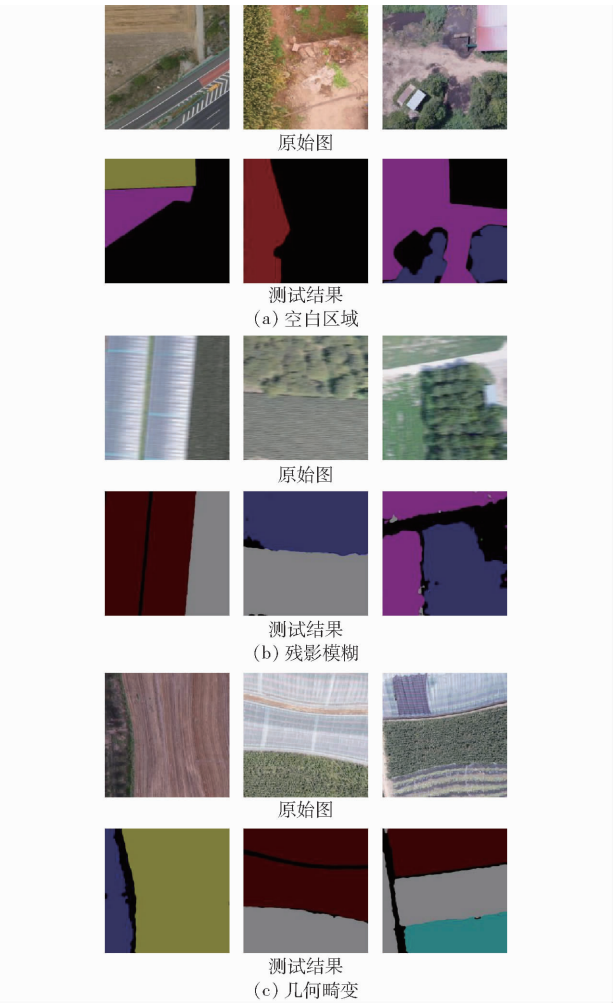

图 10 低质量样本测试效果图

Fig. 10 Test effect diagram of low-quality samples

低质样本,模型能准确识别模糊地物且正确分类各语义类别;面对几何畸变样本,尽管大棚与作物边缘存在明显扭曲现象,MAP - DeepLabv3 + 模型不仅能够识别畸变区域的边界信息,且在个别样本上因训练图像数量充足,预测结果呈现出一定的几何修复能力。结果表明,MAP - DeepLabv3 + 模型在多种复杂样本条件下均展现出优异的分割性能与较强的泛化性。

4 撂荒地种植推荐系统

为了直观地展示作物监测结果,提升撂荒地资源的科学配置与利用效率,本研究基于所提策略开发了撂荒地种植推荐系统,以应用于实际农田监测与管理,如图 11 所示。该系统后台集成遥感图像解析、地理定位与作物分布统计功能,可在广空间范围内汇聚周边作物信息,结合农时与邻域优势作物,智能生成撂荒地种植推荐方案。

系统基于 PyQt 平台构建,支持输入无人机采集的低空遥感图像,并加载用户选择的最优训练权重。在执行预测功能时,系统的作物解析区可同步显示



图 11　撂荒地种植推荐系统

Fig. 11　Recommendation system for abandoned farmland planting

测试图像及所加载的最优权重路径，同时提供该图像对应的经纬度坐标信息及识别出的作物类别结果。若图像中包含撂荒地，用户可启用推荐功能，系统将自动检索其邻域范围内（系统默认邻域半径为 200 m）的历史遥感图像，依据撂荒地种植推荐策略，在推荐种植区输出该撂荒地的优选种植作物建议。

5　结论

（1）随着撂荒现象频发，粮食产能持续下降，采用科学手段推进耕地资源的再利用具有重要意义。通过无人机技术对大范围农田开展农作物监测，统计区域内优势种植作物种类及其分布特征，开展基于作物适宜性的撂荒地种植推荐，可为智慧农业背景下耕地资源的高效利用与精准配置提供技术参考。

（2）针对农田监测需求，对 DeepLabv3 + 模型进行轻量化改进，引入 MobileNetv4 作为主干网络以降低模型参数量；在解码阶段引入自适应细粒度通道注意力机制，增强对作物边缘与纹理特征的感知；采用风车卷积替换传统 3 × 3 卷积，提升小尺度目标提取能力；构建 FocalDiceLoss 复合损失函数，以缓解类别不平衡与相似类别难区分问题。

