doi:10.6041/j.issn.1000-1298.2026.09.028

面向玉米隐性洪涝检测的 DSA－DeepLab 语义分割模型

王春山[1,2]　国婧薇[1,2]　张立杰[2]　吴华瑞[3]　段立娟[4]　李久熙[2]

（1.河北农业大学信息科学与技术学院，保定 071001；2.农业遥感应用河北省工程研究中心，保定 071001；
3.国家农业信息化工程技术研究中心，北京 100097；4.北京工业大学计算机学院，北京 100124）

摘要：在全球气候变化背景下，极端气象事件频发，对农业生产构成严重威胁。东北地区作为中国玉米主产区，其玉米关键生育期与暴雨高发期重叠，导致洪涝灾害频发，从而给粮食安全带来严峻挑战。高分辨率遥感技术为灾情快速检测提供了有效手段，然而现有方法多基于光学与雷达影像的水体特征提取，依赖先验地物知识，在冠层未淹没的“隐性洪涝”区域识别方法与效果有限。针对上述问题，本研究基于 3 m Planet 与 4 m 国网遥感影像，构建了首套玉米隐性洪涝灾害高分辨率语义分割数据集，弥补了高质量样本不足的问题；并提出 DSA－DeepLab 语义分割模型，通过引入 DenseASPP 模块和嵌入融合选择性核注意力的自适应特征融合模块，从而有效提升小目标与复杂边界识别能力。实验结果表明，本文模型平均交并比与平均像素精度分别达到 80.70% 与 88.60%，较基线模型提升 1.63、1.67 个百分点，隐性洪涝正样本的 IoU 与召回率分别提升 2.72、3.38 个百分点，优于多种主流语义分割方法。此外，针对大尺寸影像输入导致的内存溢出问题，推理阶段采用重叠裁剪-边缘忽略策略，有效抑制了拼接伪影与边界误差。本研究实现了玉米隐性洪涝灾害的高精度自动化提取，可为灾情评估与农业保险定损提供可靠技术支撑。

关键词：玉米隐性洪涝灾害；农业灾害检测；语义分割；多尺度特征融合；高分辨率遥感

中图分类号：S126；S513　　**文献标识码**：A　　**文章编号**：1000-1298(2026)09-0299-11　　**OSID**：

DSA－DeepLab Semantic Segmentation Model for Hidden Waterlogging Detection in Maize

WANG Chunshan[1,2]　GUO Jingwei[1,2]　ZHANG Lijie[2]　WU Huarui[3]　DUAN Lijuan[4]　LI Jiuxi[2]

(1. *College of Information Science and Technology*, *Hebei Agricultural University*, *Baoding* 071001, *China*
2. *Engineering Research Center for Agricultural Remote Sensing Application of Hebei Province*, *Baoding* 071001, *China*
3. *National Engineering Research Center for Information Technology in Agriculture*, *Beijing* 100097, *China*
4. *College of Computer Science*, *Beijing University of Technology*, *Beijing* 100124, *China*)

Abstract: Against the backdrop of global climate change, the increasing frequency of extreme weather events poses serious threats to agricultural production. As a major maize-producing region in China, Northeast China faces the challenge that key growth stages of maize overlap with the period of frequent regional heavy rainfall, leading to recurrent waterlogging disasters that severely endanger grain security. High-resolution remote sensing technology offers an effective means for rapid disaster monitoring. However, existing methods predominantly rely on water feature extraction from optical and radar imagery, which depends on prior knowledge of surface features and shows limited effectiveness in identifying “implicit” waterlogging areas where the canopy is not submerged. This is particularly evident in the inadequate accuracy and boundary consistency for detecting small-scale affected areas. To address these issues, the first high-resolution semantic segmentation dataset for implicit maize waterlogging disasters was constructed based on 3 m Planet and 4 m State Grid remote sensing images, filling the gap in high-quality labeled data. Furthermore, a DSA－DeepLab semantic segmentation model was proposed, which incorporated a DenseASPP module and an adaptive feature fusion module embedded with selective kernel attention, thereby effectively enhancing the detection capability for small targets and complex boundaries.

收稿日期：2025－11－09　修回日期：2025－12－10

基金项目：国家自然科学基金项目(62472012)和北京市自然科学基金项目(L251052)

作者简介：王春山(1978—)，男，教授，博士，主要从事机器学习和遥感智能解译研究，E-mail：chunshan9701@163.com

通信作者：吴华瑞(1975—)，男，研究员，博士，主要从事农业大数据智能服务和农业信息化技术研究，E-mail：wuhr@nercita.org.cn

Experimental results demonstrated that the proposed model achieved mean intersection over union and mean pixel accuracy of 80.70% and 88.60%, respectively, representing improvements of 1.63 percentage points and 1.67 percentage points over the baseline model. Specifically, for implicit waterlogging, the IoU and recall rates were increased by 2.72 percentage points and 3.38 percentage points, respectively, outperforming that of several mainstream semantic segmentation methods. Additionally, to address the memory overflow issue caused by large-size image inputs during inference, an overlapping patch extraction-edge ignoring strategy was adopted, effectively suppressing stitching artifacts and boundary errors. This research achieved high-precision automated extraction of implicit maize waterlogging disasters, providing reliable technical support for disaster assessment and agricultural insurance claims.

Key words: hidden waterlogging in maize; agricultural disaster monitoring; semantic segmentation; multi-scale feature fusion; high spatial resolution remote sensing

0 引言

作为农业大国,我国玉米主产区长期面临洪涝灾害的威胁,极端降水引发的胁迫已成为制约玉米稳产、增产的关键逆境因子[1-2]。传统灾情检测主要依托人工实地勘察及基层灾情上报等方式,单点精度高,但难以实现快速响应与大范围动态检测[3]。遥感技术以其宏观、非接触的优势,已成为灾害信息实时获取的核心手段[4]。

在现有遥感检测技术体系中,阈值决策法是水体识别的典型方法。光学遥感通过水体与非水体的光谱特征差异,采用单波段[5]或多波段指数阈值法进行水体信息提取[6]。其中,多波段指数法通过构建改良的归一化差异水体指数(Modified normalized difference water index, MNDWI)[7]、增强水体指数(Enhanced water index, EWI)[8]和自动水体提取指数(Automated water extraction index, AWEI)[9]等增强水体信息,但易受云雾干扰限制应用。相比之下,微波遥感具有全天候优势,通过分析雷达后向散射系数在水体与非水体间的显著差异进行水体提取[10],其常用阈值分割方法包括双峰法[11]、最大类间方差法[12]和最大熵值法[13]等,但受微波散射机制物理特性约束,上述方法仅适用于典型水体的快速提取,难以有效识别作物冠层变化引起的细微散射特征差异。

传统机器学习方法如随机森林[14]、高斯混合模型[15]、支持向量机[16]等分类器,能够有效整合归一化植被指数(Normalized difference vegetation index, NDVI)等光谱特征以及纹理指数等空间特征,通过构建多源特征与受灾区域间的非线性关系以识别受灾区域。然而,其受限于特征工程的泛化能力以及大量标注数据的依赖,导致难以利用空间上下文信息,致使灾害边界识别模糊、限制精度。

