

# 基于改进 UNet3+ 的粗梗水蕨生长状态智能视觉监测及其 GPI 综合评估方法

胡慧莉<sup>1</sup>, 叶曦<sup>1,2\*</sup>, 曾长立<sup>2</sup>, 董元火<sup>2</sup>

(1. 江汉大学智能制造学院, 武汉 430056; 2. 江汉大学生命科学学院湖北省汉江流域特色生物资源保护开发与利用工程技术研究中心, 武汉 430056)

**摘要:** 粗梗水蕨为国家二级重点保护野生的水生蕨类植物, 科学监测其生长状态对揭示濒危机制与制定保护策略具有重要意义. 本文基于计算机视觉技术, 采集并构建粗梗水蕨全生长周期图像数据集; 在 UNet3+ 图像分割模型的基础上引入欧氏距离自注意力机制, 以增强模型对全局上下文信息的利用效率和细小特征的保留能力, 从而提升模型对于叶片形态复杂且茎叶细小的水生植物的分割精度. 基于图像分割结果提取其冠层覆盖率、形状因子、绿度指数等形态特征参数, 并构建综合生长状态监测指标(GPI), 实现粗梗水蕨生长状态的量化分析. 结果表明幼苗期、快速生长期和成熟期 3 个阶段的 GPI 值分别为(0, 0.27), [0.27, 0.44] 与(0.44, +∞), 并验证 GPI 在区分生长阶段方面的有效性. 本研究结果为其他水生植物生长状态的智能监测提供了技术参考.

**关键词:** 粗梗水蕨; 图像分割; 欧氏距离自注意力; 生长状态监测; 量化评估

中图分类号: Q948.8

文献标识码: A

开放科学(资源服务)标识码(OSID):



植物生长状态的智能监测是现代农业、生物多样性保护及生态学研究中的关键环节. 精准获取植物表型信息, 不仅有助于优化作物栽培管理策略, 也能为珍稀濒危植物的保护与恢复提供科学依据. 粗梗水蕨 (*Ceratopteris pteridoides*) 是长江中下游湿地生态系统中极具代表性的水生蕨类, 先后于 1999 年和 2021 年被列为国家二级重点保护野生植物<sup>[1-2]</sup>. 然而, 由于其个体小、叶片薄、形态复杂且易重叠, 传统人工调查方式难以实现对其生长过程的高频、精准监测, 严重制约了对其濒危机制与生态适应性的深入理解<sup>[3]</sup>. 传统图像处理技术如阈值分割<sup>[4]</sup>、边缘检测<sup>[5]</sup>和区域生长<sup>[6]</sup>等在简单的图像场景中取得一定的效果, 但在叶片形态复杂、植株重叠交错等情况下, 分割精度较低, 鲁棒性不足<sup>[6-7]</sup>, 难以准确提取生长指标. 因此, 发展一种高效、自动化的生长状态监测方法, 不仅有助于揭示其濒危过程中的关键生长节点, 也能为其就地保护与种群恢复提供切实可行的技术手段.

近年来, 随着计算机视觉技术的快速发展, 基于深度学习的图像分割方法在植物表型监测中得到广泛的应用<sup>[8-9]</sup>. 以卷积神经网络(convolutional

neural network, CNN)<sup>[10]</sup>为基础的 U-Net<sup>[11]</sup>通过编码-解码结构和跳跃连接机制, 广泛应用于植物叶片、根系和冠层的自动分割. 然而, U-Net 及其变体在处理叶片形态复杂、目标尺度差异大的水生植物图像时, 仍存在感受野受限<sup>[12]</sup>和细节特征丢失<sup>[13-14]</sup>的问题. 为提升分割性能, 研究者提出了多种改进策略, 如引入注意力机制、特征金字塔和多尺度输入等. 例如, RAAWC-UNet 通过融合残差注意力机制与空间金字塔结构, 有效提升苹果叶片与病害分割的准确性<sup>[15]</sup>; Res-Att-UNet 则通过引入残差块和多尺度输入增强了特征表达能力, 在 CVPPP 数据集中取得了良好的性能<sup>[9]</sup>. 然而, 这些改进主要针对特征尺度相对均一、背景规则的场景, 对于粗梗水蕨这类水生蕨类植物, 其叶片形态呈羽状分裂结构, 茎叶细小且分布密集, 使传统卷积网络在局部特征提取时易出现纹理细节平滑与边界模糊的问题, 难以准确分割不同生长阶段的叶片, 从而影响后续表型指标提取与生长状态评估. 除 UNet 系列外, 其他主流分割模型在面对粗梗水蕨的分割问题时也存在一定的局限性. DeepLab<sup>[16]</sup>系列通过空洞卷积扩大感受野, 但其空间不变性与

收稿日期: 2025-09-25.

基金项目: 湖北省自然科学基金项目(2023AFB462).

\*通信联系人. Email: leslit@jhun.edu.cn.

稀疏采样特征,使其在细小结构分割中易产生断裂。HRNet<sup>[17]</sup>与PSPNet<sup>[18]</sup>虽能整合多尺度上下文信息,但在复杂边缘情况下易出现噪声或区域粘连;而Mask R-CNN等实例分割模型在背景复杂、目标粘连的场景中则易产生掩膜断裂与欠分割的问题<sup>[19]</sup>。Transformer架构<sup>[20]</sup>虽然具备全局建模能力,但其高计算开销与对大规模数据的依赖,使其在有限样本条件下难以发挥优势。

在植物生长监测方面,已有研究尝试结合图像分割与表型参数提取,构建生长状态评估模型。例如, Lee等<sup>[21]</sup>通过无人机与深度学习方法,对西蓝花单株进行精准分割,并基于冠幅和覆盖率等指标实现生长监测。李孟成等<sup>[22]</sup>采用UNet-Attention提取油菜叶片信息,通过叶面积变化分析其生长趋势; Yu等<sup>[23]</sup>则利用AUNet与Bi-LSTM模型相结合的方法,对受控条件下栽培的生菜进行表型特征提取和时序生长预测。这些方法在一定程度上验证了深度学习在植物生长监测中的应用潜力,但多依赖于结构规则,成像条件理想的作物对象,对于粗梗水蕨这类叶片形态复杂且茎叶细小的水生植物,可能无法准确提取其形态特征信息和生长信息。此外,现有研究多依赖覆盖率、叶面积或高度等单一或少量指标来反映生长趋势,对于结构变化复杂、形态异质性显著的粗梗水蕨而言,难以全面刻画其生长动态。

针对上述问题,本文提出了一种基于深度学习的粗梗水蕨生长监测的方法。首先,在UNet3+<sup>[24]</sup>的基础上,创新性地引入欧氏距离自注意力机制(Euclidean distance-based self-attention, EDSA),以增强模型对全局上下文信息的利用效率和细小特征的保留能力,提升模型对于叶片形态复杂且茎叶细小的水生植物的分割精度。其次,构建涵盖水蕨生长周期不同阶段的数据集,通过分割结果提取冠层覆盖率、形状因子等关键生长指标,实现对其生长动态的量化表征。最后,针对单一指标难以全面反映生长状态的问题,本文构建综合生长状态监测指标(growth performance index, GPI),通过融合多项生长指标,以定量分析水蕨生长趋势,并进行生长阶段划分,为粗梗水蕨生长监测提供一种高效、可量化的方法。本方法也为其他水生植物长期动态监测以及相关生态研究提供技术参考。

## 1 研究材料和方法

### 1.1 采样地点与数据集构建

为确保研究数据的科学性与代表性,实验共进

行2次独立采样,分别用于神经网络模型训练与粗梗水蕨生长状态监测。

第1次采样于2023年9月在湖北省咸宁市内水域进行,采集对象为成熟阶段的粗梗水蕨。将植株采回实验室后,置于室内水体容器中,营造近似湿地的静水环境。拍摄采用Intel RealSense D435深度相机,配合固定光源设置,获取多角度图像,构建用于模型训练和验证的图像分割数据集。

