



甘蔗干旱等级识别的低空遥感分割模型研究

王政锋¹, 李莉², 马瑞升³, 莫妤捷⁴, 匡昭敏^{3*}

1. 桂林理工大学计算机科学与工程学院(人工智能学院)/广西嵌入式技术与智能系统重点实验室, 广西桂林 541006; 2. 广西壮族自治区气候中心, 南宁 530022; 3. 广西壮族自治区气象科学研究所, 南宁 530022; 4. 广西壮族自治区气象技术装备中心, 南宁 530022

摘要: 针对单一气象指标为主要依据的干旱评估与预警方法难以精细化反映甘蔗生长状况的问题, 研究构建了一种融合低空遥感影像与深度学习模型的甘蔗干旱等级智能识别方法。以健康/干旱甘蔗为研究对象, 在三个典型种植区域采集地块低空遥感影像, 计算归一化植被指数, 并结合专家判读建立干旱等级标签。在 U-Net 语义分割框架基础上, 引入残差网络 ResNet-34 作为主干, 并采用加权跳跃连接提升边缘识别能力, 构建了 CaneUNet-W 模型。通过区域交叉验证评估模型性能, 结果显示模型在甘蔗地块识别任务中的交并比(IoU)、F1 值和 Kappa 系数平均分别为 0.924、0.960 和 0.912, 表现出较高的精度与泛化能力, 模型推演结果的空间分布特征与专家基于高分影像的视觉判读趋势基本吻合。本方法能客观反映甘蔗冠层在干旱胁迫下的遥感表型变异, 验证了其在甘蔗旱情智能识别与精细化评估中的可行性与有效性。但受限于地面同步实测数据的缺乏, 未来研究将引入土壤墒情等生理指标进行定量标定, 从而提升甘蔗生产的防灾减灾能力。

关键词: 甘蔗; 低空遥感; 深度学习; 语义分割; U-Net

1 引言

农业是全球经济的基础, 在发展中国家尤其重要, 甘蔗是我国核心糖料经济作物, 其产量稳定直接关系到国家食糖安全与蔗区农业经济发展, 同时甘蔗也为食品加工和生物能源生产提供了关键原料。近年来, 全球气候变化加剧导致极端天气频发, 干旱已经成为影响甘蔗生产的重大气象灾害之一, 在我国甘蔗主产区广西, 近 10 年(2015–2024 年)中发生干旱灾害 8 年, 2020–2023 年连续 3 年出现夏旱, 2024 年秋至 2025 年春出现了严重秋冬春连旱, 甘蔗生产面临严峻挑战。因此, 准确地评估和预警甘蔗干旱等级, 对指导甘蔗地块的科学灌溉和提升防灾抗灾减灾能力具有重要意义。

传统的甘蔗干旱评估和预警方法主要通过气象观测、土壤湿度监测等气象要素数据计算并构建标准化降水蒸散指数(Standardized Precipitation

Evapotranspiration Index, SPEI)等干旱指标进行评估^[1-3]。这些方法在区域尺度的干旱预警中具有一定的成效, 但其数据源的空间分辨率较低, 无法满足细粒度、精细化的干旱评估与预警需求^[4]。卫星遥感技术结合归一化植被指数(Normalized Difference Vegetation Index, NDVI)^[5,6]可以评估甘蔗的生长状态及干旱情况, 然而卫星遥感的时间和空间分辨率较低, 且容易受天气条件和云层的影响, 难以满足高频次、细粒度的评估与预警需求^[7]。近年来, 随着无人机遥感技术的快速发展, 为甘蔗干旱评估与预警提供了新的技术方案。无人机可以搭载多种传感器高频次地获取甘蔗地块的高分辨率低空遥感影像^[8-11], 使得高频次、细粒度的干旱评估与预警成为可能。与卫星遥感相比^[12], 无人机低空遥感具有更高的时空分辨率, 更加适合小区域甘蔗地块的高频次、精细化的监测预警任务, 其多光谱与热红外遥感影像能够精确表征作物的健康状况^[1, 13-14]。因此, 无人机低空遥感

收稿日期: 2026-04-26; 录用日期: 2026-07-15

基金项目: 中国气象局科技项目“揭榜挂帅”(No.CMAJBGS202322); 广西自然科学基金项目(No.2026GXNSFAA00641192); 桂林理工大学科研启动基金(No.GUTQDJJ6613034); 广西嵌入式技术与智能系统重点实验室基金项目(No.2020-2-3)。

联系方式: 王政锋, E-mail: zfwang@glut.edu.cn. 通信作者匡昭敏, E-mail: kzhaomin@163.com。

已经成为精细化农业监测的重要工具之一。然而,无人机低空遥感数据的大数据量以及复杂维度对传统的人工处理方法提出了挑战,因此,亟需借助计算机视觉^[15-18](图像分类、目标检测、语义分割等)等人工智能技术实现遥感数据特征的智能提取与解析^[19]。当前,计算机视觉领域的深度学习模型已经广泛应用于农田无人机低空遥感影像的特征提取与解析任务中^[17, 20],可以实现农作物生长状态以及灾害预警的自动评估与监测^[21-22]。将无人机低空遥感影像与人工智能方法相结合对农作物表型进行表征和监测,已经成为农业气象领域进行胁迫识别和减灾预警的重要技术手段之一。

研究表明,低空遥感数据与深度学习模型的融合已经在多种作物的生长状态监测、病虫害诊断及胁迫预警领域取得了显著成效,充分验证了该技术路径的可行性与有效性。例如, SU^[23]等通过植被分割、特征工程以及贝叶斯优化的支持向量机(Support Vector Machine, SVM)分类器表征解析无人机低空遥感影像的光谱强度与颜色指数等特征,实现了小麦水分胁迫的高精度(92.8%)评估。Prodhan^[24]等利用深度前馈神经网络(Deep Feedforward Neural Network, DFNN)解析 2001 至 2016 年南亚地区的遥感影像数据,结合降水、植被和土壤因子以及土壤湿度亏缺指数(Soil Moisture Deficit Index, SMDI)等人工特征,对三个不同生育期的作物干旱特征进行了评估,验证了深度学习方法在遥感影像解析中的有效性。Yang^[25]等通过无人机低空遥感数据校正卫星遥感影像,并结合实测土壤数据运用随机森林和极端梯度提升等机器学习算法计算反演土壤湿度,绘制了大尺度冬小麦干旱等级图,为基于多源遥感数据融合的精细化干旱监测提供了可行路径。Liu^[26]等提出了一种基于 ResNeXt-50 骨干网络的语义分割模型,通过解析无人机低空遥感影像并结合 NDVI 辅助标注进行农作物的干旱区域识别与等级划分,该模型验证了深度分割模型在农作物干旱的低空遥感影像上的有效性。张淦^[27]等通过融合低空遥感影像与 Swin-Transformer 迁移学习架构的语义分割模型,提高了有限样本下小麦倒伏面积提取的精度。Liang^[28]等利用 SVM 模型与无人机低空遥感数据构建了大豆干旱耐性的高通量评估体系,通过对不同区域与生育期的监测评估,验证了低空遥感影像在作物耐寒评价中的可行性。Niu^[29]等基于无人机低空遥感