深度学习技术的引入带来新突破,通过融合像素级光谱信息与空间结构特征,可实现智能感知与精准提取[17]。在无人机方面,通过深度融合卷积神经网络(Convolutional neural network, CNN)与区域增长算法,有效解决了洪水区域分割的技术难题,实现了洪涝范围的精准制图[18]。但受制于高成本和小范围检测特性,研究重点逐渐转向大范围遥感技术。KANG 等[19]基于光学影像提出的 MSCENet(Multi-scale context extractor network)网络,通过集成多尺度编码器与创新的上下文提取模块,显著提升了水体边界识别精度;文献[20]通过融合水指数特征与深度卷积神经网络进一步优化了洪水识别效果。在合成孔径雷达领域,利用卷积神经网络模型基于 Sentinel-1 数据实现了淹没像素的准确识别,极大提升了实时数据处理效率[21];LV 等[22]改进的 DeepLabv3+网络则展现出优异的特征提取能力,进一步推动了洪涝区域的精细化分割。

尽管深度学习推进了遥感识别技术,但主要聚焦于明显水体光谱特征的淹没区。在实际农业生产中,存在另一种更为隐蔽却危害严重的洪涝类型——隐性洪涝。是指在地表积水尚未完全覆盖作物冠层,但已处于过饱和状态,可引发玉米冠层黄化、长势迟滞等生理胁迫。由于缺乏直接水体特征,无法依赖传统水体指数或显性淹没检测算法,需通过作物自身的生理光谱异常实现间接检测。综上所述,玉米洪涝遥感检测仍面临两大问题:数据瓶颈,缺乏高质量、细粒度标注数据集;受小尺度受灾区域低信噪比与空间碎片化特性的影响,易导致局部漏检、边界模糊。

针对上述问题,本文提出一种 DSA-DeepLab 模型实现高精度空间分布检测,并构建面向玉米隐性洪涝灾害的高分辨率语义分割数据集。提出一种融合选择性核注意力的自适应特征融合模块,通过动态卷积核选择机制实现高阶语义特征与低层细节特征的自适应加权融合,并自适应调整感受野,以减

少相邻受灾斑块的误合与边界粘连。同时引入 DenseASPP，通过密集连接多尺度空洞卷积，实现跨尺度上下文信息的逐步积累与深度融合，以提升对从大型积水区域到零星积水点等极端多尺度目标的特征捕获能力。

1　研究区域与数据

1.1　研究区域概述

为提升玉米隐性洪涝灾害检测模型的泛化能力，本研究选取黑龙江省内 4 个主要农业地市作为研究区（图 1），包括大庆市、牡丹江市、鸡西市与鹤岗市。具体地理位置坐标分别为：大庆市 45°46′ ~ 47°28′N，123°45′ ~ 125°12′E；牡丹江市 43°24′ ~ 45°59′N，128°02′ ~ 131°18′E；鸡西市 44°51′ ~ 46°36′N，130°24′ ~ 133°56′E；鹤岗市 47°03′ ~ 48°21′N，129°40′ ~ 132°31′E。四地覆盖松嫩平原与小兴安岭山前丘陵等黑龙江省核心农业生态区。在地形地貌、气候特征及洪涝致灾模式上存在显著差异，形成平原积涝、山间汇流及丘陵低洼滞水等多类型隐性洪涝场景。区域间灾害成因与环境特征的多样性，有助于构建具有代表性的训练样本，为模型在复杂实际条件下的鲁棒性验证提供可靠基础。

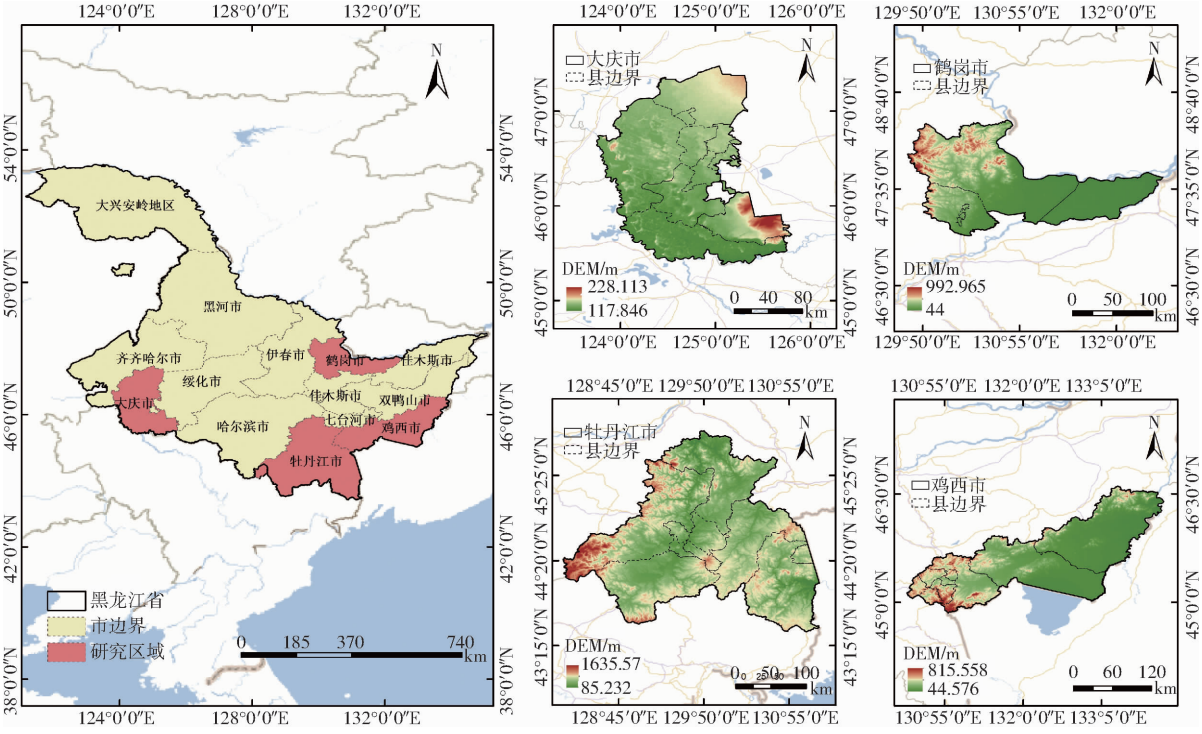

图 1　研究区域分布图

Fig. 1　Distribution map of study areas

1.2　数据预处理和样本构建

利用 2022—2024 年洪涝灾害发生后 8 月中下旬至 9 月初期间获取的高分辨率遥感影像构建数据集，该时间段正值玉米生长关键期，受灾害影响，玉米植株已出现显著生理变化，主要表现为植被黄化现象。遥感影像为 Planet 和国网卫星数据，其空间分辨率分别为 3 m 和 4 m，二者均具备红、绿、蓝及近红外 4 个波段，充分满足作物生长状况分析需求，且不同分辨率数据有助于模型学习更丰富且多层次的特征表达。预处理采用软件 ENVI 5.6，依次执行了辐射校正、大气校正等关键步骤，确保遥感数据的定量分析准确性和空间一致性，最终获得 54 幅高质量遥感图像。