第2次采样于2024年7月在湖北省荆州市洪湖市,采集叶型较好,根系健康的幼苗的3株粗梗水蕨个体作为样本,连同原生土壤一并带回实验室,并栽培于通风良好、自然光充足的环境中。通过定时浇水和换水以维持稳定的湿度与水质,控制每天8~10 h光照,温度为25℃~30℃,水体pH值6~7,每2~3 w施肥一次,使其保持自然生长状态。拍摄采用iPhone 13 Pro,固定于三脚架上进行拍摄。自移栽起至成熟阶段持续监测,每日早、中、晚固定时间点进行拍摄,保持拍摄高度、角度、距离固定采集俯视图,确保图像采集的一致性和可比性。图像用于构建生长监测数据集,用于后续表型分析与GPI指标构建。

1.1.1 粗梗水蕨分割数据集构建 为确保数据集的多样性和代表性,所有图像均在相同光源和背景下拍摄,并采用俯视、侧视及不同倾斜角度进行多视角拍摄,以增强模型对不同视角变化的适应能力。采用Labelme软件进行手动标注,标注类别包含植株整体和叶片区域,以提供精确的监督信号。为进一步扩充数据规模并提升泛化能力,采用随机裁剪、水平翻转、旋转等数据增强策略,使数据规模由442张扩充至2 496张。数据集按照7:2:1的比例划分为训练集、验证集和测试集,并统一调整为512 px × 512 px的分辨率,以满足模型训练需求。此外,为验证模型在复杂场景下的适用性,另独立制作20张来自野外环境的粗梗水蕨作为测试集,用于进一步验证模型的分割效果(图1)。




图1 数据集展示

Fig. 1 Dataset visualization

1.1.2 生长监测数据集构建 为实现粗梗水蕨生长过程动态追踪与定量分析,本文基于室内栽培样本建立为期51 d的生长监测数据集,每天早、中、晚

3个固定时间进行拍摄,并确保每次拍摄的角度恒定和环境条件一致,以最大限度地减少外界因素对数据的干扰以及数据的时序性和一致性.该数据集涵盖了粗梗水蕨从幼苗期到成熟期的完整生长周期,包含单株和多株(3株)2组,每组包含150张图像.数据集中每张图像均经过标准化处理,用于后续生长指标的提取、GPI计算及生长阶段的自动划分.图2展示了不同生长阶段的图像及分割结果示例.

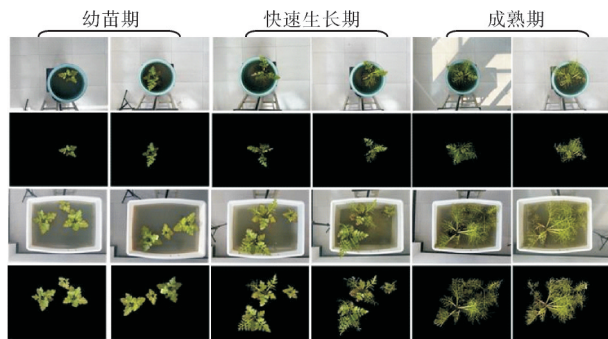


图2 粗梗水蕨生长数据集

Fig. 2 Growth Dataset of *Ceratopteris pteridoides*

## 1.2 生长状态监测及数据分析方法

针对粗梗水蕨叶片形态复杂且茎叶细小形态特征,本文选取在多尺度特征融合方面具有优势且结构相对高效的UNet3+作为基础图像分割模型,该结构通过密集跳跃连接,能够较好地保留空间细节信息.为进一步增强模型对全局上下文的建模能力并提升细小结构的分割精度,本文在UNet3+的瓶颈层引入欧氏自注意力机制,通过计算特征向量之间的欧氏距离衡量相似性,以增强模型对全局上下文信息的利用效率和细小特征的保留能力,从而提升粗梗水蕨图像的分割精度,为后续的生长监测提供更加准确的生长指标.在获取分割结果后,本文选取冠层覆盖率、冠幅直径、绿度指数、分形维数、边界密度和形状因子等六个表型指标,作为生长状态检测的主要参数,分别用于表征植株的生长面积、健康状况和复杂性.

为实现多指标融合,进一步构建综合生长状态指数GPI,本文采用主成分分析(principal component analysis, PCA)方法对各指标进行权重提取,并结合粗梗水蕨的生物学特征对权重进行修正,以确保指数的生物学解释性与稳定性.为验证GPI指数划分生长阶段的准确性,本文将其结果与人工标注结果进行对比,并引入Kappa系数用于一致性评价,以剔除随机因素的影响,衡量划分结果的稳定性与可靠性.最终,基于GPI指数的时序变

化,通过K-means聚类与Multi-Otus方法对水蕨的生长阶段阈值划分,实现粗梗水蕨生长状态的定量分析与阶段判定.本文总体流程如图3所示,包括图像采集与预处理、分割网络训练、形态参数提取、生长指标计算及阶段判断5个步骤.

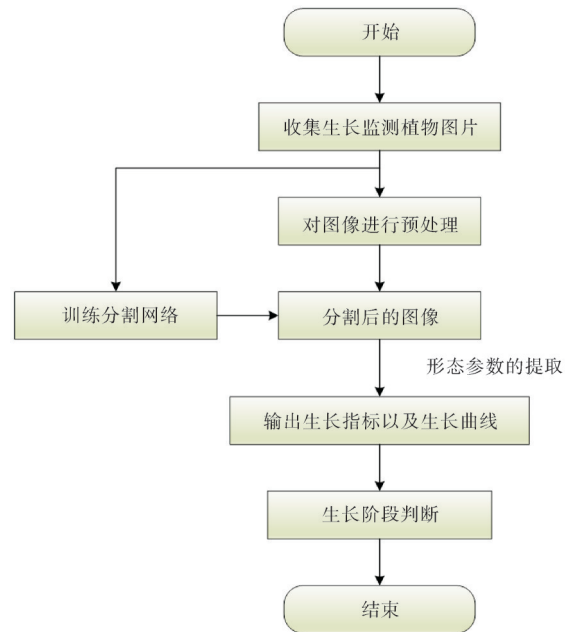


图3 生长状态监测流程图

Fig. 3 Flowchart of growth status monitoring

### 1.2.1 图像分割模型

1) 欧氏距离自注意力机制.本文提出一种欧氏距离自注意力机制,以增强模型对远距离像素间的特征建模能力,提升模型对全局上下文信息的利用效率和细小特征的保留能力.传统的自注意力机制通常基于向量的内积来计算相似性,难以有效捕捉全局空间信息与远距离特征的关联.而EDSA通过欧氏距离来度量像素之间的相似性,可以更好地关注全局特征间的空间关系,特别是处理不同尺度和远距离目标时,能够有效保留细节信息,使得模型在不同尺度和远距离特征建模方面更加精准.欧氏距离的计算公式为:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}, \quad (1)$$

其中, $x, y$ 代表两个像素特征向量, $x_i, y_i$ 分别表示其第*i*个分量.该距离度量方式能够反映像素点之间的全局空间分布,使得模型更容易捕捉远距离特征的关系.

在EDSA机制中,首先将输入特征 $X$ 通过线性映射变换为Query( $Q$ )和Value( $V$ ):

$$Q = W_Q X, V = W_V X, \quad (2)$$

其中,  $W_Q$  和  $W_V$  为可学习的权重矩阵.

基于 Query 特征中的像素点之间的欧氏距离, 构建空间距离矩阵:

$$D_{mn} = \sqrt{(Q_m - Q_n)^2}, \quad (3)$$

计算得到的距离矩阵  $D$  经过归一化后得到注意力权重矩阵  $A$ , 经过重塑后与原始输入特征的值向量  $V$  相乘, 最后重塑得到经过加权后的新的特征表, 表达式如下:

$$\text{Attention}(Q, V) = AV = \text{Soft max}(\sqrt{(Q - Q^T)^2})V, \quad (4)$$

欧氏自注意力机制的模块结构图如图 4 所示. 特征图经过  $1 \times 1$  的卷积进行权重初始化, 得到两个不一样的权重矩阵, 再将红色的权重矩阵分别重塑成一行一列进行广播相减, 之后再对其进行欧氏距离计算, 最后进行归一化处理并重塑成原来的大小. 再使用绿色的权重矩阵进行自注意力加权, 最后得到新的特征图矩阵.