影像设计实现了一种改进型 YOLOv8+模型,能够进行玉米早期干旱检测,可以识别小目标与遮挡区域。Zhou^[30]等利用无人机低空遥感对 116 个大豆基因型在生殖期的冠层影像进行采集,通过 SVM 对提取的 NDVI、株高等特征进行解析,继而完成快萎蔫与慢萎蔫基因型的分类任务,验证了低空遥感影像对冠层影像表型的反映能力。

随着无人机低空遥感技术与人工智能技术的快速发展,基于低空遥感影像的作物水分胁迫智能识别已经成为干旱评估预警的重要途径之一。虽然已经在小麦、玉米以及大豆等作物的干旱或病虫害监测中广泛应用,但是针对甘蔗这类特色经济作物的干旱识别研究相对不足,尤其是干旱等级的划分。甘蔗对水分变化极为敏感,准确的干旱预警对甘蔗的灌溉以及抗灾减灾具有重要的意义。因此,本研究提出了一种面向甘蔗干旱等级识别的低空遥感分割模型,结合 NDVI 干旱标签实现甘蔗干旱等级的精细化划分,以探索低空遥感在甘蔗干旱精细化评估与预警领域的应用潜力。

2 研究方法

本研究提出了一种基于无人机低空遥感影像的甘蔗干旱等级识别方法,采用改进型 U-Net 模型(Cane U-Net with Weighted Skip Connections, CaneUNet-W)对甘蔗地块进行精确分割,结合 NDVI 干旱等级标签实现甘蔗干旱等级的精细化划分。主要工作包括无人机遥感影像的采集与预处理、CaneUNet-W 模型的构建与训练优化、NDVI 驱动的干旱等级标签划分设计与表征以及模型的优化训练与性能评估,通过融合低空遥感影像与深度学习模型实现甘蔗干旱等级智能识别。

2.1 低空遥感影像数据采集与预处理

研究区域选取广西甘蔗主产区内的三个典型干旱区域,分别是江州宁明界派关水库(22.2°N, 107.6°E, 以下简称 A 区)、江州濠湍叫城村(22.5°N, 107.5°E, 以下简称 B 区)和江州濠湍九岸(22.4°N, 107.5°E, 以下简称 C 区),其空间地理分布及详细影像特征见图 3。研究区考虑了地形条件、背景复杂程度以及作物物候差异,为区域交叉验证和模型泛化能力提供多样化验证样本。A 区(2020 年 7 月 28 日)位于水库周边,甘蔗地块易受水体边界效应影响且分布零碎,背景差异显著;B 区(2020 年 7 月 29

日)为村庄混作区,甘蔗地块零散,且伴有杂草和树木背景,背景类型复杂;C区(2020年8月26日)地势较为平坦开阔,甘蔗地块较为规整,但相较于A区和B区其数据采集时间晚一个月,甘蔗处于不同生育阶段。上述三个实验区通过空间异质性和时间跨度的差异化组合,构成了从复杂破碎到规整平摊、从早期生长到后期发育的测试梯度,为评估模型在不同时空环境下的泛化能力提供了多样化的样本。

无人机航拍任务设定空间分辨率为5 cm/pixel,航线前向重叠率与旁向重叠率分别为80%与75%,飞行速度控制在5 m/s以内,以确保影像的空间连续性与几何精度。使用大疆精灵4RTK和Mavic 3E四轴专业级无人机获取的遥感数据包括红光、绿光与近红外波段,支持归一化植被指数(NDVI)等精确提取计算,同时RGB影像可以提供作物冠层生理与结构以及色彩等可视特征信息,便于深度学习模型识别甘蔗地块信息。此外,为适配深度学习模型的标准化输入特征分布,遥感影像会被裁剪为规定尺寸的图像块,并对其像素值进行线性归一化处理至[0,1]

区间的标准化分布。

2.2 模型结构设计

为了能够精确地提取甘蔗地块的空间分布特征,本研究构建了一种基于ResNet-34骨干网络的改进型U-Net语义分割模型CaneUNet-W。该模型仍然采用对称的编码-解码框架,在编码阶段,嵌入预训练的ResNet-34作为编码器以增强模型的特征提取能力。在解码阶段,建立了编码器与解码器对应层之间特征映射的跳跃连接。为了方便调整深浅层的特征传递和信息融合方式,设计了可切换的跳跃连接机制,包括无跳跃、加权跳跃(Weighted Skip)和注意力跳跃(Attention Skip)三种方式。加权跳跃通过可学习参数动态分配低层特征的重要性,注意力跳跃则可以通过注意力门控机制抑制复杂背景的干扰,强化边界过渡区域的特征,从而提升模型在复杂地块背景下的鲁棒性。理论上,模型CaneUNet-W在保留U-Net模型特征恢复能力的同时,又能提高甘蔗地块边界及异质背景的识别精度,为干旱等级评估提供可靠的空间信息支持。模型CaneUNet-W结构图如图1所示。




图1 模型CaneUNet-W结构示意图

Fig. 1 Schematic diagram of the CaneUNet-W model structure

在编码阶段,以 ImageNet 预训练的 ResNet-34 作为主干网络,通过五个堆叠的残差块 ($Enc_1, \dots, Enc_5$) 逐层提取输出从浅层纹理到深层语义的多尺度特征图 ($F_1, \dots, F_5$)。层次化的编码结构能够分别捕获甘蔗地块在不同空间分辨率下的特征图,浅层特征有助于甘蔗地块中的垄状边缘与周期纹理信息的提取,而深层特征则侧重于语义表征与空间结构解析。在解码阶段,通过与编码器对称的五个转置卷积上采样模块 ($UpConv_5, \dots, UpConv_1$) 逐层恢复特征图的空间分辨率。解码器的每一层上采样特征图均与编码器对应层的特征图通过加权或注意力跳跃连接进行特征融合,既能确保全局语义的一致性,又能提升模型对边缘细节的重建以及空间定位能力。模型输出层为可生成预测掩膜的单通道卷积,在推理与损失计算阶段,通过 Sigmoid 激活将预测掩膜映射为像素级概率分布,以表征各像素属于甘蔗地类别的置信度,模型的数学定义表示如下:

$$P = \sigma(\text{Conv}_{1 \times 1}(\text{Dec}(\{\Phi(Enc_i(X))\}_{i=1}^5))) \quad (1)$$

其中 Enc_i 表示 ResNet-34 分层编码器, Φ 表示加权或注意力跳跃连接融合, Dec 表示由 $UpConv$ 层组成的解码器,主要分为以下几个阶段:

假设输入遥感图像 $X \in \mathbb{R}^{H \times W \times 3}$, 在编码阶段,经过五个编码层得到多尺度特征表示:

$$F_i = Enc_i(F_{i-1}), \quad i = 1, \dots, 5 \quad (2)$$

其中 $F_0 = X$, $F_i \in \mathbb{R}^{H_i \times W_i \times C_i}$, $H_i, W_i < H, W$ 。