在标注流程中，首先基于多光谱影像通过目视解译与实地样本核验，精准勾画玉米种植区域矢量边界。在此基础上，依据先验知识与植被光谱特征设定自适应阈值，对玉米受灾与否进行初步划分，得到初始受灾分布图。为进一步保证标注数据的可靠性，在研究区内选取具有代表性的典型样本区开展地面实地调查，并将调查结果与初步划分成果进行逐像元比对，完成针对性的校验与修正，形成最终的受灾分布图，并构建 2 类标签体系：正常玉米区域（value 为 0）和受灾玉米区域（value 为 1）。最终，将经过严格校核的矢量数据栅格化并与多光谱影像高精度配准，生成满足语义分割模型训练需求的标准化标签图层，制作流程如图 2 所示。

为保证模型输入的一致性与有效性，基于玉米分布图（图 3）对玉米种植区影像进行提取。随后，将影像及其对应的标签统一裁剪为 512 像素 × 512 像素，构建图像－标签配对数据集，共获得

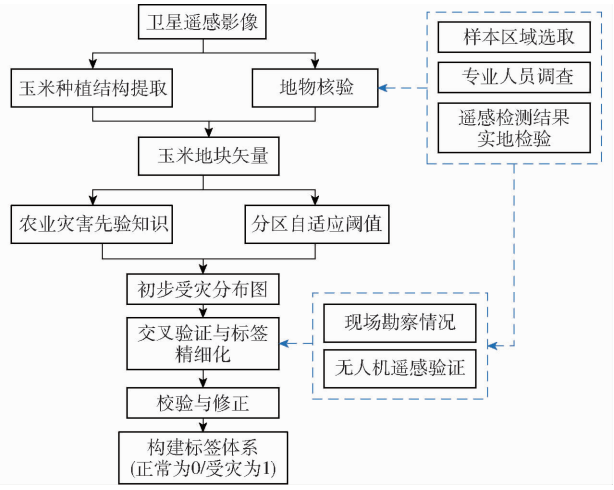

图 2 标签数据制作流程图

Fig. 2 Tag data creation flowchart

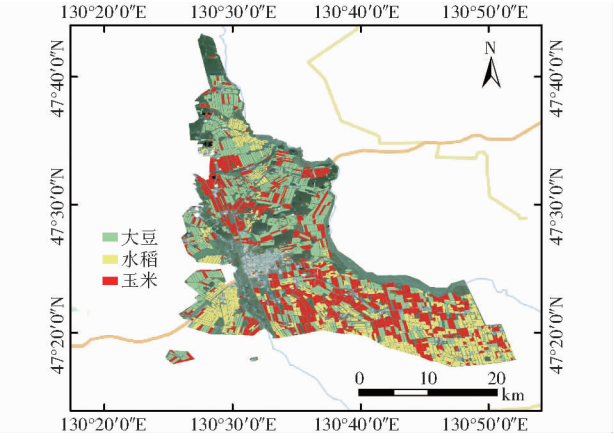

图 3 玉米分布示意图

Fig. 3 Distribution of maize planting areas

13 008 组有效样本。为保障模型训练与评估的科学性,按比例 7∶2∶1将数据集划分为训练集、验证集和测试集,分别用于参数训练、超参数调整与泛化性能评估。采用多维度数据增强策略,包括随机缩放、水平翻转、亮度扰动、对比度增强及随机裁剪等操作,进一步增强模型对复杂遥感场景的适应能力,提升模型鲁棒性。

2 研究方法

2.1 DeepLabv3 + 网络

DeepLabv3 + 作为遥感图像语义分割领域的经典模型,其通过在 DeepLabv3 基础上引入解码器结构,实现了低层边缘特征与高层语义信息的有效融合。编码部分由骨干特征提取网络与空间金字塔池化(Atrous spatial pyramid pooling, ASPP)模块组成,骨干网络通常采用 Xception、ResNet 或 MobileNet 等主流架构,用于提取高层语义特征;ASPP 则通过多尺度空洞卷积聚合不同感受野的上下文信息。解码部分进一步融合低层细节与高层语义特征,并通过双线性插值上采样,实现精确的像素级预测。此外,DeepLabv3 + 采用深度可分离卷积(Depthwise separable convolution, DSC)和空洞卷积(Atrous convolution, AC)来减少计算量并扩大感受野,使其在保持高效的同时增强多尺度特征提取能力。

2.2 DSA - DeepLab 网络

针对隐性洪涝灾害遥感影像中存在的大范围积水与局部破坏特征共存、边界模糊等挑战,本文在 DeepLabv3 + 模型的基础上设计了 DSA - DeepLab 网络(图 4),实现了对玉米隐性洪涝灾害更精准分割。将原始 Xception 替换为更简洁的 MobileNetv2 作为主干网络,该网络通过倒置残差结构,在保持特征提取能力的同时降低了模型复杂度,为后续密集多尺度特征提取奠定了高效计算基础。在编码阶段,引入密集空洞空间金字塔池化(Dense atrous

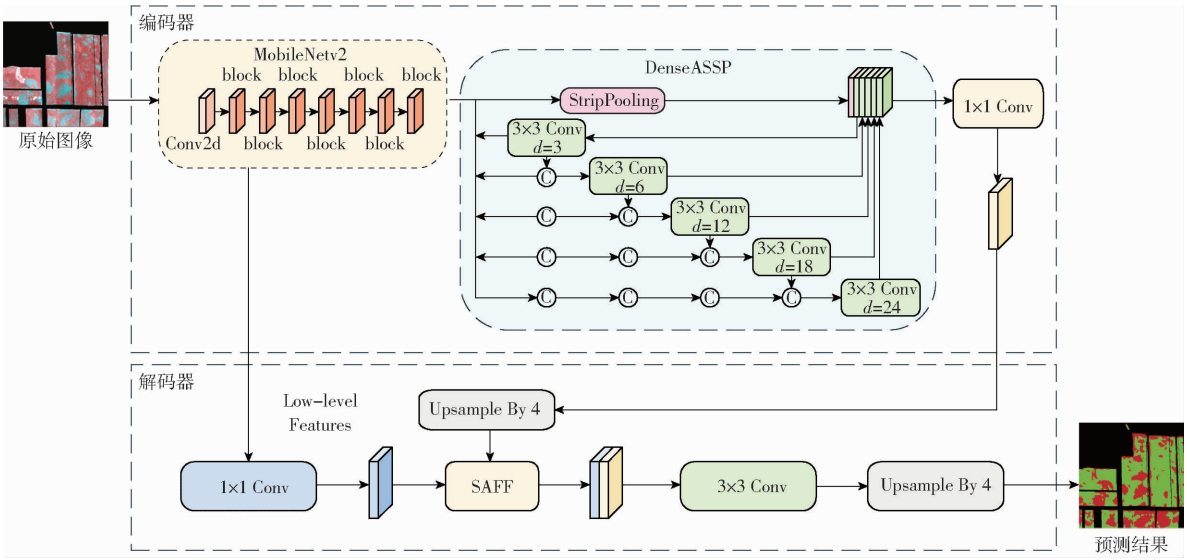

图 4 DSA - DeepLab 网络模型结构图

Fig. 4 Schematic of DSA - DeepLab model structure

spatial pyramid pooling，DenseASPP）模块以增强多尺度上下文感知。该模块通过密集连接方式堆叠不同空洞率的卷积层，实现了跨尺度特征的充分复用与渐进式融合，使得能够捕获从大型连片积水区到零星分布积水点多尺度目标的关键特征，避免了原 ASPP 模块中可能存在的特征信息割裂与遗漏问题。在解码阶段，设计了融合 SK（Selective kernel）注意力机制的改进型 AFF（Adaptive feature fusion）特征融合模块，替代原有的简单拼接操作，该模块通过自适应调整多尺度特征的融合权重，以优选不同卷积核尺度下的关键信息，从而缓解相邻受灾区域在预测结果中出现的错误合并与边界粘连现象。