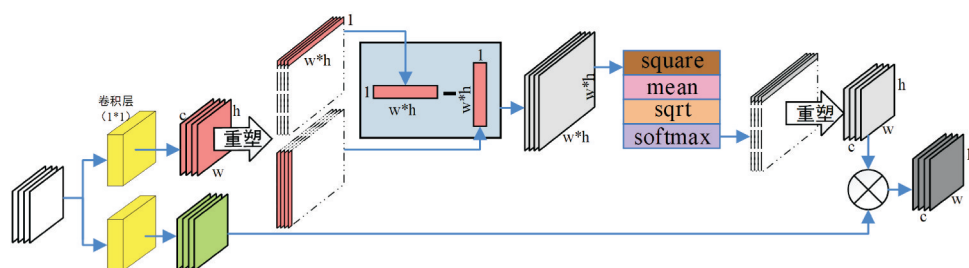


图 4 基于欧氏距离的自注意力模块

Fig. 4 Self-attention module based on Euclidean distance

2) EDSAUNet3+. 本文提出的 EDSAUNet3+ (Euclidean distance-based self-attention UNet3+) 是在 UNet3+ 的基础上, 引入 EDSA 机制, 以增强远距离特征建模能力和小目标分割能力. 将 EDSA 集成到 UNet3+ 的瓶颈层, 即位于编码器的最后一层与解码器的第一层之间, 用于优化全局特征建模, 增强不同区域之间的像素关联性. 模型结构如图 5 所示. 下采样过程中瓶颈层聚集了

丰富的语义信息, 但牺牲了部分空间细节, 空间分辨率较低, 传统卷积操作难以有效捕捉全局特征. 引入 EDSA 机制后, 模型能够基于欧氏距离衡量像素间的相似性, 提升空间特征的建模精度. 这不仅有助于提升远距离像素间的关联性, 还能在小目标区域增强细节信息, 为后续上采样恢复高分辨率分割结果提供了更精准的特征基础, 从而提升分割精度.

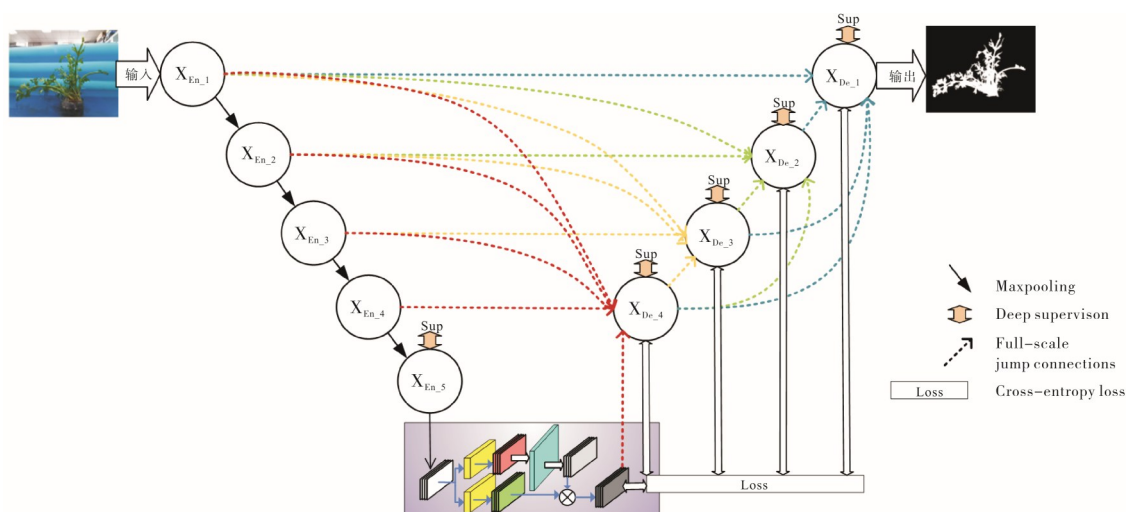


图 5 EDSAUNet3+ 模型示意图

Fig. 5 Schematic diagram of EDSAUNet3+ model

### 1.2.2 分割性能评估方案

1) 评估指标. 为了更加有效地评估模型的分割效果, 本文采用 Dice 系数、IoU 和 F1score 作为评

估指标对模型的分割性能进行衡量<sup>[25]</sup>, 如公式(5)所示. 这 3 个指标的值越大, 表明分割结果与模型的相似度越高, 模型的分割效果越好.

$$\left\{ \begin{array}{l} \text{Dice} = 2 \frac{|X \cap Y|}{|X| + |Y|}, \\ \text{IoU} = \frac{X \cap Y}{X \cup Y}, \\ \text{F1}_{\text{score}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + \frac{1}{2}(N_{\text{FP}} + N_{\text{FN}})}. \end{array} \right. \quad (5)$$

2) 试验设置. 本次试验所用服务器使用 Window10 操作系统, 硬件方面使用了 Intel® Core™ 13 700K CPU 和 NVIDIA GeForce RTX 3090TI GPU 显卡, 训练平台和学习库选择了 Python 3.7.10、torch1.8.1. 优化器为 Adam 优化器, 学习率设置为 0.001, 训练时的 Batch 为 4, 测试时的 Batch 为 1.

### 1.2.3 生长监测指标

1) 冠层覆盖率. 冠层覆盖率 (foliage coverage index, FCI)<sup>[26]</sup> 表示植物叶片或植被在图像中的占比, 用于评估植被的生长面积扩展情况, 其计算方法为:

$$I_{\text{FC}}(C. \text{pteridoides}) = \frac{\sum_{i=1}^N I(x_i \in \Omega_{\text{veg}})}{\sum_{j=1}^M I(x_j \in \Omega_{\text{total}})} \times 100\%, \quad (6)$$

式中,  $I$  表示函数, 当像素  $x_i$  属于植被区域时取值为 1, 否则为 0;  $\Omega_{\text{veg}}$  表示图中植被区域的像素集合;  $\Omega_{\text{total}}$  图中区域像素集合;  $N$ 、 $M$  分别为植被像素和总像素的数量 ( $N \leq M$ ).

2) 冠幅直径. 通过最小外接圆来计算, 最小外接圆的直径即为冠幅直径 (crown diameter, CD), 用来量化水蕨空间上的扩展范围. 其计算方法为:

$$D_c(C. \text{pteridoides}) = \min\{d(C)\}, \quad (7)$$

式中,  $C$  为包含所有叶片像素点的圆,  $d(C)$  表示圆  $C$  的直径<sup>[27]</sup>.

3) 绿度指数. 绿度指数 (green leaf index, GLI)<sup>[28]</sup> 是一种常见的植被指数, 反映植物的叶绿素含量, 与光合作用效率和健康状况相关. 绿度指数较高的植物通常健康且生长旺盛, 其计算方法为:

$$I_{\text{GL}}(C. \text{pteridoides}) = \frac{2G - R - B}{2G + R + B}, \quad (8)$$

式中,  $R$ 、 $G$ 、 $B$  分别表示图像中红色、绿色和蓝色通道的像素值.

4) 分形维数. 分形维数 (information fractal dimension, IFD)<sup>[29]</sup> 主要描述的是图像的复杂度, 用于评估叶片或者植被的边界复杂度. 分形结构越

复杂, 植物叶片形态越复杂, 其计算方法为:

$$D_{\text{IF}}(C. \text{pteridoides}) = -\frac{\log(N)}{\log(s)}, \quad (9)$$

式中,  $s$  是盒子的大小,  $N$  是  $s$  尺度下被覆盖植被的盒子数.