（3）所提出的改进 DeepLabv3 + 模型在农田遥感影像分割任务中取得优异表现，其准确率、平均像素准确率和平均交并比分别达到 96.64%、96.37%、92.82%，较原始模型分别提升了 1.85、3.71、6.10 个百分点；同时，模型参数量和浮点运算次数分别较原模型减少 76.04%、79.80%。与 FCN、PSPNet、U - Net 和 HRNet 等典型语义分割模型相比，综合性能最优。

参　考　文　献

[1] 张楚，侯冠宇. 转型与创新：中国农业农村发展的历史逻辑——以“中央一号文件”为中心的考察[J]. 农业经济，2025(5)：22 - 24.
ZHANG Chu, HOU Guanyu. Transformation and innovation: the historical logic of China's agricultural and rural development—an investigation centered on the "No. 1 Central Document"[J]. Agricultural Economy, 2025(5): 22 - 24. (in Chinese)

[2] 赵晓宇，孙春强，崔荣国，等. 基于粮食安全的中国耕地保护阈值研究[J]. 资源科学，2024，46(12)：2355 - 2366.
ZHAO Xiaoyu, SUN Chunqiang, CUI Rongguo, et al. Research on the arable land protection threshold in China based on food security[J]. Resources Science, 2024, 46(12): 2355 - 2366. (in Chinese)

[3] 彭继权，童建，李家陶，等. 粮食安全背景下高标准农田建设的耕地复种效应研究[J]. 中国土地科学，2024，38(12)：29 - 40.
PENG Jiquan, TONG Jian, LI Jiatao, et al. Study on the multiple cropping effect of high-standard farmland construction under the background of food security[J]. China Land Science, 2024, 38(12): 29 - 40. (in Chinese)

[4] 郑淋议，陈紫微. 耕地细碎化对农户耕地撂荒的影响及其治理优化[J]. 地理研究，2024，43(1)：200 - 213.
ZHENG Linyi, CHEN Ziwei. The impact of arable land fragmentation on farmland abandonment by farmers and optimization of its governance[J]. Geographical Research, 2024, 43(1): 200 - 213. (in Chinese)

[5] WUYUN D, DUAN M, SUN L, et al. Pixel-wise parameter assignment in LandTrendr algorithm: enhancing cropland abandonment monitoring using satellite-based NDVI time-series[J]. Computers and Electronics in Agriculture, 2024, 227: 109541.

[6] LEITE D, TEIXEIRA I, MORAIS R, et al. Comparative analysis of CNNs and vision transformers for automatic classification of abandonment in Douro's vineyard parcels[J]. Remote Sensing, 2024, 16(23): 4581.

[7] HAFEEZ A, HUSAIN M A, SINGH S P, et al. Implementation of drone technology for farm monitoring & pesticide spraying: a review[J]. Information Processing in Agriculture, 2023, 10(2): 192 - 203.

[8] RUAN Z, CHANG P, CUI S, et al. A precise crop row detection algorithm in complex farmland for unmanned agricultural machines[J]. Biosystems Engineering, 2023, 232: 1 - 12.

[9] WANG L, BAI Y, WANG J, et al. Histogram matching-based semantic segmentation model for crop classification with Sentinel - 2 satellite imagery[J]. GIScience & Remote Sensing, 2023, 60(1): 2281142.

[10] LI Z, DENG X, LAN Y, et al. Fruit tree canopy segmentation from UAV orthophoto maps based on a lightweight improved U - Net[J]. Computers and Electronics in Agriculture, 2024, 217: 108538.

[11] EBRAHIMY H, YU T, ZHANG Z. Developing a spatiotemporal fusion framework for generating daily UAV images in agricultural areas using publicly available satellite data[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2025,