2.3　SAFF 模块

DeepLabv3 + 原始网络在融合编码器生成的多级特征图时，采用简单的通道拼接（Concat）方式，并依赖后续卷积层对融合后的特征进行压缩与整合。然而，这种固定权重的融合策略难以根据特征重要性进行自适应调整，可能导致冗余信息的引入，且对于不同尺度目标的敏感性有限。

为解决此任务中边界粘连显著等问题，设计了选择性自适应特征融合模块（Selective adaptive feature fusion，SAFF），其结构如图 5 所示。该模块替代了解码器中原有的 Concat 融合方式，通过多尺度特征选择与动态权重校准机制，提升了对隐性洪涝边界特征的判别能力。SAFF 模块基于 AFF 框架构建[23]，首先通过初始集成步骤将低层与高层特征进行初步融合，随后通过 MS－CAM（Multi-scale channel attention module）注意力建模全局与局部的特征相关性，并生成融合权重 M。在融合阶段，采用低层与高层特征之间动态分配权重，而非依赖固定融合比例输出，其中特征图 Z 生成公式为

$$Z = M(X \oplus Y) \otimes X + (1 - M(X \oplus Y)) \otimes Y \quad (1)$$

式中　$\oplus$——初始集成操作符

$\otimes$——元素级乘法操作符

X——低层特征

Y——高层特征

为进一步增强多尺度表达能力，在 MS－CAM 前端引入了 SK 注意力模块[24]。通过并行多分支卷积结构-采用不同尺寸的卷积核对输入特征进行多尺度特征提取，并自适应地调整各分支的融合权重，使得后续能够基于更丰富的上下文信息计算注意力权重，从而更精准地融合高低级特征并且有效缓解固定卷积核的局限性。首先对输入的特征图 X 进行分组卷积，卷积核大小分别为 3×3 和 5×5，将两个分支结果得到特征图 U_1 和 U_2 融合得到 U，之后使用全局平均池化生成特征向量，计算式为

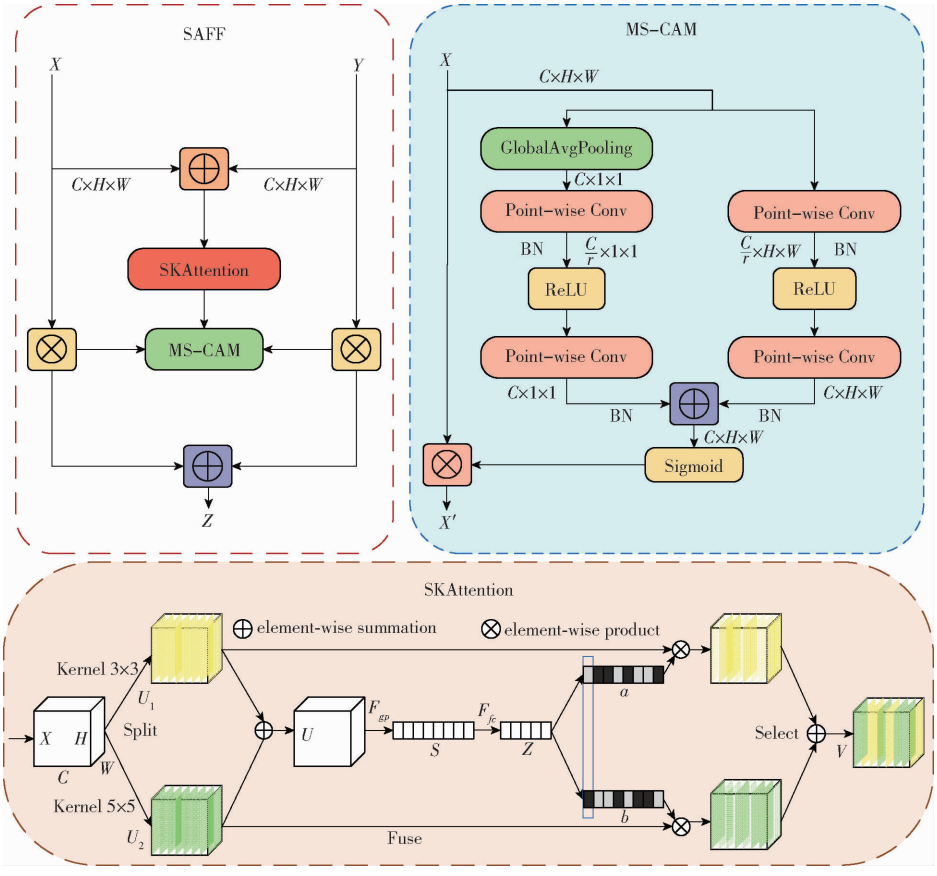

图 5　SAFF 模块

Fig. 5　SAFF module

$$S_C = \boldsymbol{F}_{gp}(U_C) = \frac{1}{HW}\sum_{i=1}^{H}\sum_{j=1}^{W} U_C(i,j) \tag{2}$$

式中 S_C——第 C 个通道输出

$\boldsymbol{F}_{gp}$——全局平均池化函数

H——特征图高度

W——特征图宽度

$U_C(i,j)$——第 C 个通道的输入特征

S_C 经过全连接层进行降维操作得到 Z，计算式为

$$Z = \boldsymbol{F}_{fc}(S) = \delta(\beta(\boldsymbol{W}_S)) \tag{3}$$

式中 $\boldsymbol{F}_{fc}$——全连接操作函数

δ——ReLU 激活函数

β——批规范化

$\boldsymbol{W}_S$——全连接层的权重参数矩阵

最终通过 Softmax 得到各个特征尺度的权重，并在 Select 中将其与卷积后的结果加权求和。

2.4 DenseASPP 模块

针对玉米隐性洪涝灾害检测中大面积积水与局部积水共存的多尺度问题，原 DeepLabv3 + 中的 ASPP 模块虽通过并行空洞卷积捕捉多尺度上下文，但其各分支相互独立，缺乏跨尺度语义交互，难以有效关联大范围积水区域与细小水渍的关联特征。为突破这一瓶颈，本文以 DenseASPP 模块[25]替代原始 ASPP 结构。DenseASPP 通过密集连接方式串联多个空洞卷积层，使每层的输入均包含前面所有层的输出特征与原始特征图的拼接，从而实现了跨尺度的语义信息融合与传递，增强了特征复用能力以提升模型对多尺度目标的识别能力，其结构如图 6 所示。其中每层空洞卷积层的输入都是前面所有卷积层的输出和输入的 feature map 的拼接，空洞卷积的