5) 边界密度. 边界密度 (edge density, ED) 是衡量植被边界复杂性的重要指标, 反映了植被边缘的长度相对于研究区域总面积的密集程度, 其计算方法为:

$$D_{\text{E}}(C. \text{pteridoides}) = \frac{\sum_{i=1}^N E_i}{A}, \quad (10)$$

其中,  $E_i$  为第  $i$  个斑块的边缘长度 (像素或实际单位);  $A$  为研究区域总面积<sup>[30]</sup>.

6) 形状因子. 形状因子 (form coefficient, FC)<sup>[31]</sup> 主要是用于衡量叶片或者植被的形状是否规则, 主要用于区分生长形态不同的植物. 其计算方法为:

$$C_{\text{F}}(C. \text{pteridoides}) = \frac{4\pi S}{C^2}, \quad (11)$$

式中,  $S$  是叶片的面积,  $C$  是叶片的周长.

## 1.2 4 生长状态评估方法

为实现对粗梗水蕨生长状态的稳定评估与阶段划分, 本文提出综合性生长状态指数 GPI. GPI 指数基于 6 项关键表型指标构建, 分别为 FCI、GLI、CD、ED、IFD 及 FC, 涵盖了生长面积、健康状况与形态复杂性等方面.

在权重设置方面, 本文首先采用皮尔逊相关分析初步评估各指标之间的关系, 随后利用 PCA 方法提取主要影响成分. PCA 结果用于判断各指标对粗梗水蕨生长状态的主导程度, 以构建 GPI 的初步权重分配框架. 在此基础上, 结合粗梗水蕨的生长生物学特性对各项权重进行适当调整, 以增强 GPI 在实际应用中的生物解释性和稳定性, 最终形成基于线性加权模型的 GPI 指数构建公式. 本文结合 Multi-Otsu 方法和 K-means 聚类分析两种方法对粗梗水蕨的生长阶段进行划分, 确保生长阶段划分的结果源于数据本身的自然结构, 而非单一算法的局限性.

为验证 GPI 系数划分的准确性, 本文以人工判读的生长阶段作为参考真值, 将基于 GPI 的自动划分结果与其进行对比, 通过计算其总体的分类的准确性 (accuracy) 与 Kappa 系数, 对分类效果进行评价. 根据 Landis 和 Koch 的研究, Kappa 系数为 (0.8, +∞) 表示完全一致, (0.6, 0.8] 表示高度一

致,  $(0.4, 0.6]$  表示中度一致,  $[0.2, 0.4]$  表示一般一致,  $[0, 0.2]$  表示一致性较差.

$$P_{\text{accuracy}} = \frac{N_{\text{correct}}}{N_{\text{total}}}, \quad (12)$$

其中,  $N_{\text{correct}}$  为 GPI 划分与人工判定一致的样本数,  $N_{\text{total}}$  为样本.

$$K = \frac{p_o - p_e}{1 - p_e}, \quad (13)$$

其中,  $p_o$  为观测一致率,  $p_e$  为随机一致率.

## 2 研究结果

### 2.1 图像分割结果

为全面 EDSAUNet3+ 模型的性能, 分别进行了消融实验和与现有先进方法的对比试验. 试验设置均使用 1.2.2 所述设置, 采用了分割任务当中的 6 项分割指标, 用于从不同维度综合评估模型性能. 但主要将骰子系数(Dice)、交并比(IoU)和 F1 这 3 项作为衡量分割模型的核心指标, 因其能更直接、全面反映分割结果与真实标注的一致性体现模

型的分割能力. 但为全面验证模型在不同维度的表现, 本文在消融实验中仍保留其他辅助指标, 以进一步分析模型的综合性能.

2.1.1 消融实验结果 为定量评估 EDSA 机制对 UNet3+ 性能的提升作用, 设计了消融实验, 对比 EDSAUNet3+、基础 UNet3+ 以及引入传统自注意力机制的改进模型 UNet3\_SelfAttention 在同一水蕨数据集上的分割性能, 分割结果如表 1 所示. EDSAUNet3+ 在所有指标上均优于 UNet3+ 和 UNet3\_SelfAttention, 尤其是在 Dice 和 IoU 的方面较 UNet3\_SelfAttention 提升了 1.2% 和 1.8%, 展现出了更强的分割能力. 其中, EDSAUNet3+ 的 Dice 和 IoU 分别达到了 91.9% 和 85.2%, 表明其能够更准确地捕捉目标区域, 提高分割精度; F1 相较 UNet3+ 提升了 1.9%, 表明 EDSAUNet3+ 在平衡精度(Precision)与召回率(Recall)方面表现更好, 能够减少假阳性和假阴性, 确保目标区域的分割更为全面和准确, 验证了 EDSA 注意力机制在细节捕捉方面的优势.

表 1 消融实验结果

Tab. 1 Results of ablation experiments

模型	精确率/%	骰子系数/%	交并比/%	F1/%	平均交并比/%	召回率/%
UNet3+	95.9	90.0	82.5	90	89.8	85.6
UNet3_SelfAttention	94.9	90.7	83.4	90.7	90.1	87.3
EDSAUNet3+	95.7	91.9	85.2	91.9	91.4	88.6

2.1.2 对比实验结果 为了验证本文提出的 EDSAUNet3+ 模型的在粗梗水蕨分割上的有效性, 选择多类具有代表性的语义分割方法进行对比, 包括经典的多尺度上下建模网络 DeepLabV3+<sup>[32]</sup>、具备边界感知能力的 Agate Net<sup>[33]</sup>、融合 CNN 与 Transformer 的 TransUNet<sup>[34]</sup>, 以及近年来提出的轻量化嵌套网络 U2NETP<sup>[35]</sup>和

高效 Transformer 分割模型 SegFormer<sup>[36]</sup>, 面向农业植株实例、具备层级结构优势的 HAPT<sup>[37]</sup>. 这些方法分别代表卷积型、注意力增强型和 Transformer 型等不同思路, 在同一数据集上的分割效果进行对比, 从而更全面地评价本文方法的有效性, 分割性能结果对比如表 2 所示.

表 2 不同网络对比试验结果

Tab. 2 Comparison experiments results of different networks

模型	精确率/%	骰子系数/%	交并比/%	F1/%	平均交并比/%	召回率/%
HAPT	94.70	91.00	83.80	91.00	90.40	88.00
Agate Net	93.40	90.40	82.80	90.40	90.00	86.70
DeepLabV3+	93.90	88.80	80.30	88.80	88.30	84.90
TransUNet	92.40	90.50	82.90	90.50	90.20	89.10
U2NETP	94.70	90.90	83.70	90.90	90.20	87.90
SegFormer	94.80	89.60	81.60	89.60	89.00	85.40
EDSAUNet3+	95.70	91.90	85.20	91.90	91.40	88.60

各个模型在粗梗水蕨图像分割任务中的表现存在一定差异. SegFormer与DeepLabV3+在精确率指标上相对较高,但Dice、IOU和召回率指标相对较低,说明模型在追求细节分割的同时牺牲了对整体形状的捕捉. 与之相反, TransUNet在Recall指标上表现突出,能够有效捕捉目标,验证了Transformer架构在全局上下文感知与捕捉方面的优势,但Precision指标偏低,表明其存在一定过分割现象. Agate Net的各项指标表现均衡但均不突出,表明其在处理粗梗水蕨这类分割任务时的性能局限性. 模型U2NETP与HAPT的Dice与IoU分别为90.90%、83.70%和91.00%、83.80%,优于前述模型,表明其边界细节刻画具有优势. 整体而

言,所提出的EDSAUNet3+在Precision、Dice、IOU与MIOU等指标上较HAPT模型分别提升1.0%、0.9%、1.4%和1.0%,验证其在全局特征建模、细节保持以及复杂形态适应性方面的有效性与优越性.

为了验证模型在真实复杂湿地环境下的适用性,本文算法在野外粗梗水蕨图像上进行了测试. 尽管整体分割指标较实验室场景有所下降,但所提出的EDSAUNet3+模型在Dice、IoU、mIoU以及Recall等指标上均优于其他算法(表3),表明EDSAUNet3+在复杂背景下仍具有较强的分割性能.