在特征进行跳跃融合之前,通过中心裁剪算子 $C(\cdot)$ 对编码器输出的特征图 F_i 进行空间对齐,使其与解码器上采样结果保持一致的尺寸,确保后续跳跃连接的有效融合:

$$F'_i = C(F_i; H'_i, W'_i) \quad (3)$$

其中 F_i 为编码器第 i 层的输出特征, $F'_i \in \mathbb{R}^{C_i \times H'_i \times W'_i}$ 。

对于解码器第 i 层,建立与编码器第 i 层的加权或注意力机制跳跃连接融合:

$$\tilde{F}_i = \Phi(F'_i, D_{i+1}) \quad (4)$$

其中 D_{i+1} 为上一解码层的特征, $\Phi(\cdot)$ 表示特征融合函数,其加权和注意力形式分别表示如下:

$$\tilde{F}_i = \alpha_i F'_i + (1 - \alpha_i) D_{i+1}, \quad \alpha_i \in [0, 1] \quad (5)$$

其中为特征融合层的全局可学习标量权重,初始化为 0.5。在训练过程中,通过反向传播自动动态调节低层空间细节信息特征 F'_i 的输入强度,实现深浅层特征的自适应动态残差融合。

$$\tilde{F}_i = \sigma(W[F'_i, D_{i+1}]) \odot F'_i + D_{i+1} \quad (6)$$

其中 σ 为 Sigmoid, $\odot$ 为逐元素乘。利用上一解码层的高层语义信息作为门控信号,生成空间与通道注意力权重,从而抑制破碎背景噪声。

在解码阶段,通过转置卷积实现上采样:

$$D_i = UpConv_i(\tilde{F}_i), \quad i = 5, \dots, 1 \quad (7)$$

其中 $D_i \in \mathbb{R}^{H'_i \times W'_i \times C'_i}$, $H'_i, W'_i > H_{i+1}, W_{i+1}$

最终,通过单通道卷积以及 Sigmoid 映射输出像素级的概率分布:

$$P = \sigma(\text{Conv}_{1 \times 1}(D_1)), \quad P \in [0, 1]^{H \times W} \quad (8)$$

其中, $P_{\mu, \nu}$ 表示像素 (μ, ν) 属于甘蔗地的置信度。

遥感影像中甘蔗区域与非甘蔗区域样本分布存在显著不均衡性,因此,模型训练过程中采用二元交叉熵损失函数 (Binary Cross Entropy, BCE) 作为优化目标,其定义如下:

$$L_{BCE} = -\frac{1}{HW} \sum_{u, \nu} [T_{u, \nu} \log(P_{u, \nu}) + (1 - T_{u, \nu}) \log(1 - P_{u, \nu})] \quad (9)$$

其中, $T_{u, \nu} \in \{0, 1\}^{1 \times H \times W}$ 为像素 (u, ν) 的真实标签。

此外,在模型训练优化和推理过程中,由于输入的遥感影像尺寸较大,模型采用滑窗策略自动地将影像进行分块处理,并在在输出时自动拼接,可有效提升训练效率与显存利用率。

最后,生成的甘蔗地块分割图作为 NDVI 计算的空间掩膜,为后续干旱等级分类提供空间约束。模型的结构参数设置见表 1。

2.3 甘蔗干旱等级标签的构建与表征

为了在生成的甘蔗地块空间掩膜上实干旱状态的精细化表征与建模,本研究结合实地干旱调查和专家经验对 NDVI 值的判读构建了干旱等级标签体系。NDVI 是遥感监测作物水分状态的重要指标之一,通过计算遥感影像的中每个像素的 NDVI 值,生成高分辨率的 NDVI 图层,表征甘蔗植被的绿度水平及生长状态。其计算公式如下:

表 1 模型结构参数设置表（以输入图像尺寸为 512×512 为例）

Table 1 Model structure parameter settings (example for input image size 512×512)

模块	名称	操作类型	输出尺寸 (H×W×C)	参数说明
编码器	Enc1	Conv3×3+BN+ReLU×2	512×512×64	ResNet-34 第 1 层
	Enc2	Conv3×3+BN+ReLU×2	256×256×64	MaxPool + ResNet-34 第 2 层
	Enc3	Conv3×3+BN+ReLU×2	128×128×128	ResNet-34 第 3 层
	Enc4	Conv3×3+BN+ReLU×2	64×64×256	ResNet-34 第 4 层
	Enc5	Conv3×3+BN+ReLU×2	32×32×512	ResNet-34 第 5 层
解码器	UpConv5	Transposed Conv 2×2	64×64×256	与 Enc4 特征相加融合
	UpConv4	Transposed Conv 2×2	128×128×128	与 Enc3 特征相加融合
	UpConv3	Transposed Conv 2×2	256×256×64	与 Enc2 特征相加融合
	UpConv2	Transposed Conv 2×2	512×512×64	与 Enc1 特征相加融合
	UpConv1	Conv3×3+BN+ReLU	512×512×32	最后融合层
输出层	OutputConv	Conv1×1+Sigmoid	512×512×1	二分类概率图（甘蔗/非甘蔗）输出

$$NDVI = \frac{NIR - RED}{NIR + RED}$$

(10)

其中 RED、NIR 分别代表影像的红光波段与近红外波段。

干旱等级划分以 NDVI 作为表征因子。在数据采集同期对各研究区进行了手持 GPS 定位调查，通过实地观测甘蔗叶片卷曲度、变黄比例及土壤墒

情确立地面真值，充分考虑甘蔗植被在不同水分条件下的 NDVI 响应特征，并结合农业气象专家的人工经验判读，将干旱状态划分为四个等级：正常（Level 0）、轻度干旱（Level 1）、中度干旱（Level 2）、重度干旱（Level 3）和特重干旱（Level 4）。各等级对应的 NDVI 区间及作物生长状态描述如表 2 所示。

表 2 干旱等级划分标准

Table 2 Drought classification standards

干旱等级	NDVI 阈值区间	作物状态描述
Level 0	NDVI>0.70	无明显缺水迹象
Level 1	0.50≤NDVI≤0.70	轻度水分不足，叶片色泽略暗
Level 2	0.35≤NDVI<0.50	明显干旱，叶片卷曲发黄
Level 3	0.20≤NDVI<0.35	重度干旱，叶片明显干枯
Level 4	NDVI<0.20	严重干旱，生长停滞或枯死

算法 1 描述了结合遥感数据和 NDVI 植被指数评估甘蔗干旱等级的方法流程，该方法能够直观反应不同 NDVI 区间所对应的作物生理状态，实现甘蔗水分胁迫程度的定量和可视化与空间化表征。然而，NDVI 值在区间边界附近存在一定的模糊性，固定阈值的划分方式可能导致边界附近的像素分类不稳定的问题，在后续的研究中可考虑软标签或模糊权重的策略解决植被状态的过渡特征。此外，该方法在不同区域或生育期下可能存在适配误差，未来可考虑进行区域或生育期校正进一步提高该方法的适配性。