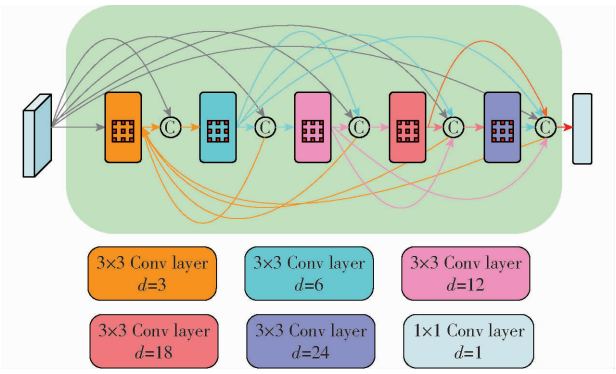

图 6 DenseASPP 模块

Fig. 6 DenseASPP module

卷积核大小 K_d 计算公式为

$$K_d = K + (K-1)(d-1) \tag{4}$$

式中 K——原始卷积核大小

d——空洞率

2 个卷积叠加后的卷积核大小 K_{eff} 计算式为

$$K_{\text{eff}} = K_1 + K_2 - 1 \tag{5}$$

DenseASPP 引入条形池化（Strip pooling，SP）[26]，作为辅助特征增强手段，其结构如图 7 所示。通过在水平方向与垂直方向构建长条形池化核，能够有效聚合目标在单一方向上的长程依赖信息，实现多尺度上下文信息与方向性特征的联合建模。条形池化是标准平均池化的变体，标准平均池化可以表示为

$$y_{i_o,j_o} = \frac{1}{hw}\sum_{0\leqslant i<h}\sum_{0\leqslant j<w} \boldsymbol{x}_{i_o h+i, j_o w+j}$$
$$(\boldsymbol{x}_{i_o h+i, j_o w+j} \in \mathbf{R}^{H\times W}) \tag{6}$$

式中 h——输入特征图高

w——输入特征图宽

$\boldsymbol{x}_{i_o h+i, j_o w+j}$——二维特征张量

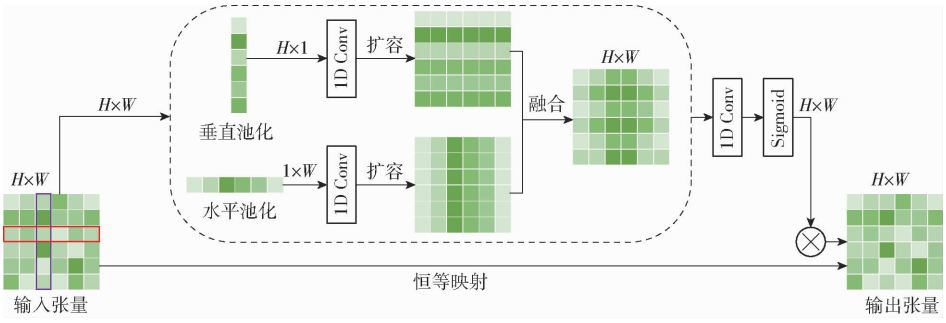

图 7 Strip Pooling 模块

Fig. 7 Strip Pooling module

Strip Pooling 分别在水平与垂直方向上进行池化，其池化核的尺寸为 $H \times W$，在 2 个方向的运算公式分别定义为

$$y_i^h = \frac{1}{W}\sum_{0\leqslant j<W} x_{i,j} \tag{7}$$

$$y_j^v = \frac{1}{H}\sum_{0\leqslant i<H} x_{i,j} \tag{8}$$

其中 y_i^h 和 y_j^v 分别表示水平方向的条形池化输出（$y^h \in \mathbf{R}^H$）和垂直方向条形池化输出（$y^v \in \mathbf{R}^W$）。

2.5　损失函数

在本研究的数据集中，受灾玉米样本与非受灾玉米样本之间存在不平衡现象。在此情形下，若直接采用传统的交叉熵损失函数（Cross-entropy loss，CE_Loss）进行模型训练，易导致对受灾样本的识别能力不足。为缓解类别不均衡带来的训练偏置，本实验引入 Focal_Loss 损失函数，在训练过程中降低易分类样本对总损失的贡献，同时增强难分类样本的影响，从而引导模型更加关注后者。Focal_Loss 可以表示为

$$F_L = -\alpha_t(1-p_t)^{\gamma}\ln(p_t) \tag{9}$$

式中　p_t——正确类的预测概率

α_t——类别平衡系数

γ——焦点调节因子

F_L——Focal_Loss 损失函数

采用基于类别频率的逆频率加权策略来确定 α，对负、正样本分别赋予权重 $\alpha=[0.25,0.75]$，为少数类分配更高的损失权重，并将焦点调节因子设置为 2，以聚焦于难分类样本，使得提升模型在受灾玉米样本上的识别能力。

2.6　实验环境和配置

本实验所用 CPU 型号为 Intel Xeon Silver 4210R @ 2.40 GHz，GPU 型号为 NVIDIA RTX A5000，软件配置为 64 位 Ubuntu 20.04.6 LTS 操作系统，CUDA 版本 12.1，深度学习框架 Pytorch 版本 2.4.1。训练迭代次数为 100 次，批次大小设置为 16，优化器选用 Adam，初始学习率设为 1×10^{-4}。

2.7　模型评估指标

为全面评估模型性能，在对比实验中采用平均交并比（Mean intersection over union，mIoU）、平均像素精度（Mean pixel accuracy，mPA）、宏平均 F1 值（Macro-F1 score，mF1）、召回率（Recall）作为评估指标。其中平均交并比反映模型整体分割精度；平均像素精度衡量模型的平均分类能力；宏平均 F1 值有效克服类别不平衡带来的评估偏差；召回率则直接体现模型对隐性洪涝区域的查全能力。

在消融实验中，为精确量化各模块对隐性洪涝的提取能力，继而采用精确率（Precision）、F1 值（F1 score）、IoU 及召回率 4 个评价指标。其中精确率描述预测可信度；F1 值反映精确率与召回率的平衡表现；IoU 为预测区域和实际区域的重叠率。

3　实验分析与讨论

3.1　不同模型之间的提取结果比较

为客观评估本研究所提出 DSA－DeepLab 模型的有效性，将其与 Unet[27]、Segformer[28]、PSPNet[29]、HRNet[30]、Unet++[31]等主流语义分割模型进行了对比。表 1 结果显示，不同模型在该任务中的性能表现出显著差异。具体而言，PSPNet 与 Segformer 模型适应性较弱，其平均交并比分别为 68.27% 和 67.49%。Unet++、HRNet、DeepLabv3+ 与 Unet 的结果较为接近，其中 Unet 和 DeepLabv3+ 的平均交并比均接近 79%，表现优于前两者。在众多模型中，本文提出方法的多个关键评价指标均取得了最优值，平均交并比和平均像素精度达到 80.70% 和 88.60%，较基线模型分别提升 1.63、1.67 个百分点，同时，隐性洪涝（正样本）的召回率达到 80.71%，有效缓解了漏检问题。

表 1　对比实验结果

Tab.1　Comparative experimental results　%

模型	平均交并比	平均像素精度	宏平均 F1 值	召回率
PSPNet	68.27	82.17	79.75	73.46
Segformer	67.49	75.40	78.78	54.04
Unet++	73.96	81.99	82.70	67.50
HRNet	74.87	85.79	84.75	77.47
DeepLabv3+	79.07	86.93	87.69	77.33
Unet	79.47	86.47	88.00	75.92
本文模型	80.70	88.60	88.81	80.71