表3 复杂背景下的对比试验结果

Tab. 3 Comparison experiments results under complex backgrounds

模型	精确率/%	骰子系数/%	交并比/%	F1/%	平均交并比/%	召回率/%
HAPT	93.80	73.40	59.90	73.40	69.30	62.90
Agate Net	<b>97.30</b>	54.80	39.90	54.90	45.60	40.30
DeepLabV3+	92.20	73.10	59.60	73.10	70.30	64.10
TransUNet	95.64	61.35	46.02	61.35	54.53	47.86
U2NETP	94.45	62.17	46.93	62.17	55.11	49.56
SegFormer	94.11	72.30	58.43	72.30	67.79	61.60
EDSAUNet3+	90.71	76.46	62.82	76.46	72.74	68.16

为进一步验证模型分割的有效性,本文将对比实验算法用于对粗梗水蕨生长数据集在快速生长期、成熟期等不同生长阶段及单株、多株等不同植株密度下进行分割测试(图6),其中,蓝色框表示

分割不细致区域,绿色框表示误分割区域. 为便于结果对比,用白色框在标签图中标出与蓝色框区域相对应的部位,以展示本文改进算法在细节还原方面的优势.

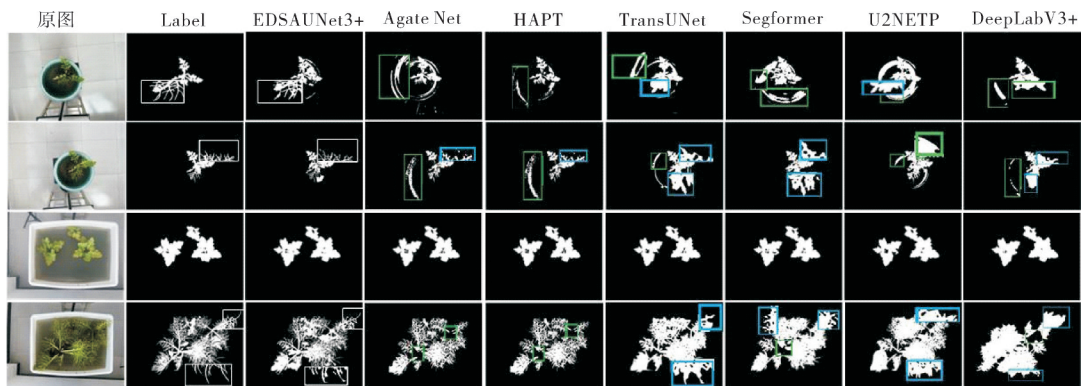


图6 对比模型算法在水蕨生长数据集的分割结果

Fig. 6 Segmentation results of comparison model algorithms on the ceratopteris growth dataset

## 2.2 智能视觉监测结果

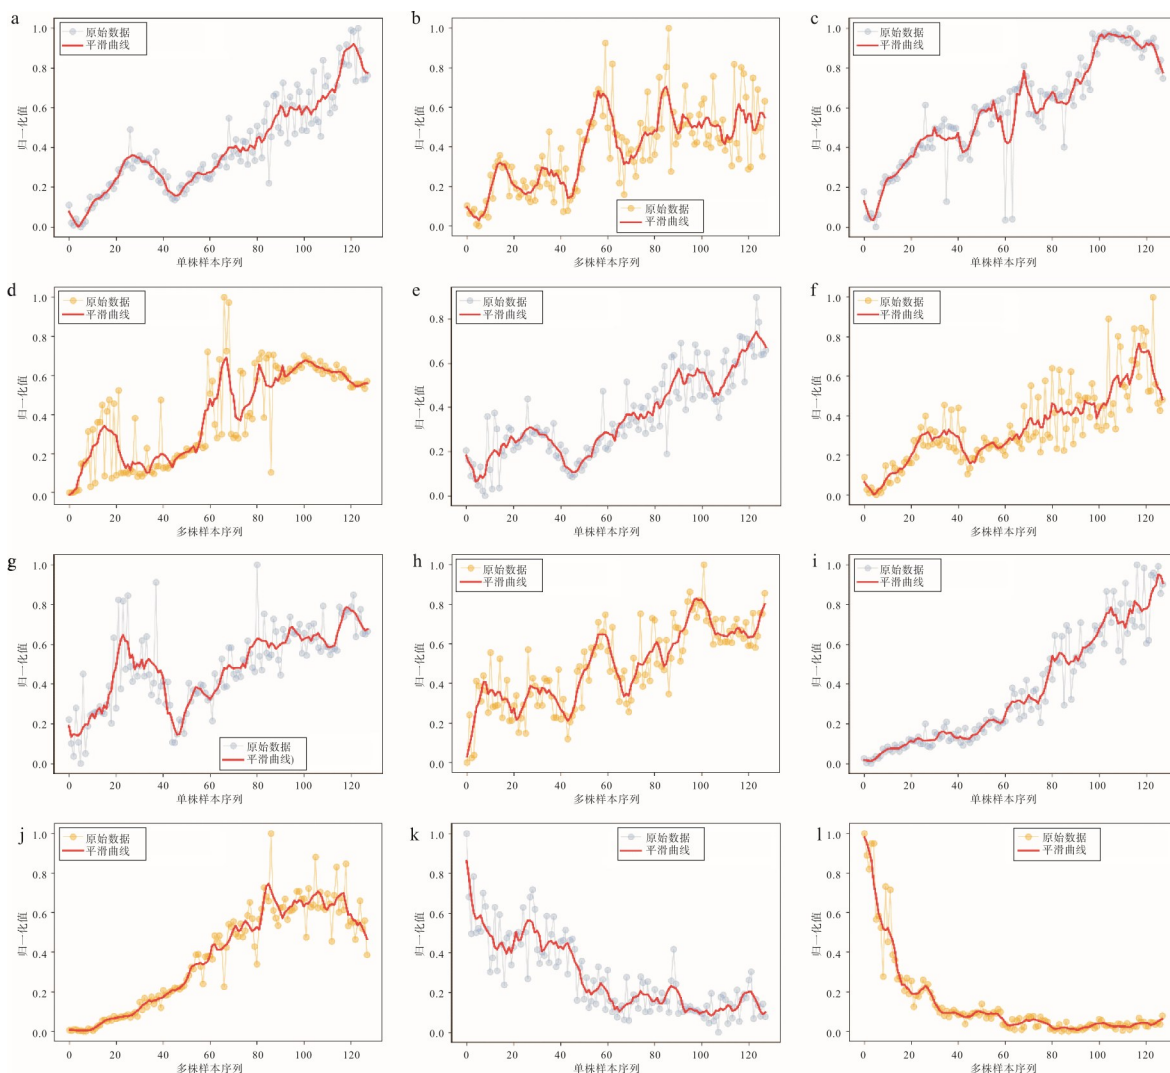
利用前面改进好的EDSAUNet3+算法,对51天(每天一张)的粗梗水蕨图像进行分割,将分割结果分为黑白图像和彩色图像,用于粗梗水蕨的表型

分析. 为避免不同生长指标量纲差异对后续分析的影响,对各指标原始数据进行了归一化的处理,归一化后的所有指标被映射在0到1的区间,确保数据的可比性,为了减少环境干扰、测量误差及个

体生长波动带来的噪声对分析结果的影响,采用 Savitzky-Golay 滤波器进行平滑处理,能够有效减少噪声,以便更准确地分析水蕨的生长趋势。

利用冠层覆盖率、冠幅直径、绿度指数、分形维数、边界密度和形状因子等 6 个生长指标,对分割后的结果进行计算和分析,绘制出的生长指数曲线

(图 7)。其中,左图为单株样本的指标变化曲线,右图为多株样本的变化曲线。可以看出,多株样本由于个体间存在光照与空间竞争,表现出一定波动性,但其整体生长趋势与单株样本基本一致,表明所构建的指标体系具有较好的稳定性和代表性。



a~b. 冠层覆盖率变化曲线;c~d. 冠幅直径变化曲线;e~f. 叶绿指数变化曲线;g~h. 分形维数变化曲线;i~j. 边界密度变化曲线;k~l. 形状因子变化曲线

