

MFENet: 面向植物伪装的多频边缘检测网络

祁杰, 张生*, 韩韧

上海理工大学光电信息与计算机工程学院, 上海

收稿日期: 2025年2月25日; 录用日期: 2025年3月18日; 发布日期: 2025年3月27日

摘要

本文针对植物伪装检测任务中低信噪比、动态干扰与细粒度识别问题, 提出一种多频边缘动态检测网络 MFENet, 以提升复杂生态场景下的隐蔽植物检测精度与鲁棒性。在 MFENet 中, 采用多尺度频率分离模块处理低信噪比问题, 通过多尺度分组卷积分离低频全局特征与高频细节特征。同时, 构建了通道感知边缘注意力模块, 结合 Sobel 边缘先验与通道-空间注意力优化细粒度特征。为进一步提升检测精度, 提出了边缘强度驱动的动态迭代反馈机制, 自适应调整计算复杂度。在 PlantCamo 数据集上, 与通用的伪装检测模型相比, MFENet 在各指标上提升明显。消融实验验证了各模块的有效性。MFENet 显著提升了植物伪装检测的精度与效率, 为生态保护与农业监测提供可靠技术支撑。

关键词

植物伪装检测, 目标检测, 注意力机制, 动态迭代

MFENet: Multi-Frequency Edge Detection Network for Plant Camouflage

Jie Qi, Sheng Zhang*, Ren Han

School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai

Received: Feb. 25th, 2025; accepted: Mar. 18th, 2025; published: Mar. 27th, 2025

Abstract

This paper addresses the problems of low signal-to-noise ratio, dynamic interference, and fine-grained recognition in the task of plant camouflage detection. We propose a multi-frequency edge dynamic detection network (MFENet) to enhance the accuracy and robustness of concealed plant

*通讯作者。

文章引用: 祁杰, 张生, 韩韧. MFENet: 面向植物伪装的多频边缘检测网络[J]. 建模与仿真, 2025, 14(3): 588-597.
DOI: 10.12677/mos.2025.143249

detection in complex ecological scenes. MFENet employs a multi-scale frequency separation module to address the low signal-to-noise ratio issue by utilizing multi-scale grouped convolutions to separate low-frequency global features from high-frequency detail features. Additionally, we construct a Channel-Aware Edge Attention module that combines Sobel edge priors with channel-space attention to optimize fine-grained features. To further enhance detection accuracy, we introduce an edge intensity-driven dynamic iterative feedback mechanism to adaptively adjust computational complexity. On the PlantCamo dataset, MFENet shows significant improvements in all evaluation metrics compared to conventional camouflage detection models. Ablation studies validate the effectiveness of each module. MFENet significantly enhances the accuracy and efficiency of plant camouflage detection, providing reliable technical support for ecological protection and agricultural monitoring.

Keywords

Plant Camouflage Detection, Object Detection, Attention Mechanism, Dynamic Iteration

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

伪装[1]作为自然界中生物适应环境的核心生存策略,生物通过隐蔽自身或模仿环境特征以规避捕食或捕获猎物[2],已成为进化生物学与生态学的重要研究课题。在计算机视觉领域中,伪装目标检测技术[3](Camouflaged Object Detection, COD)由于其在复杂背景条件下识别与背景高度相似目标的挑战性,已逐步成为研究热点。现有研究成果表明,COD在医学图像分析、自然灾害检测、军事迷彩侦察和野生动物保护[3]等多个领域具有显著的应用价值。

然而,与动物和人类伪装相比,植物伪装的研究尚显不足。植物伪装检测[4](Plant Camouflaged Object Detection, PCOD)的研究仍处于起步阶段。生物研究表明,植物通过颜色融合(如叶绿素与背景植被的色谱匹配)、纹理拟态(如兰花模拟昆虫形态,蜜蜂兰模拟蜜蜂)、结构伪装(如石斛兰茎干模拟树皮纹理)等策略实现隐蔽,此类机制对传统COD模型提出特殊挑战。低信噪比特性,与动物相比,植物的伪装策略在光谱维度上更具局限性。动物可通过色素多样性(如变色龙)或动态调整体表结构(如章鱼皮肤)实现多波段光谱匹配,而植物主要依赖叶绿素主导的绿色光谱和固定形态特征。研究表明,植物伪装的光谱自由度较低[5],其绿色通道(RGB空间)的反射曲线与背景的差异度通常小于动物场景,这与其生理限制(如光合作用需求)直接相关。动态干扰敏感,自然光照变化与枝叶晃动导致表观特征不稳定。细粒度识别需求,需区分叶片边缘锯齿、半透明新芽等微观特征。

植物伪装检测研究具有重要的科学意义和广泛的应用价值。深入研究伪装植物的检测方法,不仅有助于理解植物适应环境的生存策略,还可为生态学研究提供新的视角,提升物种识别的准确性,为农业生产中的濒危植物保护和生长监控提供技术支持。此外,在军事与安全领域,该技术可用于伪装目标的侦查与监测。结合遥感与无人机技术,植物伪装检测在自然保护、植被恢复及非法采伐防控等方面也有着重要的应用潜力,对生态环境保护与可持续发展意义深远。