算法 1 基于遥感影像的干旱等级评估方法

输入：遥感影像 I ，分割模型 $f(\cdot)$ ，NDVI 阈值集合 $\{\tau_1, \tau_2, \dots, \tau_k\}$

输出：干旱等级图 D

初始化：设置阈值集合 $\{\tau_k\}$

- 计算影像 I 中每个像素 (i, j) 的 NDVI 指值 $V(i, j)$ ；
- 利用分割模型 $f(\cdot)$ 计算得到掩膜 $M(i, j) \in \{0, 1\} \leftarrow f(I)$ ；
- 对于每个像 $(i, j) \in M$ ：若 $\tau_{k-1} \leq V(x, y) < \tau_k$ ，则赋值等级 $d_{i,j} \leftarrow k$ ；
- 返回干旱等级图 $D = \{d_{x,y} \mid (x, y) \in M\}$ 。

2.4 模型优化训练与性能评估

为了优化和验证模型对甘蔗地块识别的有效性,本研究在构建的甘蔗地块影像上对模型进行了优化训练和评估。在模型训练过程中,将甘蔗地块影像划分为三组进行区域交叉验证,其中两个区域用于模型参数的迭代优化,剩余组用于模型泛化能力的评估。为满足神经网络的输入要求,采用滑动窗口对各区原始高分辨率遥感正射影像进行无重叠裁切,切片规格统一设置为 512×512 像素。经剔除不含甘蔗种植区的边缘无效切片后,最终构建了包含三个独立子集的区域交叉验证数据集。其中, A 区包含 93 张样本切片, B 区包含 100 张样本切片, C 区包含 100 张样本切片。该数据量确保了在两区联合训练、一区独立测试的交叉实验中,模型拥有充足且分布独立的样本进行参数更新与泛化表现评估。模型基于 PyTorch 深度学习框架实现,硬件运行环境为 NVIDIA RTX 3090 GPU,训练轮数设定为 200 轮,采用 Adam 优化器,并设置初始学习率为 1×10^{-3} , 参数 β_1 和 β_2 分别设置为 0.9、0.999, 损失函数选用适用于甘蔗地块识别的二元交叉熵损失。此外,针对甘蔗地块遥感影像尺寸大小不一的问题,训练和测试阶段均采用滑窗切块的方法生成小尺寸图像,并在测试阶段进行自动拼接恢复,使模型在不同尺度下对甘蔗地块实现精确、稳定的分割。在模型性能评估过程中引入多项评价指标,包括交并比 (Intersection over Union, IoU)、平均交并比 (mean IoU, mIoU)、准确率 (Precision)、召回率 (Recall)、F1-score 及 Kappa 系数。其定义如下:

IoU 用于评价模型预测甘蔗地块与实际甘蔗地块之间的重叠程度,定义为:

$$IoU = \frac{TP}{TP + FP + FN} \quad (11)$$

mIoU 是甘蔗地块与非甘蔗地块的 IoU 算术平均,是对模型分割性能的综合评。

Precision、Recal 以及 F1-score 用于评估模型对甘蔗地块的预测性能。其中, Precision 表示被模型预测为甘蔗地块的像素中实际属于甘蔗地块的比例, Recall 表示真实甘蔗地块像素被模型正确预测的比例, F1-score 定义为 Precision 与 Recall 的调和平均数,用于综合评估模型在甘蔗地块预测中的准确性。其计算公式为:

$$Precision = \frac{TP}{TP + FP} \quad (12)$$

$$Recall = \frac{TP}{TP + FN} \quad (13)$$

$$F1-score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (14)$$

Kappa 系数用于评估甘蔗地识别结果与随机一致性的偏差,可以全面量化模型的分割性能与泛化能力,定义如下:

$$k = \frac{P_o - P_e}{1 - P_e} \quad (15)$$

其中,观察一致率 P_o 计算为:

$$P_o = \frac{TP + TN}{TP + TN + FP + FN} \quad (16)$$

随机一致率 P_e 计算为:

$$P_e = \frac{(TP + FP)(RP + FN) + (FN + TN)(FP + TN)}{(TP + TN + FP + FN)^2} \quad (17)$$

其中,真正例 (True Positive, TP) 表示被模型正确预测为甘蔗地的像素数,真反例 (True Negative, TN) 为被模型正确预测为非甘蔗地的像素数,假正例 (False Positive, FP) 为被模型错误预测为甘蔗地的非甘蔗像素数,假反例 (False Negative, FN) 为被模型错误预测为非甘蔗地的甘蔗像素数。

3 实验结果与分析

为了验证本研究提出的甘蔗地块识别模型 CaneUNet-W 在不同空间下的泛化能力,选取三个典型甘蔗种植区的遥感影像,通过区域交叉验证实验系统地比较模型在不同时空区域上的性能,定量分析模型的泛化能力。实验区域分别编号为 A、B 和 C 区,三地在地形条件和数据采集时间存在差异,区域交叉验证的具体划分方式见表 3。

表 3 区域交叉实验设计方案

Table 3 Regional crossover experimental design plan

实验编号	训练区域	测试区域
实验一	A 区+B 区	C 区
实验二	B 区+C 区	A 区
实验三	A 区+C 区	B 区

在每组实验中,选取两个区域的数据作为训练集,在未参与训练的区域数据上进行测试实验。在所有实验中,使用统一的模型结构、训练超参数及评价指标,

确保实验结果的一致性和可比性。尽管 A、B、C 三个实验区的空间背景与采时存在异质性，但由于其处于同一区域气候背景下，各区内部均完整涵盖了从无干旱到重度干旱的 5 个受灾等级样本。这种标签分布的完备性确保了在任意两区联合训练时，训练集的特征空间均能完全覆盖测试区的所有干旱等级，从而在根本上避免了因区域标签缺失导致模型无法预测的问题。

3.1 模型性能评估

为了评估模型 (CaneUNet-W) 的性能，分别在三组区域交叉验证实验中评估了模型的各项性能指标。图 2 与表 4 列出了模型在各测试区域甘蔗地识别任务中的性能评估结果和指标分值，反映了模型的分割精度与空间泛化能力。

表 4 列出了模型 (CaneUNet-W) 在三组区域交叉验证实验中的性能评价指标分值，模型在各项评价指标上均取得了较高的分值，这表明所提出的模型在甘蔗种植区识别任务中具有良好的鲁棒性与泛化能力。从实验结果可以看出，模型在实验一 (A