图 7 粗梗水蕨 6 个生长指标变化曲线

Fig. 7 Variation curves of six growth indicators of *Ceratopteris pteridoides*

### 2.3 生长状态综合评估

皮尔逊相关分析结果表明,粗梗水蕨的主要表型指标存在显著相关性,尤其是冠层覆盖率、分形维数、边界密度、形状因子与冠幅直径之间的相关性最为紧密(图 8),为后续指标融合提供理论依据。

PCA 结果显示,PC1 解释了 79.53% 的方差,主要反映水蕨的整体生长与空间扩展,PC2 和 PC3

分别解释了 11.45% 和 4.65% 的方差,揭示形态复杂性以及细微的变化。根据 PCA 载荷矩阵(表 4),可以进一步确定各生长监测指标的权重分配,并进一步构建 GPI 指数。

为将主成分分析的结果转化为可量化的评价指标,基于承载了绝大部分数据信息的 PC1 载荷系数计算各指标的初始权重,对 PC1 的载荷绝对值进行归一化处理,得到指标的初始贡献度。但考




图 8 皮尔逊相关系数矩阵

Fig. 8 Pearson correlation coefficient matrix

表 4 PCA 载荷矩阵

Table 4 PCA Load Matrix

指标	PC1	PC2	PC3
冠层覆盖率 FCI	0.438	0.260	-0.272
冠幅直径 CD	0.425	-0.179	-0.099
绿度指数 GLI	0.438	0.261	-0.271
分形维数 IFD	0.377	0.476	0.762
边界密度 ED	0.424	-0.178	-0.329
形状因子 FC	-0.338	0.758	-0.392

考虑到 PCA 仅基于方差解释率,未必完全符合生物学意义,例如,冠层覆盖率与绿度指数直接决定了其光合作用效率与生存竞争能力,是表征其生长健康状况的关键指标,因此,在初始权重的基础上进行了提高;同时保持其他指标与 PC1 所揭示的空间扩展主题一致,并适当降低主要反映细微形态变化的指标权重.最终确定综合生长指标指数 GPI 的计算公式如下:

$$I_{GP} = 0.3 \times I_{FC} + 0.25 \times I_{GL} + 0.2 \times D_C + 0.15 \times D_E + 0.1 \times D_{IF} + 0.1 \times C_F \quad (15)$$

基于 GPI 指数的变化趋势,结合 Multi-Otsu 方法和 K-means 聚类分析对 GPI 分布进行划分. Multi-Otsu 方法基于类间方差最大化原则得到 2 个最优阈值  $T_1=0.24$ ,  $T_2=0.43$ ; K-means 聚类 ( $k=3$ ) 得到三个簇中心  $C_1=0.17$ ,  $C_2=0.32$ ,  $C_3=0.59$ . 两种方法的结果高度一致.为提高划分稳健性,将两种方法得到的分界点进行融合,确定最终阈值为  $T_1=0.27$  和  $T_2=0.44$ . 据此,粗梗水蕨生长过程被划分为幼苗期、快速生长期和成熟期 3 个阶

段,对应 GPI 值的 3 个分布区间分别为  $GPI < 0.27$  为幼苗期、 $0.27 \leq GPI \leq 0.44$  为快速生长期和  $GPI > 0.44$  为成熟期.

为验证 GPI 指数阶段划分结果的可靠性与有效性,本文将自动划分结果与人工判定结果进行对比分析,根据公式(12)与(13)计算得到分类准确率为 78.12% 和 Kappa 系数为 0.67,不同生长阶段人工判断与自动判断的数量对比如图 10 所示.

### 3 讨论

#### 3.1 分割性能

由图 5 可见,不同模型在粗梗水蕨图像分割中表现差异显著. Agate Net 与 U2NETP 在花盆边缘出现明显的误分割,并在叶片末端与细小分枝处表现出分割不细致,导致轮廓不完整. 基于 Transformer 的 TransUNet 与 SegFormer 能够较好提取整体形状,但在非目标区域易产生误分割,且叶片裂片和边缘细节仍存在欠分割. HAPT 与 DeepLabV3+ 在主体区域提取较为准确,但边缘锯齿、粘连及部分空洞问题较为突出,仍有背景被误识别的情况. 值得注意的是,在水蕨早期生长阶段(图 5 第三行),由于植株株型较小、叶片分散,整体分割难度较低,各模型均能较为完整地提取目标区域,分割性能差异不明显. 然而,随着植株生长,叶片逐渐细长并出现重叠交错,分割难度显著增加,各模型性能差异随之显现. 相比之下,所提出的 EDSAUNet3+ 能够在不同样本中保持稳定的分割性能,误分割现象显著减少,边缘轮廓更加完整,叶片细裂片与复杂结构得以准确保留,分割结果更

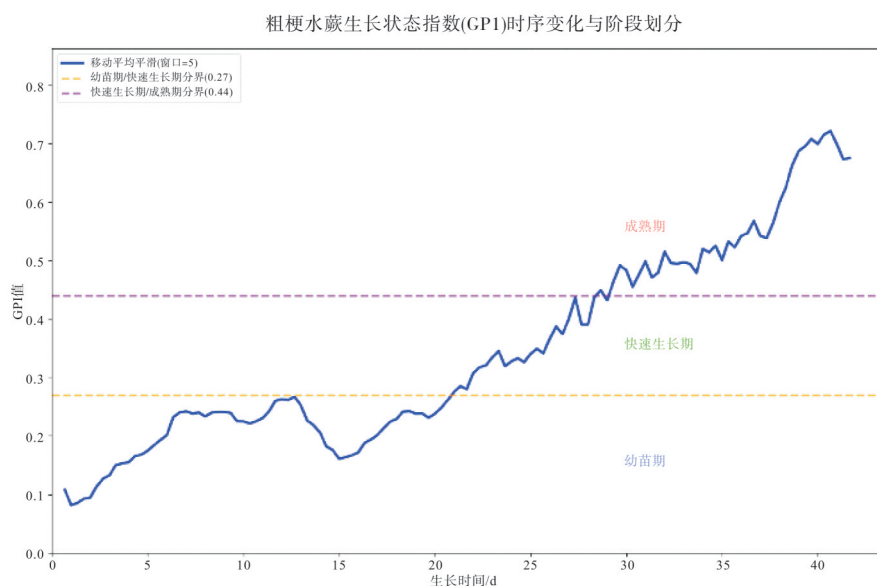


图9 GPI的时序变化与生长阶段的划分

Fig. 9 Temporal variation of GPI and division of growth stages




图10 不同生长阶段人工判断与自动判断的数量对比

Fig. 10 Quantity comparison between manual judgment and automatic judgment in different growth stages

加贴近于标签。这与表2的量化结果,EDSAUNet3+在 Precision、Dice、IoU 等指标上均取得最优表现相吻合。

上述结果进一步验证欧氏距离注意力机制的有效性,其通过增强模型对远距离像素之间特征关系的建模能力,提升了模型对于叶片形态复杂且茎叶细小的水生植物的分割精度,证明EDSAUNet3+在粗梗水蕨图像分割任务中的有效性。

### 3.2 监测与评估结果讨论

监测与评估结果显示,在水蕨的生长过程中,多个指标呈现显著的时序变化趋势。冠层覆盖率随叶片数量的增加而持续上升,在第20~25 d期间增速最为明显,50 d后增长趋于缓慢。绿度指数在15~30 d时增长显著,随后进入生长稳定期。分形维数在25~40 d时上升最为显著。边界密度总体

趋势在不断增加,尤其是在20~30 d之间增长得最快,而45 d后由于空间竞争,增长速率减缓。由于植物叶片数量不断增加,在空间上不断扩展,因此冠幅直径也在增大,扩展率在15~35 d之间最快,之后放缓。相比之下,形状因子呈现出下降的趋势,在20~40 d最明显。