图 8 展示了不同模型在测试集上的预测结果。图中红色与绿色区域分别为受灾与非受灾区域，黄色矩形框则高亮显示了模型间差异最显著的局部。可以观察到：①小尺度目标完整性。面对零星积水点与狭长渍涝带等小尺度目标识别上，Unet++ 与 Segformer 等模型普遍存在漏检，导致预测结果断裂、不连续；相比之下，本文模型凭借增强的多尺度特征融合机制，展现出更优异的小目标结构保持能力，显著减少了局部漏检现象。②边界分割精确度。在受灾与非受灾区域的过渡地带，多数对比模型预测的边界呈现粗糙与粘连。本文模型通过引入 SAFF 模块，实现了对边缘特征的动态校准，从而获得边界更加清晰、连续，更贴近真实标注。③大范围区域一致性。在识别连片淹没区时，部分基线模型出现明显的误分类噪声，无法准确还原实际灾情范围；本研究通过 DenseASPP 模块强化了全局上下文感知，抑制了误分现象，提升了整体区域识别的空间一致性。综上表明，本文模型在区域完整性、边界准确性与大范围识别可靠性方面共同验证了其在隐性洪涝场景下的有效性与优越性。

3.2　消融实验

为验证各改进模块的有效性，本研究设计了控制变量消融实验。鉴于隐性洪涝区域是本研究的核

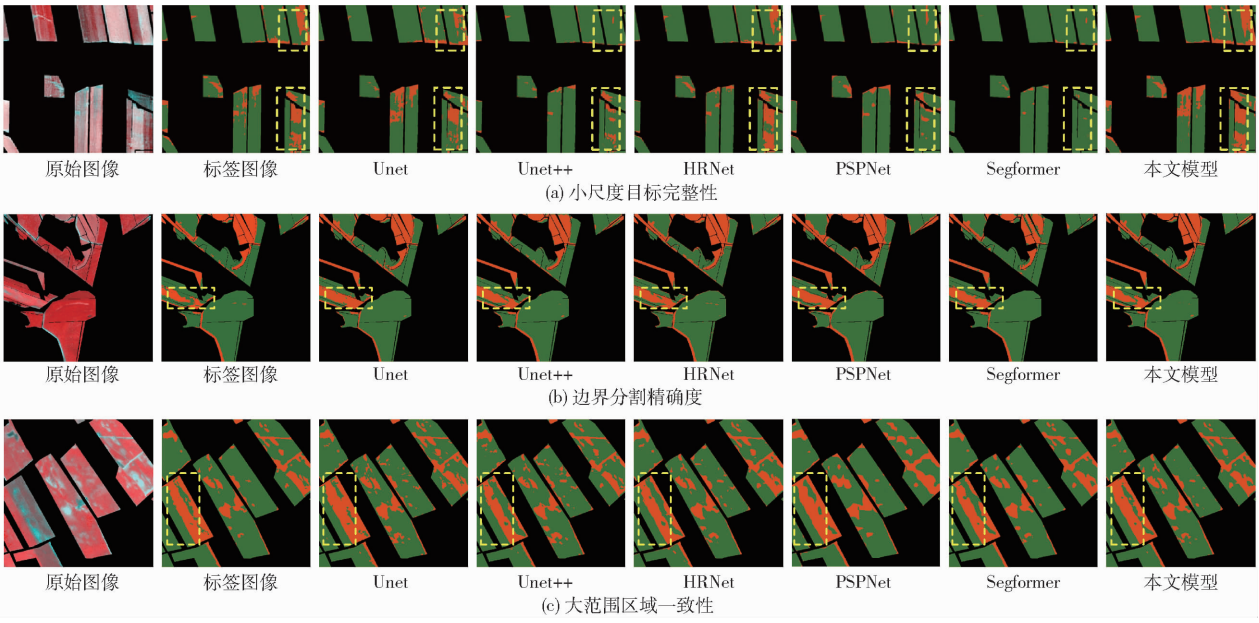

图 8 不同模型预测结果对比

Fig. 8 Comparison of prediction results among different models

心目标,消融实验的评价指标(IoU、召回率、精确率和 F1 值)均聚焦于正样本,旨在精确量化各模块在关键类别上的性能贡献。同时,为与整体评估体系保持一致,还补充报告平均交并比,用于衡量模型的全局分割性能。实验以 DeepLabv3 + 为基准网络,首先在基准网络基础上将解码器的 Concat 通道拼接操作替换为 AFF 模块,接着在 AFF 中引入 SK 注意力机制,构成完整的 SAFF 模块;最后将编码器的 ASPP 模块替换为 DenseASPP,得到 DSA - DeepLab 模型。

表 2 结果表明,随着各模块的逐步引入,IoU、F1 值及平均交并比呈现持续提升趋势,最终在实验 4 取得最优表现(IoU 为 68.45%,F1 值为 81.27%,平均交并比为 80.70%)。其中,AFF 的引入(实验 2)使得召回率提升 3.60 个百分点,表明其增强了模型对受灾区域的敏感度;SK 注意力的加入(实验 3)进一步优化了 IoU 与召回率,显示出多尺度特征选择的有效性;而 DenseASPP 的引入(实验 4)使得精确率提高 1.94 个百分点,平衡模型的整体性能的同时,IoU 与召回率分别提高 2.72、3.38 个百分点。

表 2 消融实验结果

Tab. 2 Ablation experimental results %

实验序号	AFF	SK	DenseASPP	IoU	精确率	召回率	F1 值	平均交并比
1	×	×	×	65.73	81.42	77.33	79.32	79.07
2	√	×	×	66.76	79.32	80.93	80.07	79.57
3	√	√	×	67.57	79.90	81.40	80.65	80.08
4	√	√	√	68.45	81.84	80.71	81.27	80.70

注:√表示使用该模块,×表示不使用该模块。

由图 9 定性结果进一步印证了上述结论。在基线模型上逐步引入 AFF 与 SK 模块后,洪涝灾害区域的识别逐渐趋于完整:小尺度受灾区域的漏检现象得到有效缓解(图 9a),中大尺度区域的识别也逐步覆盖完整(图 9b),IoU、召回率以及 F1 值均有显著提升。然而,SAFF 模块的引入也使模型对潜在灾区的响应过于敏感,从而带来一定的冗余标签,导致精确率略有下降。进一步加入 DenseASPP 利用其强大的多尺度上下文融合能力,为模型提供了全局语义信息来验证这些预测,有效抑制了误检(图 9c)。最终实验 4 在综合指标上取得最优表现。

3.3 大尺寸图像的预测方法与实现

高分辨率影像的全图直接输入在深度学习中常因显存限制而难以实现。通常将整幅影像裁剪为子图分别预测,再拼接重建为完整分类结果。但此类方法在子图边界区域因上下文信息缺失易导致预测精确度下降,进而在拼接后产生明显的接缝伪影。为此,本文引入“重叠裁剪-边缘忽略”的预测融合策略[32]。在裁剪阶段设置相邻子图重叠,以增强边界像素的上下文,实际裁剪图像预测的结果为 A,进行拼接的结果为 a,a 占 A 的区域百分比为 n,相邻裁剪图像的重叠比例为 $1-\sqrt{n}$;在拼接阶段仅保留各子图像中心区域的预测结果,舍弃边缘部分的低置信度预测值,从而抑制因局部信息缺失所引起的分类误差,减轻拼接痕迹,提升最终分类图的整体平滑性与精度。