区、B 区训练, C 区测试) 中的表现优异, IoU、F1-score 和 Recall 分别达到 0.964、0.982 和 0.977, 表明模型能够在未见过的区域中准确识别种植区边界, 具有较强的空间泛化能力。其 Kappa 值为 0.909, 也进一步验证了预测结果与真实标注之间的一致性。在实验二 (B 区、C 区训练, A 区测试) 中, 模型在指标 mIoU 与 Kappa 上表现突出, 分别为 0.955 和 0.954, 结果显示模型在 A 区 (水库区) 这种复杂地形和种植格局下, 仍然能够保持较高的一致性和整体分类精度。上述结果表明模型在训练样本多样性较高时 (融合 B 区和 C 区), 能够有效提升模型在不同空间分布下的适应能力。相比较其他两组实验, 模型在实验三 (A 区、C 区训练, B 区测试) 中取得的指标相对较低, IoU 和 mIoU 分别为 0.873 和 0.882, Kappa 为 0.874, Recall 值为 0.920, 均低于其他两组实验, 这表明模型在识别 B 区种植区时存在一定的漏检情况。这可能与 B 区 (村庄区) 影像中存在的地形起伏大、植被混杂度高等复杂背景因素相关, 导致模型在边界识别上出现偏差。




图 2 三组区域交叉验证实验中模型的性能评估结果。评价指标包括 IoU、mIoU、F1-score、Precision、Recall 和 Kappa 系数。每组实验使用两个区域的数据训练模型, 并在剩余区域进行测试。左图 (柱状图) 显示各指标得分; 右图 (ROC 曲线) 展示分类性能及 AUC 值。

Fig. 2 Performance evaluation results of the model in the three-region cross-validation experiments. Evaluation metrics include IoU, mIoU, F1-score, Precision, Recall, and Kappa coefficient. Each experiment used data from two regions to train the model and tested it in the remaining regions. Subplots: Left (Grouped bar charts) show the scores of each metric; Right (ROC curves) show the classification performance and AUC value.

表 4 不同测试区域的模型性能评价指标值
Table 4 Model performance evaluation metrics in different test areas

实验编号	IoU	mIoU	F1-score	Precision	Recall	Kappa
实验一	0.964	0.914	0.982	0.987	0.977	0.909
实验二	0.935	0.955	0.967	0.959	0.975	0.954
实验三	0.873	0.882	0.932	0.945	0.920	0.874

通过分析三组实验的结果，表明训练样本的多样性会直接影响模型的泛化性能。当训练区域涵盖多样的地貌与种植模式时（实验二），模型对新区域的适应性更强。此外，地形复杂的区域（如 B 区）会显著增加模型的训练与泛化难度，为提升复杂区域的性能表现，未来可通过扩充更多区域样本或增强数据集多样性来进一步提升模型表现。但总体上模型的表现稳定，在所有实验中，F1-score 均高于 0.93，Precision 均高于 0.94，表明模型在实际应用中具备较高的可靠性。

3.2 空间异质性分析

从区域交叉验证实验结果可以看出，虽然模型整体精度较高，但在不同测试区域的性能仍然存在差异，表明遥感影像的空间异质性是影响模型泛化能力的关键因素之一。在实验二（A 区测试）中，各项指标值相对均衡且整体较高，表明在水库区的复杂地形背景下，模型依然能够获得较高的分类精度；实验一（C 区测试）的多数评价指标值均高于其他两组实验，但其 mIoU 和 Kappa 相较实验二较低，这可能与 C 区遥感影像的采集时间较晚有关，甘蔗处于不同生长期，光谱响应和纹理特征存在差异，使得模型在边界一致性上的表现略有下降；实验三（B 区测试）的各项直接均低于其他两组实验，尤其是 IoU 和 Kappa 值，表明模型在村庄混作区域受非目标植被和杂草的影响较为明显。非目标植被与杂草的光谱特征与甘蔗地块存在部分重叠，降低了模型的特征判别能力。如图 2 所示，实验二的柱状图各指标柱高较为均衡，各项指标值整体较高；相比之下，实验一和实验三的柱高有所降低，直观地揭示了复杂背景及时空异质性对模型精度与泛化能力的影响。。结合图 3 研究区分布图，显示不同区域的地形环境和种植条件与模型性能形成对应关系，进一步验证了时空异质性对模型性能的影响。

上述差异性主要受到三方面因素的影响：1）地形与背景复杂度：水库区地貌复杂，但甘蔗地块边界纹

理特征清晰，模型仍能准确捕获关键特征；而混作区域非目标植被及杂草等干扰因素多，导致模型的分类精度下降；2）物候差异：C 区采集时间比其他区域晚一个月，甘蔗生长状态及背景植被处于不同生长阶段，其响应光谱和纹理特征存在差异，影响模型在边界一致性上的表现；3）训练样本多样性：训练数据覆盖的时空异质性越高，模型的泛化能力越强，这是实验二性能指标值分布均衡的关键因素。

3.3 可视化结果分析


图 4 可视化了三组测试区域的甘蔗地块分割及干旱等级划分结果，通过原始遥感影像与模型预测图的对比直观反映模型的性能表现。对比结果表明，模型能够准确地识别甘蔗地块的空间分布以及边界目标，预测结果与实际甘蔗地块格局高度一致且轮廓清晰、连续。通过等级划分图与甘蔗地块叠加分析发现，三组区域干旱等级的空间分布趋势与遥感图像基本一致，表明该方法在甘蔗干旱等级评估任务中的有效性和稳定性，验证了模型的空间泛化能力。

在甘蔗地块的边界区域，模型能准确的捕获地块边界并保持地块的完整性，体现了模型 CaneUNet-W 中跳跃连接结构在融合浅层边缘纹理特征与深层语义信息方面的有效性，增强了模型在甘蔗地块边缘区域的识别能力。

三组测试区的可视化结果表明，模型在甘蔗地块空间异质分布及不同采集时间条件下均能实现准确的识别甘蔗地块，表现出良好的空间泛化能力。同时图 4 的对比结果直观的验证了模型在干旱等级空间分布预测中的有效性，为后续干旱灾害的精细化分析提供了可靠的数据支撑。

3.4 模型对比与消融实验

为验证本研究提出的模型在甘蔗地快分割任务上的优越性，在同一测试环境中与其他主流语义分割模型进行了性能比较。通过模型结构的消融测试，评估了模型各模块对性能提升的贡献度。



实验区甘蔗主要分布区域，红色图层叠 The main distribution areas of sugarcane in the experimental areas , with the red layer overlaid

图3 研究区分布与实验性能对比：标注了三个实验区域的地理位置及模型表现。A 区表现最佳 (mIoU=0.955, Kappa=0.954)，B 区表现相对较低 (mIoU=0.882, Kappa=0.874)，C 区地势平坦、采集时间较晚，其 mIoU 和 Kappa 略低。图示直观揭示地形与物候差异对模型识别精度的影响。

Fig. 3 Study area distribution and experimental performance comparison: The geographical locations and model performance of the three experimental areas are marked. Area A performed best (mIoU=0.955, Kappa=0.954), Area B performed relatively poorly (mIoU=0.882, Kappa=0.874), and Area C, with its flat terrain and later data collection time, had slightly lower mIoU and Kappa. The figure visually illustrates the impact of topographic and phenological differences on the model's recognition accuracy.