粗梗水蕨在整个生长周期中,各项生长指标呈现出清晰的时序变化特征。通过对分割结果提取的表型指标进行归一化处理与时序分析,发现多个指标在20~40 d之间快速变化,这一阶段可视为粗梗水蕨的快速生长期。这一阶段,叶片数量与叶绿素含量同步上升,反映出植物光合作用效率的增强和叶片结构向羽状叶形的转变;分形维数与边界密度的明显增长,则表明植株边缘与植株的形态复杂度在不断上升。上述趋势与陈庆山关于粗梗水蕨在移栽后20 d左右出现羽状叶形,40 d后转为孢子叶的观察结果一致<sup>[38]</sup>。

基于上述指标变化规律以及PCA载荷矩阵,本研究构建了综合生长指标GPI,用于量化表征粗梗水蕨的生长状态与发育阶段。GPI综合了冠层覆盖率(0.3)、绿度指数(0.25)、冠幅直径(0.2)、边界密度(0.15)、分形维数(0.1)和形状因子(0.1)6个关键参数,权重设置依据各指标与生长状态的生物学关联性及其在形态建成中的贡献程度确定。实验结果表明,GPI指数对生长阶段分类的准确率达到78.12%,Kappa系数为0.67,说明GPI指数在生长阶段分类任务中具有较好的稳定性和可靠性,能够有效支持粗梗水蕨表型监测的定量化与自动化

分析.

### 3.3 生长状态监测在濒危机制与保护策略中的意义

本文提出了将图像分割与生长指标融合的粗梗水蕨生长监测方法,能够应用于粗梗水蕨的濒危机制分析. GPI指数的时序变化表明,在实验室模拟的适宜环境中,粗梗水蕨具有良好的生长潜力,多个指标在第21~40 d的快速生长期表现出显著增长. 然而,野外水蕨种群却出现普遍存在个体缩小、分布破碎和更新能力下降等退化现象. 这一差异表明,粗梗水蕨的濒危问题更可能由外部环境劣化与人类干扰导致,而非其自身的生理缺陷. 这一推论也得到了相关研究文献的支持<sup>[1]</sup>.

通过冠层覆盖率、分形维数、边界密度、形状因子等关键生长指标的时序分析,系统地揭示粗梗水蕨从简单叶态向复杂叶态过渡的过程. 这些指标的阶段性变化不仅体现了叶片形态复杂度的提升与光合作用效率的增强,也为不同生长阶段的识别和划分提供了量化依据. 进一步地,在种群层面,这些动态指标可以反映群体活力和结构演替趋势,一旦监测到指标停止或异常波动,便可视为种群动态变化的早期信号,从而为濒危预警与保护干预提供重要依据.

#### 参考文献:

- [1] 杨星宇, 梁玉婷, 陈永勤, 等. 濒危植物粗梗水蕨孢子高效无菌萌发及成苗技术[J]. 湖北大学学报(自然科学版), 2024, 46(4): 584-590.  
YANG X Y, LIANG Y T, CHEN Y Q, et al. High-effective aseptic spore germination and seedling production of *Ceratopteris pteridoides*, an endangered plant[J]. Journal of Hubei University (Natural Science Edition), 2024, 46(4): 584-590. (Ch).
- [2] 国家林业和草原局, 农业农村部. 国家重点保护野生植物名录(2021版)[EB/OL]. (2021-09-08) [2025-11-10]. [https://www.gov.cn/zhengce/zhengceku/2021-09/09/content\\_5636409.htm](https://www.gov.cn/zhengce/zhengceku/2021-09/09/content_5636409.htm). National Forestry and Grassland Administration, Ministry of Agriculture and Rural Affairs. List of wild plants under state priority conservation (2021) [EB/OL]. (2021-09-08) [2025-11-10]. [https://www.gov.cn/zhengce/zhengceku/2021-09/09/content\\_5636409.htm](https://www.gov.cn/zhengce/zhengceku/2021-09/09/content_5636409.htm). (Ch).
- [3] TAN S Y, LIU J B, LU H H, et al. Machine learning approaches for rice seedling growth stages detection[J/OL]. Frontiers in Plant Science, 2022, 13. [2025-11-10]. <https://doi.org/10.3389/fpls.2022.914771>.
- [4] MOHAMED H, NADAOKA K, NAKAMURA T. Automatic semantic segmentation of benthic habitats using images from towed underwater camera in a complex shallow water environment[J/OL]. Remote Sensing, 2022, 14(8) [2025-11-10]. <https://doi.org/10.3390/rs14081818>.
- [5] 董红霞. 基于图像的植物叶片分类方法研究[D]. 长沙: 湖南大学, 2013.  
DONG H X. Researches on classification of plant leaves based on images[D]. Changsha: Hunan University, 2013. (Ch).
- [6] 汪建. 结合颜色和区域生长的茶叶图像分割算法研究[J]. 茶叶科学, 2011, 31(1): 72-77.  
WANG J. Segmentation algorithm of tea combined with the color and region growing[J]. Journal of Tea Science, 2011, 31(1): 72-77. (Ch).
- [7] 曾德斌, 陆万荣, 郑良芳, 等. 基于U<sup>2</sup>-DSCNet植物叶片分割方法研究[J]. 中国农机化学报, 2025, 46(2): 253-258.  
ZENG D B, LU W R, ZHENG L F, et al. Research on plant leaf segmentation method based on U<sup>2</sup>-DSCNet[J]. Journal of Chinese Agricultural Mechanization, 2025, 46(2): 253-258. (Ch).
- [8] 孙承秀. 植物工厂复杂环境下的黄瓜幼苗实例分割及叶面积计算方法研究[D]. 新乡: 河南科技学院, 2025.  
SUN C X. Study on instance segmentation and leaf area calculation methods for cucumber seedlings in the complex environment of plant factories[D]. Xinxiang: Henan Institute of Science and Technology, 2025. (Ch).
- [9] 欧朴康. 基于深度学习的植被覆盖率测量[D]. 西安: 西安石油大学, 2023.  
OU P K. Vegetation coverage measurement based on deep learning[D]. Xi'an: Xi'an Shiyou University, 2023. (Ch).
- [10] O'SHEA K, NASH R. An introduction to convolutional neural networks [DB/OL]. 2015-12-020 [2025-11-10]. <https://arxiv.org/abs/1511.08458>.
- [11] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation [C]//NAVAB N, HORNEGGER J, WELLS W M, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Cham: Springer, 2015: 234-241.
- [12] 李赫, 刘建军, 肖亮. 融合交叉注意力与双编码器的医学图像分割[J]. 中国图象图形学报, 2024, 29(11): 3462-3475.  
LI H, LIU J J, XIAO L. Dual-encoder global-local cross-attention network for medical image segmentation [J]. Journal of Image and Graphics, 2024, 29(11): 3462-3475. (Ch).
- [13] 黄鹏, 郑洪, 梁超. 图像分割方法综述[J]. 武汉大学学报(理学版), 2020, 66(6): 519-531.  
HUANG P, ZHENG Q, LIANG C. Overview of image segmentation methods [J]. Journal of Wuhan University (Natural Science Edition), 2020, 66(6): 519-531. (Ch).
- [14] 宋永献, 袁敏峰, 王祥祥, 等. 基于改进U-Net的工件表面缺陷分割方法[J]. 仪表技术与传感器, 2023(3): 82-87.  
SONG Y X, YUAN M F, WANG X X, et al.