本文对比了规则网格裁剪与所提出的重叠-忽略策略(图 10)。在规则网格裁剪模式下,子图边缘

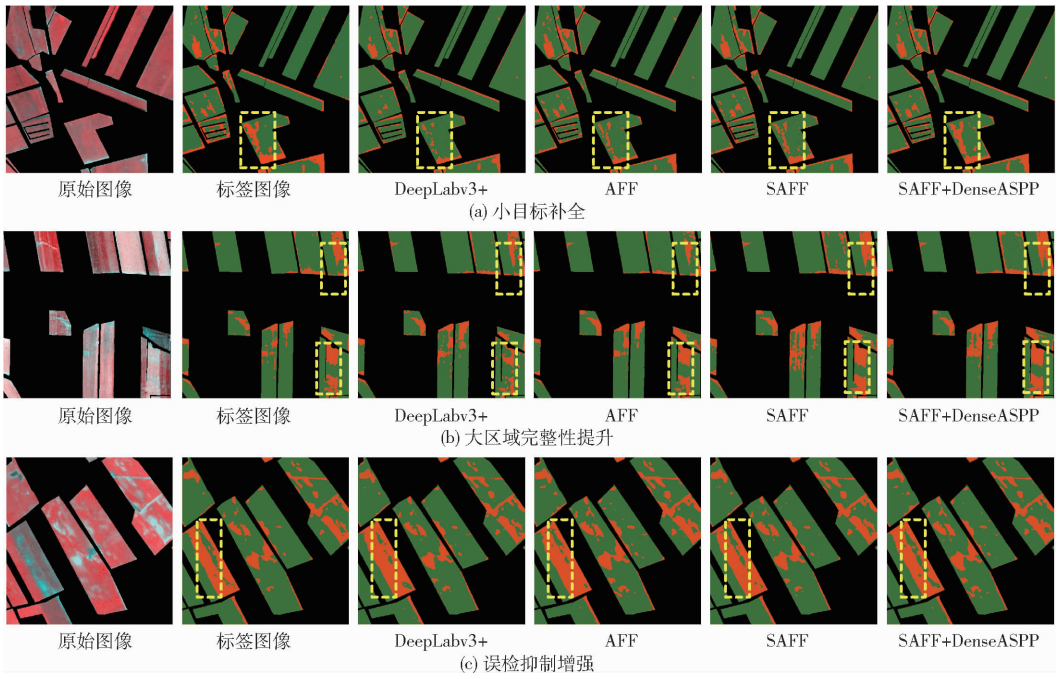

图 9　消融实验结果对比

Fig. 9　Comparison of ablation experiment results

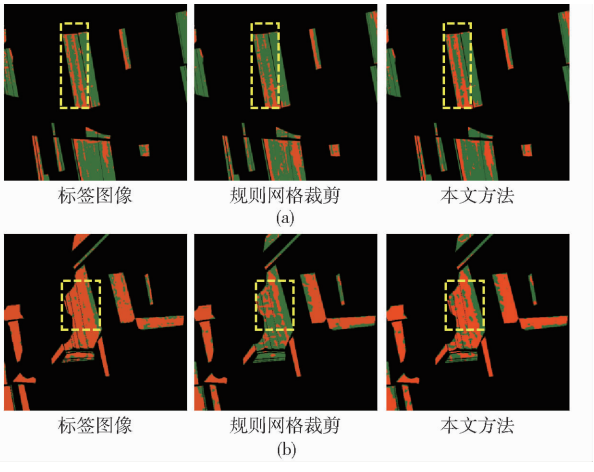

图 10　不同预测方法区域结果图

Fig. 10　Regional result maps of different prediction methods

由于感受野受限而无法获得充分的空间上下文，导致语义信息表达不完整，使该区域的分类精度呈现显著下降，如图 10a 所示。局部性误差在空间域中不断累积并跨块传播，最终在全图尺度上形成规则的网格状伪影，严重破坏地物边界的空间连续性与分类图斑的结构完整性，如图 10b 所示。图 11 展示了从原始影像到最终输出结果的可视化，用于直观说明模型的最终效果。

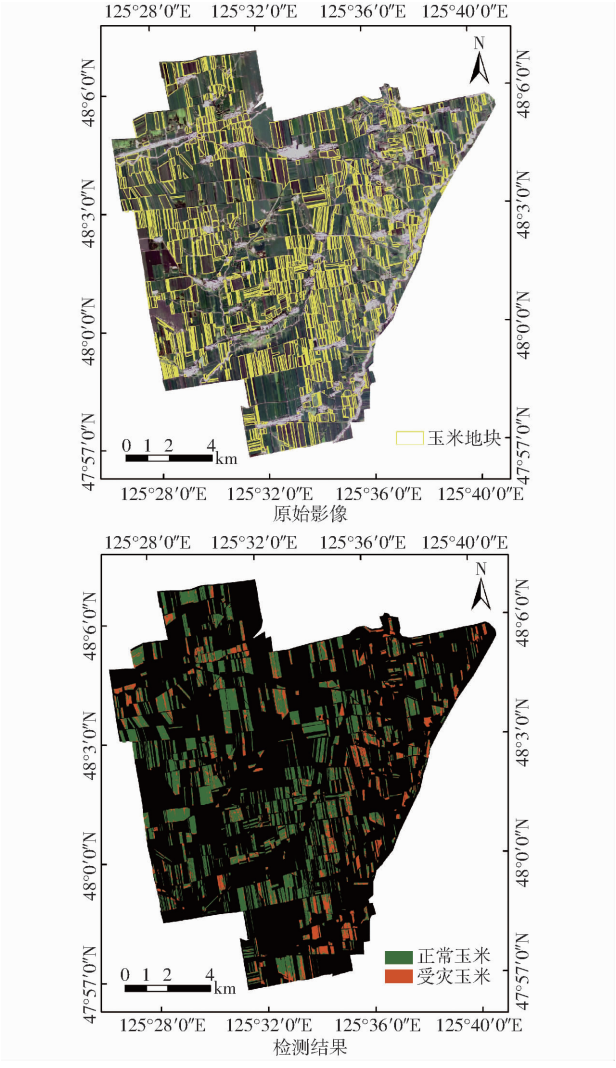

图 11　检测结果可视图

Fig. 11　Detection results visualization

4　结论

(1)为应对玉米隐性洪涝灾害精细化遥感监测的迫切需求，本研究提出了一种改进型 DSA－DeepLab 语义分割模型。该模型在编码部分引入 DenseASPP 模块，通过密集连接的空洞卷积层强化

了对从大型淹没区到零星积水点等极端多尺度目标的上下文信息捕获能力;在解码端设计了融合选择性核注意力的自适应特征融合模块,实现了高阶语义与低层细节的自适应、动态融合,提升了对灾害边界分割的准确性与空间连续性。

(2)系统性实验结果表明,本文所提模型在玉米隐性洪涝灾害提取任务中表现优异,其平均交并比、平均像素精度、宏平均 F1 值和召回率分别达到 80.70%、88.60%、88.81% 和 80.71%,综合性能优于 Unet、HRNet 等主流模型。相较于 DeepLabv3 + 基线模型,本方法平均交并比和平均像素精度分别提升了 1.63、1.67 个百分点,其中受灾区域的识别效果提升尤为显著,IoU 和召回率分别提高了 2.72、3.38 个百分点。针对大尺寸遥感影像的推理内存限制问题,采用的"重叠裁剪-边缘忽略"策略有效保障了边界区域的预测质量,显著减轻了规则网格拼接带来的伪影,最终生成了空间一致性高、细节保持好的全景灾害制图结果。

参 考 文 献

[1] CHEN H, LIANG Q, LIANG Z, et al. Remote-sensing disturbance detection index to identify spatio-temporal varying flood impact on crop production[J]. Agricultural and Forest Meteorology, 2019, 269: 180 - 191.