3.4.1 模型对比实验

本研究选取广泛应用于遥感图像语义分割的模型 U-Net 与 DeepLabv3+ 作为基准比较模型。三种模型采用相同的训练集和测试集，确保实验条件的一致性和实验结果的可比性。训练迭代轮数设定为 200，优化器采用 Adam，初始学习率为 1×10^{-4} 。表 5 列出了三种模型在测试集上的评价指标值，涵盖 IoU、mIoU、F1-score、Precision、Recall 以及 Kappa 等指标。

表 5 列出了三种模型在 IoU、mIoU、F1-score、Precision、Recall、Kappa 及推理时间上的实验结果。

结合表 5 和图 5 可以看出，标准 U-Net 在所有指标上均显著低于 DeepLabv3+ 与 0.618，表明其在复杂背景下的分割鲁棒性和一致性不足。相比之下，DeepLabv3+ 在六个评价指标上均取得了较高分值，尤其在 IoU (0.969)、Recall (0.982) 和 Kappa (0.921) 上表现突出，验证了空洞卷积与多尺度上下文融合在遥感影像分割中的有效性。进一步对比 DeepLabv3+ 与 CaneUNet-W 可以发现，两者在各项指标上整体接近，但 CaneUNet-W 在 IoU、mIoU、F1-score 与 Kappa 等关键指标上均略高于 DeepLabv3+ (例如 IoU 由 0.969




图 4 典型测试区域甘蔗地分割及干旱等级预测可视化示例。左列为无人机原始影像，中列为预测干旱等级，右列为叠加结果。直观展示了模型对甘蔗地块边缘的精准识别，以及利用 NDVI 物理指标对于干旱空间状态的客观精细化表征。

Fig. 4 Visual example of sugarcane field segmentation and drought level prediction in a typical test area. The left column shows the original UAV imagery, the middle column shows the predicted drought levels, and the right column shows the overlay results, which intuitively demonstrate the model's accurate identification of sugarcane field edges and the objective and refined characterization of drought spatial conditions using the NDVI physical index.

表 5 不同模型在甘蔗地识别任务中的性能比较

Table 5 Performance comparison of different models in sugarcane field recognition tasks

模型	IoU	mIoU	F1-score	Precision	Recall	Kappa	Time (s)
U-Net	0.814	0.683	0.898	0.988	0.822	0.618	18.24
DeepLabv3+	0.969	0.925	0.984	0.987	0.982	0.921	21.99
CaneUNet-W	0.970	0.926	0.985	0.983	0.987	0.923	11.55




图5 模型CaneUNet-W在各个指标上与其它模型的对比以及三种模型的综合性能评估。评价指标包括IoU、mIoU、F1-score、Precision、Recall和Kappa系数。左图（热图）展示三种模型在各指标上的具体数值及整体性能差异；右图（ROC曲线图）显示三种模型分类性能及AUC值。

Fig. 5 compares the CaneUNet-W model with other models on various metrics and evaluates the overall performance of the three models. Evaluation metrics include IoU, mIoU, F1-score, Precision, Recall, and Kappa coefficient. The left figure shows the specific values of the three models on each metric and the overall performance differences; The right figure shows the ROC curves of the three models' classification performance and AUC values.

提升至0.970，mIoU由0.925提升至0.926，Kappa由0.921提升至0.923）。尽管数值提升幅度有限，但其在保持精度的同时显著降低了推理时间，仅为11.55 s，相较于DeepLabv3+的21.99 s缩短近一半，显示了模型在效率与精度之间的优势平衡。

综上所述，CaneUNet-W在保持与DeepLabv3+相当甚至略优的分割精度的同时，具有更高的计算效率，更适用于对实时性与资源消耗有较高要求的甘蔗灾害监测评估与预警任务。

3.4.2 消融实验设计与结果

为验证模型结构中关键模块的有效性，本文设计了多组消融实验，通过依次去除或修改核心模块单元，评估模型的性能变化，从而系统地分析核心模块单元对模型性能提升的贡献。消融实验设置如下：1）无跳跃连接（NoneSkip）：去除U-Net中的跳跃连接结构，仅通过解码器单向重建图像空间；2）加权跳跃连接（WeightedSkip）：在跳跃连接过程中引入可学习的权重参数，对编码和解码特征进行加权融合，通过自适应调整不同层级特征的贡献度，提升模型的多尺度信息表征能力；3）注意力跳跃连接（AttentionSkip）：在跳跃连接中引入通道与空间注

意力机制，对编码层传递的特征进行注意力加权，突出关键信息并抑制冗余信息，以提升特征融合的有效性；4）浅层编码器（ShallowEncoder）：将模型中的ResNet-34编码器替换为三层 3×3 卷积构成的浅层卷积堆叠结构；5）取消中心裁剪对齐机制（NoCropAlign）：在解码器的跳跃连接部分取消特征尺寸对齐，加权后直接拼接或相加融合。各组消融实验结果如图6和表6所示。

表6列出了不同结构下的消融实验结果。结合图6和表6可以看出，加权跳跃连接（WeightedSkip）和注意力跳跃连接（AttentionSkip）模型的各项性能指标均优于无跳跃连接（NoneSkip）的模型。其中，无跳跃连接的模型性能指标IoU、mIoU和Kappa的分值分别下降至0.954、0.893和0.885，表明跳跃连接可以有有效的传递特征的空间信息。加权跳跃连接模型在各项指标上的表现最优，尤其是在指标IoU（0.965）、F1-score（0.982）以及Kappa（0.912）上的表现尤为突出，表明在跳跃连接的路径上加入权重调节可以有效地提升空间信息特征的融合质量。相比注意力跳跃连接，注意力跳跃连接虽然在指标Precision上保持了较高水平（0.988），但是各项指标整体上略低于加权

跳跃连接。注意力机制在模型中没有发挥其优势可能与数据集规模或特征分布有关。但以上实验结果表明跳跃连接通过保留空间信息的方式可以显著提高模型的分割精度。

此外，编码器的结构以及特征对齐策略对模型的性能也有显著的影响。浅层编码器（ShallowEncoder）模型的性能下降较为明显，IoU 下降至 0.783，而 Kappa

的分值则降至 0.572。由此可见，浅层编码器无法捕获复杂的高层语义信息，同时也验证了在甘蔗分割任务中，深层编码器对提升全局感受野和增强判别能力起到关键的作用。无中心裁剪对齐模型的性能指标同样有所下降，mIoU 和 Kappa 分别降至 0.856 和 0.842，表明在解码阶段保持特征尺度对齐对于准确恢复空间结构具有重要意义。

表 6 消融实验结果对比
Table 6 Comparison of ablation experiment results

模型版本	IoU	mIoU	F1-score	Precision	Recall	Kappa
无 skip (NoneSkip)	0.954	0.893	0.976	0.989	0.964	0.885
加权 skip (WeightedSkip)	0.965	0.917	0.982	0.989	0.976	0.912
注意力 skip (AttentionSkip)	0.950	0.885	0.974	0.988	0.961	0.876
浅层编码器 (ShallowEncoder)	0.783	0.649	0.878	0.988	0.791	0.572
无中心裁剪对齐 (NoCropAlign)	0.935	0.856	0.967	0.987	0.947	0.842




图 6 模型性能评估与消融实验结果对比。改进型 U-Net 模型的五种消融模型在各评价指标 (IoU、mIoU、F1-score、Precision、Recall、Kappa) 上的性能分析。左图 (小提琴-箱线-均值图) 展示各模型在所有指标上的值分布、离散程度及均值对比; 右图 (ROC 曲线图) 显示五种模型的分类性能及对应 AUC 值。

Fig. 6 Comparison of model performance evaluation and ablation experiment results. Performance analysis of five ablation models of the improved U-Net model on various evaluation metrics (IoU, mIoU, F1-score, Precision, Recall, Kappa). The left figure (Violin-box-means plot) shows the value distribution, dispersion, and mean comparison of each model on all metrics; The right figure (ROC curve plot) shows the classification performance of the five models and their corresponding AUC values.