- Segmentation method for surface defects of industrial components based on improved U-net [J]. *Instrument Technique and Sensor*, 2023(3): 82-87. (Ch).
- [15] WANG J L, JIA J H, ZHANG Y K, et al. RAAWC-UNet: an apple leaf and disease segmentation method based on residual attention and atrous spatial pyramid pooling improved UNet with weight compression loss [J/OL]. *Frontiers in Plant Science*, 2024, 15 [2025-11-10]. <https://doi.org/10.3389/fpls.2024.1305358>.
- [16] 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*, 2018, 40(4): 834-848.
- [17] SUN K, XIAO B, LIU D, et al. Deep high-resolution representation learning for human pose estimation[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 15-20, 2019, Long Beach, CA, USA. IEEE, 2020: 5686-5696.
- [18] ZHAO H S, SHI J P, QI X J, et al. Pyramid scene parsing network [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). July 21-26, 2017, Honolulu, HI, USA. IEEE, 2017: 6230-6239.
- [19] STOREY G, MENG Q G, LI B H. Leaf disease segmentation and detection in apple orchards for precise smart spraying in sustainable agriculture [J/OL]. *Sustainability*, 2022, 14 (3) [2025-11-10]. <https://doi.org/10.3390/su14031458>.
- [20] JIANG K, AFZAAL U, LEE J. Transformer-based weed segmentation for grass management [J/OL]. *Sensors*, 2023, 23 (1) [2025-11-10]. <https://doi.org/10.3390/s23010065>.
- [21] LEE C J, YANG M D, TSENG H H, et al. Single-plant broccoli growth monitoring using deep learning with UAV imagery[J/OL]. *Computers and Electronics in Agriculture*, 2023, 207 [2025-11-10]. <https://doi.org/10.1016/j.compag.2023.107739>.
- [22] 李孟成. 基于深度学习的油菜叶片生长信息监测方法与装置研究[D]. 武汉: 华中农业大学, 2023.
- LI M C. Research on monitoring method and device of rape leaf growth information based on deep learning[D]. Wuhan: Huazhong Agricultural University, 2023. (Ch).
- [23] YU H Y, DONG M, ZHAO R H, et al. Research on precise phenotype identification and growth prediction of lettuce based on deep learning [J/OL]. *Environmental Research*, 2024, 252 [2025-11-10]. <https://doi.org/10.1016/j.envres.2024.118845>.
- [24] HUANG H M, LIN L F, TONG R F, et al. UNet 3+: A full-scale connected UNet for medical image segmentation [C]//ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). May 4-8, 2020, Barcelona, Spain. IEEE, 2020: 1055-1059.
- [25] 于营, 王春平, 付强, 等. 语义分割评价指标和评价方法综述[J]. *计算机工程与应用*, 2023, 59(6): 57-69.
- YU Y, WANG C P, FU Q, et al. Survey of evaluation metrics and methods for semantic segmentation [J]. *Computer Engineering and Applications*, 2023, 59(6): 57-69. (Ch).
- [26] BENIAICH A, SILVA M L N, AVALOS F A P, et al. Determination of vegetation cover index under different soil management systems of cover plants by using an unmanned aerial vehicle with an onboard digital photographic camera [J]. *Semina: Ciências Agrárias*, 2019, 40(1): 49-66.
- [27] XIANG B B, WIELGOSZ M, KONTOGIANNI T, et al. Automated forest inventory: Analysis of high-density airborne LiDAR point clouds with 3D deep learning[J/OL]. *Remote Sensing of Environment*, 2024, 305 [2025-11-10]. <https://doi.org/10.1016/j.rse.2024.114078>.
- [28] 董默. 基于深度学习的生菜表型精准鉴定与应用研究[D]. 长春: 吉林大学, 2024.
- DONG M. Research on accurate phenotyping and application of lettuce based on deep learning [D]. Changchun: Jilin University, 2024. (Ch).
- [29] 魏晋启. 基于分形维数和深度学习的水稻生长阶段识别[D]. 武汉: 华中农业大学, 2023.
- WEI J Q. Identification of rice growth stages based on fractal dimension and deep learning [D]. Wuhan: Huazhong Agricultural University, 2023. (Ch).
- [30] WANG J L, HAN Y, ZHAO S S, et al. A new multi-scale analytic algorithm for edge extraction of strawberry leaf images in natural light [J]. *International Journal of Agricultural and Biological Engineering*. 2016, 9 (1) : 99-108.
- [31] SHAHIDUL I, TOWFIQ R, HAMIDUL IMD, et al. Leaf-based varietal categorization of sweetpotato (*Ipomoea batatas* L. Lam.), a potentially healthful vegetable, using image processing and K-means clustering [J]. *Journal of Agriculture, Food, Environment and Animal Sciences*. 2025, 6(1): 31-49.
- [32] CHEN L C, ZHU Y K, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]//FERRARI V, HEBERT M, SMINCHISCU C, et al. *Computer Vision-ECCV 2018*. Cham: Springer, 2018: 833-851.
- [33] OKTAY O, SCHLEMPER J, LE FOLGOC L, et al. Attention U-Net: Learning where to look for the pancreas [DB/OL]. (2018-05-20) [2025-11-10]. <https://arxiv.org/abs/1804.03999>.
- [34] CHEN J N, LU Y Y, YU Q H, et al. TransUNet: Transformers make strong encoders for medical image segmentation [DB/OL]. (2021-02-08) [2025-11-10]. <https://arxiv.org/abs/2102.04306>.
- [35] QIN X B, ZHANG Z C, HUANG C Y, et al. U2-Net: going deeper with nested U-structure for salient object detection [J/OL]. *Pattern Recognition*, 2020, 106 [2025-

- 11-10]. <https://doi.org/10.1016/j.patcog.2020.107404>.
- [36] XIE E Z, WANG W H, YU Z D, et al. SegFormer: simple and efficient design for semantic segmentation with transformers [DB/OL]. (2021-10-28) [2025-11-10]. <https://arxiv.org/abs/2105.15203>.
- [37] ROGGIOLANI G, SODANO M, GUADAGNINO T, et al. Hierarchical approach for joint semantic, plant instance, and leaf instance segmentation in the agricultural domain [DB/OL]. (2023-06-14) [2025-11-10]. <https://arxiv.org/abs/2210.07879>
- [38] 陈庆山. 水蕨的生物学特性观察和人工繁育探索[D]. 福州: 福建农林大学, 2013.
- CHEN Q S. Observation of biological characteristics and artificial propagation for aquatic fern *Ceratopteris thalictroides* [D]. Fuzhou: Fujian Agriculture and Forestry University, 2013. (Ch).

## Intelligent visual monitoring of growth status and comprehensive GPI evaluation method for *Ceratopteris pteridoides* based on improved UNet3+

HU Huili<sup>1,2</sup>, YE Xi<sup>1,2</sup>, ZENG Changli<sup>2</sup>, DONG Yuanhuo<sup>2</sup>

(1. School of Intelligent Manufacturing, Jiangnan University, Wuhan 430056, China;

2. School of Life Sciences, Jiangnan University / Hubei Engineering Research Center for the Conservation, Development and Utilization of Characteristic Biological Resources in the Hanjiang River Basin, Wuhan 430056, China)

**Abstract:** *Ceratopteris pteridoides*, an aquatic fern classified as a second-level nationally protected wild plant, holds significant ecological value. Scientifically monitoring its growth status is crucial for elucidating its endangerment mechanisms and formulating conservation strategies. In this study, computer vision technology was employed to collect and construct a comprehensive image dataset covering its entire growth cycle. Building upon the UNet3+ image segmentation model, a Euclidean distance self-attention mechanism was introduced to enhance the model's efficiency in utilizing global contextual information and its ability to retain fine features, thereby improving segmentation accuracy for aquatic plants with complex leaf morphologies and slender stems. Based on the image segmentation results, morphological parameters such as canopy coverage, shape factor, and greenness index were extracted. A comprehensive growth status monitoring index (GPI) is constructed to enable quantitative analysis of the growth status of *Ceratopteris pteridoides*. The results indicated that the GPI values were less than 0.27 during the seedling stage, between 0.27 and 0.44 during the rapid growth stage, and greater than 0.44 at the maturity stage, demonstrating the effectiveness of GPI in distinguishing growth stages. These findings provide a technical reference for the intelligent monitoring of growth status in other aquatic plants.

**Key words:** *Ceratopteris pteridoides*; image segmentation; Euclidean distance selfattention; growth status monitoring; quantitative assessment