为了评估现有COD模型在植物伪装检测任务中的表现,我们基于专用数据集 PlantCamo [4]对先进COD模型进行了训练与测试。实验表明,尽管这些模型在传统COD数据集(如COD10K [3]、CHAMELEON

[3]、NC4K [6]上表现良好,但在 PlantCamo 数据集上的性能普遍较差,原因在于植物伪装的特征与传统数据集中以动物和人类为主的伪装特征存在显著差异。而对于最新的植物伪装检测框架 PCNet [4],该模型采用了多尺度特征增强(MGFE)和多尺度特征细化(MFR)模块,尽管其在性能上有所提升,但仍存在计算复杂度高和内存需求大的问题,尤其在处理高分辨率图像时限制明显。另外,PCNet 中的迭代反馈机制在实验中表现最佳时迭代次数为 2 次,这可能限制了模型在更复杂场景下的表现。为解决上述问题,本文提出了一种改进的植物伪装检测模型 MFENet,通过多尺度频率分离、通道感知边缘注意力和优化迭代反馈机制,旨在进一步提升植物伪装检测的性能与效率。

本文的主要贡献如下:

- 1) 提出了一种改进的植物伪装检测模型 MFENet,进一步提升植物伪装检测的性能与效率。
- 2) 设计了多尺度频率感知分离模块通过低频和高频信息的分离与融合,帮助网络从多尺度和多频率的角度理解图像,提升了网络对检测目标整体结构的感知能力。
- 3) 设计了通道感知边缘注意力机制,有效提升了网络对检测目标边缘细节的敏感性。
- 4) 提出了动态迭代反馈机制,根据图像复杂度实现精度与效率的自适应平衡。

2. 方法

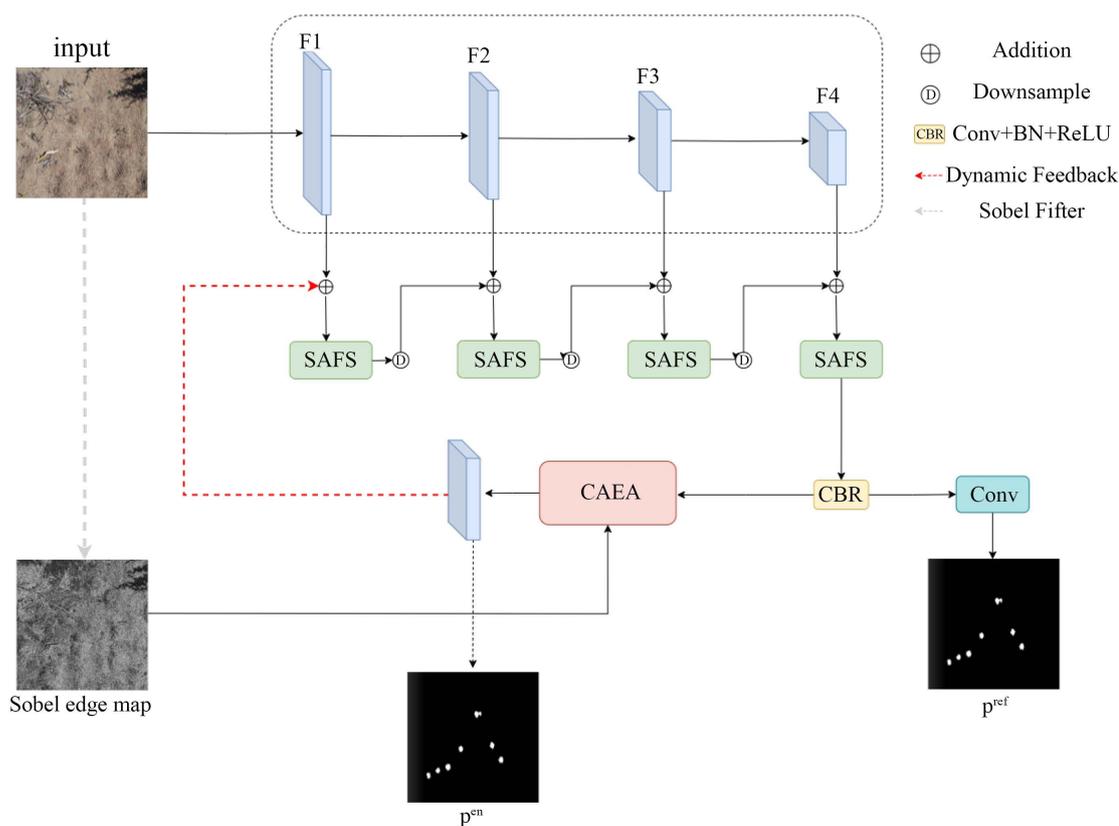


Figure 1. Overall architecture
图 1. 总体架构

如图 1 所示网络采用 Pyramid Vision Transformer (PVT) [7]作为骨干网络,从输入图像中提取多层次特征(即 F1, F2, F3, F4)。为了准确检测伪装植物,网络使用自下而上的方法,依次经过尺度感知频率分离模块(Scale-Aware Frequency Separation Module, SAFS),该模块负责处理提取的多尺度特征图,通过