[2] LINDSEY A J, ORTEZ O A, THOMISON P R, et al. Severe storm damage and short-term weather stresses on corn: a review [J]. Crop Science, 2024, 64(3): 1129 - 1166.

[3] THOMAS M, TELLMAN E, OSGOOD D E, et al. A framework to assess remote sensing algorithms for satellite-based flood index insurance[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2023, 16: 2589 - 2604.

[4] 沈瑜,王海龙,苑玉彬,等. 基于改进 linknet 的寒旱区遥感图像河流识别方法[J]. 农业机械学报, 2022, 53(7): 217 - 225.
SHEN Yu, WANG Hailong, YUAN Yubin, et al. Recognition of rivers in remote sensing images in cold and arid regions based on improved linknet[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(7): 217 - 225. (in Chinese)

[5] BIJEESH T V, NARASIMHAMURTHY K N. Surface water detection and delineation using remote sensing images: a review of methods and algorithms[J]. Sustainable Water Resources Management, 2020, 6(4): 68.

[6] 赵文举,李聪聪,马宏,等. 基于 Sentinel - 2 超分辨率影像的干旱区水体提取方法[J]. 农业机械学报, 2023, 54(10): 316 - 328.
ZHAO Wenju, LI Congcong, MA Hong, et al. Water body extraction method in arid area based on Sentinel - 2 super-resolution images[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(10): 316 - 328. (in Chinese)

[7] RASHID M B. Monitoring of drainage system and waterlogging area in the human-induced ganges-brahmaputra tidal delta plain of bangladesh using mndwi index[J]. Heliyon, 2023, 9(6): e17412.

[8] 赵文举,谢振东,徐文,等. 基于 Landsat 的黑河流域水体识别方法与时空演变[J]. 农业机械学报, 2025, 56(8): 152 - 162.
ZHAO Wenju, XIE Zhendong, XU Wen, et al. Identification method and spatio-temporal evolution of surface water body in Heihe river basin based on Landsat imagery[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(8): 152 - 162. (in Chinese)

[9] FEYISA G L, MEILBY H, FENSHOLT R, et al. Automated water extraction index: a new technique for surface water mapping using landsat imagery[J]. Remote Sensing of Environment, 2014, 140: 23 - 35.

[10] HOSSEINI M, KERNER H R, SAHAJPAL R, et al. Evaluating the impact of the 2020 iowa derecho on corn and soybean fields using synthetic aperture radar[J]. Remote Sensing, 2020, 12(23): 3878.

[11] DONG Z, WANG G, AMANKWAH S O Y, et al. Monitoring the summer flooding in the poyang lake area of China in 2020 based on Sentinel - 1 data and multiple convolutional neural networks[J]. International Journal of Applied Earth Observation and Geoinformation, 2021, 102: 102400.

[12] LI N, LV X, XU S, et al. An improved water surface images segmentation algorithm based on the Otsu method[J]. Journal of Circuits, Systems and Computers, 2020, 29(15): 2050251.

[13] LI W, ZHANG W, LI Z, et al. A new method for surface water extraction using multi-temporal Landsat 8 images based on maximum entropy model[J]. European Journal of Remote Sensing, 2022, 55(1): 303 - 312.

[14] SORIA-RUIZ J, FERNANDEZ-ORDOÑEZ Y M, AMBROSIO-AMBROSIO J P, et al. Flooded extent and depth analysis using optical and sar remote sensing with machine learning algorithms[J]. Atmosphere, 2022, 13(11): 1852.

[15] GUAN H, HUANG J, LI L, et al. Improved Gaussian mixture model to map the flooded crops of VV and VH polarization data [J]. Remote Sensing of Environment, 2023, 295: 113714.

[16] FARHADI H, ESMAEILY A, NAJAFZADEH M. Flood monitoring by integration of remote sensing technique and multi-criteria decision making method[J]. Computers & Geosciences, 2022, 160: 105045.

[17] RAHMAN M S, DI L. A systematic review on case studies of remote-sensing-based flood crop loss assessment[J]. Agriculture,

2020,10(4):131.

[18] HASHEMI-BENI L,GEBREHIWOT A A. Flood extent mapping: an integrated method using deep learning and region growing using UAV optical data[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2021,14: 2127－2135.

[19] KANG J,GUAN H,PENG D,et al. Multi-scale context extractor network for water-body extraction from high-resolution optical remotely sensed images[J]. International Journal of Applied Earth Observation and Geoinformation, 2021,103:102499.

[20] JAIN P, SCHOEN-PHELAN B, ROSS R. Automatic flood detection in Sentinel-2 images using deep convolutional neural networks[C]// Proceedings of the 35th Annual ACM Symposium on Applied Computing, 2020.

[21] NEMNI E, BULLOCK J, BELABBES S, et al. Fully convolutional neural network for rapid flood segmentation in synthetic aperture radar imagery[J]. Remote Sensing, 2020,12(16):2532.

[22] LV S,MENG L,EDWING D,et al. High-performance segmentation for flood mapping of HiSea-1 SAR remote sensing images [J]. Remote Sensing, 2022,14(21):5504.

[23] DAI Y,GIESEKE F,OEHMCKE S,et al. Attentional feature fusion[C]// Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision, 2021.

[24] LI X,WANG W,HU X,et al. Selective kernel networks[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019.

[25] YANG M, YU K, ZHANG C, et al. Denseaspp for semantic segmentation in street scenes[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018.

[26] HOU Q,ZHANG L,CHENG M,et al. Strip pooling: rethinking spatial pooling for scene parsing[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020.

[27] RONNEBERGER O, FISCHER P, BROX T. U－net: convolutional networks for biomedical image segmentation[C]// International Conference on Medical Image Computing and Computer-assisted Intervention, 2015.

[28] XIE E, WANG W, YU Z, et al. Segformer: simple and efficient design for semantic segmentation with transformers[J]. Advances in Neural Information Processing Systems, 2021,34:12077－12090.

[29] ZHAO H,SHI J,QI X,et al. Pyramid scene parsing network[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017.

[30] SUN K,XIAO B,LIU D,et al. Deep high-resolution representation learning for human pose estimation[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019.

[31] ZHOU Z,RAHMAN SIDDIQUEE M M,TAJBAKHSH N,et al. Unet++: a nested u-net architecture for medical image segmentation[C]// International Workshop on Deep Learning in Medical Image Analysis, 2018.

[32] 王振庆,周艺,王世新,等. Ieu－net 高分辨率遥感影像房屋建筑物提取[J]. 遥感学报, 2021,25(11):2245－2254.
WANG Zhenqing,ZHOU Yi,WANG Shixin,et al. House building extraction from high-resolution remote sensing images based on Ieu－net[J]. Journal of Remote Sensing, 2021,25(11):2245－2254. (in Chinese)