220: 413 – 427.
[12] 武锦龙,吴虹麒,李浩,等. 基于改进 DeepLabv3 + 的荞麦苗期无人机遥感图像分割识别方法研究[J]. 农业机械学报,2024,55(5):186 – 195.
WU Jinlong, WU Hongqi, LI Hao, et al. Research on buckwheat seedling stage image segmentation and recognition from UAV remote sensing based on improved DeepLabv3 + [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(5): 186 – 195. (in Chinese)
[13] 李安琦,马丽,于合龙,等. 改进的 U – Net 算法在遥感图像典型农作物分类研究[J]. 红外与激光工程,2022,51(9): 428 – 434.
LI Anqi, MA Li, YU Helong, et al. Research on typical crop classification in remote sensing images based on improved U – Net algorithm[J]. Infrared and Laser Engineering, 2022, 51(9): 428 – 434. (in Chinese)
[14] CHEW R, RINEER J, BEACH R, et al. Deep neural networks and transfer learning for food crop identification in UAV images[J]. Drones, 2020, 4(1): 7.
[15] 赵子宇,石刚. 引入自注意力 U – Net 的无人机遥感农作物分类模型[J]. 现代电子技术,2023,46(4):125 – 129.
ZHAO Ziyu, SHI Gang. A crop classification model for UAV remote sensing images based on self-attention U – Net[J]. Modern Electronic Technology, 2023, 46(4): 125 – 129. (in Chinese)
[16] 郭金,宋廷强,孙媛媛,等. 改进 DeepLabv3 + 的双注意力融合作物分类方法[J]. 计算机工程与应用,2024,60(8):110 – 120.
GUO Jin, SONG Tingqiang, SUN Yuanyuan, et al. Crop classification method based on dual attention fusion with improved DeepLabv3 + [J]. Computer Engineering and Applications, 2024, 60(8): 110 – 120. (in Chinese)
[17] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]// Proceedings of the European Conference on Computer Vision (ECCV), 2018: 801 – 818.
[18] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition,2017: 1251 – 1258.
[19] QIN D, LEICHNER C, DELAKIS M, et al. MobileNetV4: universal models for the mobile ecosystem[C]// European Conference on Computer Vision. Cham: Springer Nature Switzerland, 2024: 78 – 96.
[20] SUN H, WEN Y, FENG H, et al. Unsupervised bidirectional contrastive reconstruction and adaptive fine-grained channel attention networks for image dehazing[J]. Neural Networks, 2024, 176: 106314.
[21] YANG J, LIU S, WU J, et al. Pinwheel-shaped convolution and scale-based dynamic loss for infrared small target detection [C]// Proceedings of the AAAI Conference on Artificial Intelligence, 2025: 9202 – 9210.
[22] 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.
[23] LI X, SUN X, MENG Y, et al. Dice loss for data-imbalanced NLP tasks[J]. arXiv preprint arXiv:1911.02855, 2019.

(上接第 66 页)

[18] 丁力, 杨丽, 武德浩, 等. 基于 DEM – CFD 耦合的玉米气吸式排种器仿真与试验[J]. 农业机械学报, 2018,49(11): 48 – 57.
DING Li, YANG Li, WU Dehao, et al. Simulation and experiment of corn pneumatic suction seed metering device based on DEM – CFD coupling [J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(11): 48 – 57. (in Chinese)
[19] SUN J, CHEN H, WANG Z, et al. Study on plowing performance of EDEM low-resistance animal bionic device based on red soil[J]. Soil and Tillage Research, 2020,196: 104336.
[20] AMANOWICZ A, WOJTKOWIAK J. Thermal performance of multi-pipe earth-to-air heat exchangers considering the non-uniform distribution of air between parallel pipes[J]. Geothermics, 2020,88: 101896.
[21] ICHA A, LEMONS D S. A student's guide to dimensional analysis[J]. Pure and Applied Geophysics, 2018,175(6): 2403 – 2405.
[22] XING H, WANG Z, LUO X, et al. Design and experimental analysis of rice pneumatic seeder with adjustable seeding rate [J]. International Journal of Agricultural and Biological Engineering, 2021,14(4): 113 – 122.
[23] 宋鹏飞, 杨利然. 单相多分支并联管路流动特性研究与设计[J]. 炼油技术与工程, 2020,50(3): 42 – 47.
SONG Pengfei, YANG Liran. Research and design on flow characteristics of single-phase multi-branch parallel pipelines [J]. Refining Technology and Engineering, 2020, 50(3): 42 – 47. (in Chinese)
[24] 展鹏程, 夏俊芳, 周华, 等. 气力式水稻旱直播机气力系统负压特性试验[J]. 华中农业大学学报, 2017,36(4): 95 – 101.
ZHAN Pengcheng, XIA Junfang, ZHOU Hua, et al. Experimental study on the negative pressure characteristics of the pneumatic system of pneumatic dry direct-seeded rice seeder[J]. Journal of Huazhong Agricultural University, 2017, 36(4): 95 – 101. (in Chinese)