4 讨论与展望

本研究提出了一种融合低空遥感影像与深度学习

模型的甘蔗干旱等级智能划分方法，既可以准确表征作物生长状态，又能实现高精度、连续化的监测评估。通过改进 U-Net 语义分割模型构建 CaneUNet-

W, 实现甘蔗地块的精准分割, 结合归一化植被指数的特征分布, 建立反映作物生理水分状况的干旱等级分类标签。在模型 CaneUNet-W 中加入跳跃连接, 有效提升了甘蔗地块边界识别的精度, 与 U-Net 和 DeepLabv3+ 等其他语义分割模型的性能相比, 其精度与空间泛化能力更优越。在干旱等级划分任务中, 该方法评估的干旱等级空间分布特征与遥感图像基本一致, 表明了该方法能准确评估甘蔗干旱等级。此外, 运用区域交叉验证的方法, 验证了该方法在不同地貌条件下均能表现出较高的识别精度与空间泛化能力, 表明其在农业旱情监测任务中的可行性与有效性。

尽管该方法在甘蔗干旱等级评估任务中取得了良好的实验结果, 但仍然存在一定的局限性。1) 该法使用固定 NDVI 区间的干旱等级标签, 在不同区域或生育期下存在一定的适配误差, 可能导致部分像素分类不稳定。2) 本研究利用单时相遥感图像训练识别, 对甘蔗生长过程中的时序变化特征不敏感, 可能导致模型对不同生育阶段的适应性不足, 从而影响甘蔗地块识别结果的稳定性。针对以上问题, 后续研究可以从以下两方面改进: 1) 在不同的区域和生育期下进行 NDVI 值等级标签的校正, 建立更加系统的干旱等级标签, 提高等级划分方法的时空适应性。2) 通过在关键物候阶段采集多时相无人机遥感数据, 构建反映作物动态变化的时序样本集, 并在模型中加入时序注意力模块, 提高模型对不同时期甘蔗冠层光谱特征的表征能力。

综上所述, 本研究提出的融合低空遥感影像与深度学习模型的甘蔗干旱等级划分方法在精细化甘蔗干旱评估与预警中有广阔的应用前景, 通过与气象指标和气象预报的空地数据融合应用, 有望成为甘蔗干旱精细化评估与预警的重要技术支撑, 有效提高甘蔗生产的防灾抗灾减灾能力。

参考文献

- [1] Sharma H, Sidhu H, Bhowmik A. Remote sensing using unmanned aerial vehicles for water stress detection: a review focusing on specialty crops. *Drones*, 2025, 9(4): 241.
- [2] Chen H, Yang N, Song X, et al. A novel agricultural drought index based on multi-source remote sensing data and interpretable machine learning. *Agricultural Water Management*, 2025, 308: 109303.
- [3] 李欣璋, 别强, 石莹, 等. 中国西北地区不同类型草地 NDVI 对 SPEI 的时空响应特征 [J/OL]. 甘肃农业大学学报 (2025-12-03). <https://link.cnki.net/urlid/62.1055.s.20251202.2007.008>.
- [4] Li X Z, Bie Q, Shi Y, et al. Spatiotemporal response characteristics of NDVI to SPEI in different grassland types in Northwest China [J/OL]. *Journal of Gansu Agricultural University* (2025-12-03). <https://link.cnki.net/urlid/62.1055.s.20251202.2007.008>.
- [5] Mullapudi A, Vibhute A D, Mali S, et al. A review of agricultural drought assessment with remote sensing data: Methods, issues, challenges and opportunities. *Applied Geomatics*, 2023, 15(1): 1-13.
- [6] Som-Ard J, Atzberger C, Izquierdo-Verdiguier E, et al. Remote sensing applications in sugarcane cultivation: A review. *Remote Sensing*, 2021, 13(20): 4040.
- [7] 李莉, 匡昭敏, 莫建飞, 等. 广西甘蔗秋旱灾害风险评估技术初步研究. *应用气象学报*, 2016, 27(1): 95-101.
- [8] Li L, Kuang Z M, Mo J F, et al. Assessment of autumn drought risk of sugarcane in Guangxi. *Journal of Applied Meteorological Science*, 2016, 27(1): 95-101.
- [9] Kumar V, Sharma K V, Pham Q B, et al. Advancements in drought using remote sensing: assessing progress, overcoming challenges, and exploring future opportunities. *Theoretical and Applied Climatology*, 2024, 155(6): 4251-4288.
- [10] Awais M, Li W, Cheema M J M, et al. UAV-based remote sensing in plant stress image using high-resolution thermal sensor for digital agriculture practices: A meta-review. *International Journal of Environmental Science and Technology*, 2023, 20(1): 1135-1152.
- [11] 李林源, 黄华国, 穆西晗, 等. 低空无人机植被定量遥感: 进展、挑战与展望. *遥感学报*, 2025, 29(6): 2083-2113.
- [12] Li L Y, Huang H G, Mu X H, et al. Low-altitude UAV-based quantitative remote sensing of vegetation: Advances, challenges, and prospects. *National Remote Sensing Bulletin*, 2025, 29(6): 2083-2113.
- [13] Mohd Nazri N W, Hashim K A, Mohd Zaki N A, et al. Advancing sustainable paddy farming: utilizing multispectral unmanned aerial vehicle (UAV) technology for efficient water stress detection and management // 2025 21st IEEE International Colloquium on Signal Processing & Its Applications (CSPA). February 7-8, 2025. Pulau Pinang, Malaysia. IEEE, 2025: 210-215.
- [14] Aldrighttoni J, d'Urso M G. Advances in precision farming: a contribute for estimating crop health and water stress by comparing UAV multispectral and thermal imagery. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2025: 33-40.

- [12] Ahmad U, Alvino A, Marino S. A review of crop water stress assessment using remote sensing. *Remote Sensing*, 2021, 13(20): 4155.
- [13] Ruwanpathirana P P, Sakai K, Jayasinghe G Y, et al. Evaluation of sugarcane crop growth monitoring using vegetation indices derived from RGB-based UAV images and machine learning models. *Agronomy*, 2024, 14(9): 2059.
- [14] Dong H, Dong J H, Sun S K, et al. Crop water stress detection based on UAV remote sensing systems. *Agricultural Water Management*, 2024, 303: 109059.
- [15] 钱涛,詹雅婷,李胤,等. 基于车载相机和 HLS 时序遥感数据的作物分类研究. *农业大数据学报*, 2025, 7(2): 161-172.
- Qian T, Zhan Y T, Li Y, et al. Crop Classification research based on vehicle images and HLS time-series remote sensing data. *Journal of Agricultural Big Data*, 2025, 7(2): 161-172.
- [16] Cai Z R, Liu Z Y, Kou L. Reliable UAV monitoring system using deep learning approaches. *IEEE Transactions on Reliability*, 2022, 71(2): 973-983.
- [17] Bouguettaya A, Zarzour H, Kechida A, et al. Deep learning techniques to classify agricultural crops through UAV imagery: A review. *Neural Computing and Applications*, 2022, 34(12): 9511-9536.
- [18] Mittal P, Singh R, Sharma A. Deep learning-based object detection in low-altitude UAV datasets: A survey. *Image and Vision Computing*, 2020, 104: 104046.
- [19] 黄睿茜,赵俊芳,霍治国,等. 深度学习技术在农业干旱监测预测及风险评估中的应用. *中国农业气象*, 2023, 44(10): 943-952.
- Huang R X, Zhao J F, Huo Z G, et al. Application of deep learning technology in monitoring, forecasting and risk assessment of agricultural drought. *Chinese Journal of Agrometeorology*, 2023, 44(10): 943-952.
- [20] 苑江浩,郑作军,初昌明,等. 2023 年黑龙江水稻产量预测无人机遥感图像数据集. *农业大数据学报*, 2024, 6(4): 546-551.
- Yuan J H, Zheng Z J, Chu C M, et al. Rice yield prediction UAV remote sensing image dataset of Heilongjiang province in 2023. *Journal of Agricultural Big Data*, 2024, 6(4): 546-551.
- [21] Osco L P, Junior J M, Ramos A P M, et al. A review on deep learning in UAV remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, 2021, 102: 102456.
- [22] Shahi T B, Xu C Y, Neupane A, et al. Recent advances in crop disease detection using UAV and deep learning techniques. *Remote Sensing*, 2023, 15(9): 2450.
- [23] Su J Y, Coombes M, Liu C J, et al. Machine learning-based crop drought mapping system by UAV remote sensing RGB imagery. *Unmanned Systems*, 2020, 8(1): 71-83.
- [24] Prodhon F A, Zhang J, Yao F, et al. Deep learning for monitoring agricultural drought in south Asia using remote sensing data. *Remote Sensing*, 2021, 13(9): 1715.
- [25] Yang X H, Gao F, Yuan H W, et al. Integrated UAV and satellite multi-spectral for agricultural drought monitoring of winter wheat in the seedling stage. *Sensors*, 2024, 24(17): 5715.
- [26] Liu C, Li H Y, Su A Y, et al. Identification and grading of maize drought on RGB images of UAV based on improved U-Net. *IEEE Geoscience and Remote Sensing Letters*, 2021, 18(2): 198-202.
- [27] 张淦,严海峰,胡根生,等. 基于深度学习语义分割和迁移学习策略的麦田倒伏面积识别方法. *智慧农业(中英文)*, 2023, 5(3): 75-85.
- Zhang G, Yan H F, Hu G S, et al. Identification method of wheat field lodging area based on deep learning semantic segmentation and transfer learning. *Smart Agriculture*, 2023, 5(3): 75-85.
- [28] Liang H, Zhou Y, Lu Y, et al. Evaluation of soybean drought tolerance using multimodal data from an unmanned aerial vehicle and machine learning. *Remote Sensing*, 2024, 16(11): 2043.
- [29] Niu S W, Nie Z G, Li G, et al. Early drought detection in maize using UAV images and YOLOv8+. *Drones*, 2024, 8(5): 170.
- [30] Zhou J, Zhou J F, Ye H, et al. Classification of soybean leaf wilting due to drought stress using UAV-based imagery. *Computers and Electronics in Agriculture*, 2020, 175: 105576.

引用本文: 王政锋,李莉,马瑞升,莫妘捷,匡昭敏. 甘蔗干旱等级识别的低空遥感分割模型研究[J]. *农业大数据学报*, 2026,8(3): 281-295. DOI: 10.19788/j.issn.2096-6369.000161.

CITE: WANG ZhengFeng, LI Li, MA RuiSheng, MO YunJie, KUANG ZhaoMin. Research on a Low-Altitude Remote Sensing Segmentation Model for Sugarcane Drought Level Identification[J]. *Journal of Agricultural Big Data*, 2026,8(3):281-295. DOI: 10.19788/j.issn.2096-6369.000161.

Research on a Low-Altitude Remote Sensing Segmentation Model for Sugarcane Drought Level Identification

WANG ZhengFeng¹, LI Li², MA RuiSheng³, MO YunJie⁴, KUANG ZhaoMin^{3*}

1. School of Computer Science and Engineering (School of Artificial Intelligence), Guilin University of Technology/Guangxi Key Laboratory of Embedded Technology and Intelligent Systems, Guilin 541006, Guangxi, China; 2. Guangxi Climate Center, Nanning 530022, China; 3. Guangxi Institute of Meteorological Sciences, Nanning 530022, China; 4. Guangxi Meteorological Technology Equipment Center, Nanning 530022, China

Abstract: To address the limitation of drought assessment and early warning methods relying primarily on single meteorological indicators in accurately reflecting sugarcane growth, this study constructs an intelligent method for identifying sugarcane drought levels by integrating low-altitude remote sensing imagery and a deep learning model. Low-altitude remote sensing imagery of healthy and drought-stressed sugarcane fields was collected in three typical planting areas. The Normalized Difference Vegetation Index (NDVI) was calculated and drought level labels were established based on expert interpretation. Based on the U-Net semantic segmentation framework, a residual network (ResNet-34) was introduced as the backbone, and weighted skip connections were used to enhance edge recognition capabilities, resulting in the CaneUNet-W model. Model performance was evaluated through regional cross-validation. Results showed that the model achieved average Intersection over Union (IoU), F1-score, and Kappa coefficient of 0.924, 0.960, and 0.912, respectively, for sugarcane fields identification, demonstrating high accuracy and generalization. The spatial distribution characteristics of the model's inference results were basically consistent with the visual interpretation trends of experts based on high-resolution imagery. The method presented in this paper can objectively reflect the remote sensing phenotypic variation of sugarcane canopy under drought stress, verifying its feasibility and effectiveness in intelligent identification and refined assessment of sugarcane drought conditions. However, due to the lack of synchronous ground-based measured data, future research will introduce physiological indicators such as soil moisture for quantitative calibration, thereby improving the disaster prevention and mitigation capabilities of sugarcane production.

Keywords: sugarcane; low-altitude remote sensing; deep learning; semantic segmentation; U-Net