低频和高频信息的分离与融合，帮助网络从多尺度和多频率的角度理解图像，提高对伪装目标和背景之间微小差异的敏感性。随后在最高层处理完后，得到融合细化特征 SF_i 以及预测图 $pref$ 。 SF_i 继续输入到 CAEA 模块(Channel-Aware Edge Attention Module)中，在 SAFS 模块输出的特征图基础上结合边缘特征优化高频细节，得到 SFC_i 。 SFC_i 作为反馈特征，如图所示继续输入到网络中。最终的特征图经过卷积操作(Conv)和激活函数(ReLU)处理后，输出伪装目标的检测结果。

2.1. SAFS 模块

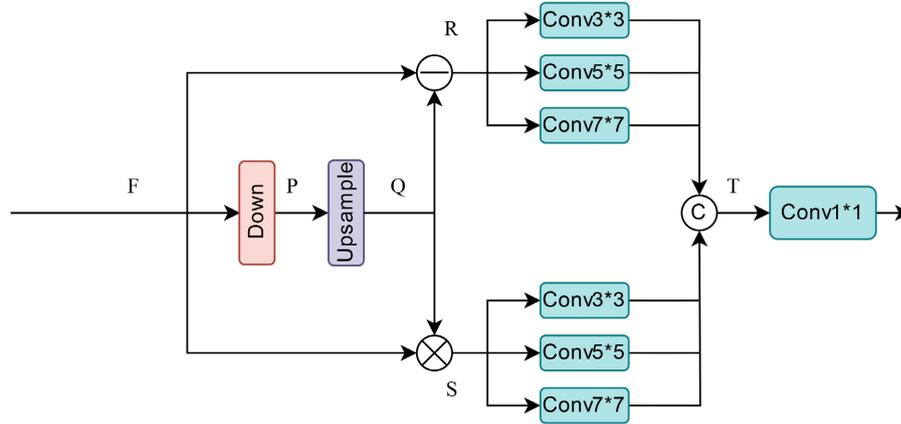


Figure 2. SAFS module
图 2. SAFS 模块

受图像处理中的锐化与对比度增强技术启发，我们设计了一种新颖的 SAFS 模块，用于同时提取图像中的低频背景信息和高频细节特征，从而提升植物伪装检测中对伪装物体与背景细微差异的敏感性。SAFS 模块结构如图 2 所示。 $F \in \mathbb{R}^{C \times H \times W}$ 作为 SAFS 模块的输入，首先经过下采样获得下采样特征图 $P \in \mathbb{R}^{C \times H/2 \times W/2}$ 。在图像处理中，常常通过取图像与其模糊版本的差异来增强高频部分。因此，SAFS 模块采用类似的方法，通过对平滑的特征图 P 上采样到与 F 相同的空间分辨率以获得 Q 特征。此时，通过计算输入特征图 F 与上采样后的特征图 Q 之间的差异，能够突出细节部分，从而得到 R (细节增强后的特征图)，即高频部分。SAFS 中的第二个分支(底部)致力于捕捉特征图中的低频区域。这对于强调伪装区域(如伪装物体的大致轮廓)至关重要。为了实现这一点，我们通过输入图像 F 与其模糊版本 Q 的逐元素乘积操作，得到 S (低频部分)。低频信息主要反映了图像的宏观结构，因此这一操作有助于保留和强化伪装物体的整体形状。之后，模块会对低频和高频信息分别进行不同尺度的卷积处理。这些卷积操作采用了不同大小的卷积核，包括 3×3 、 5×5 、 7×7 卷积核。这些不同尺度的卷积核分别用于提取不同尺度上的特征，使得网络能够从多角度捕捉伪装目标的局部和全局特征。较小的卷积核(3×3)能够有效捕捉细节信息，而较大的卷积核(5×5 和 7×7)则帮助捕捉更大范围的特征和背景信息。最后，经过不同尺度卷积后的特征图会被拼接在一起得到特征 T 。拼接操作将多个卷积核提取到的特征合并在一起，为后续的网络层提供更丰富的信息。拼接后的特征图会通过一个 1×1 的卷积进行通道压缩，减少特征图的通道数并输出最终的特征表示 \bar{F} 。这一过程不仅有效地减少了计算量，还保持了特征的丰富性，最终生成适合用于后续任务的特征图。通过这一系列操作，SAFS 模块成功地在多个尺度上提取和分离低频与高频信息，使得网络在面对植物伪装的挑战时，能够同时关注到伪装目标的整体结构和细节特征。低频特征帮助网络识别伪装目标的整体轮廓，而高频特征则增强了对细小伪装细节的感知，最终提升了模型在复杂背景下

的鲁棒性和精度。

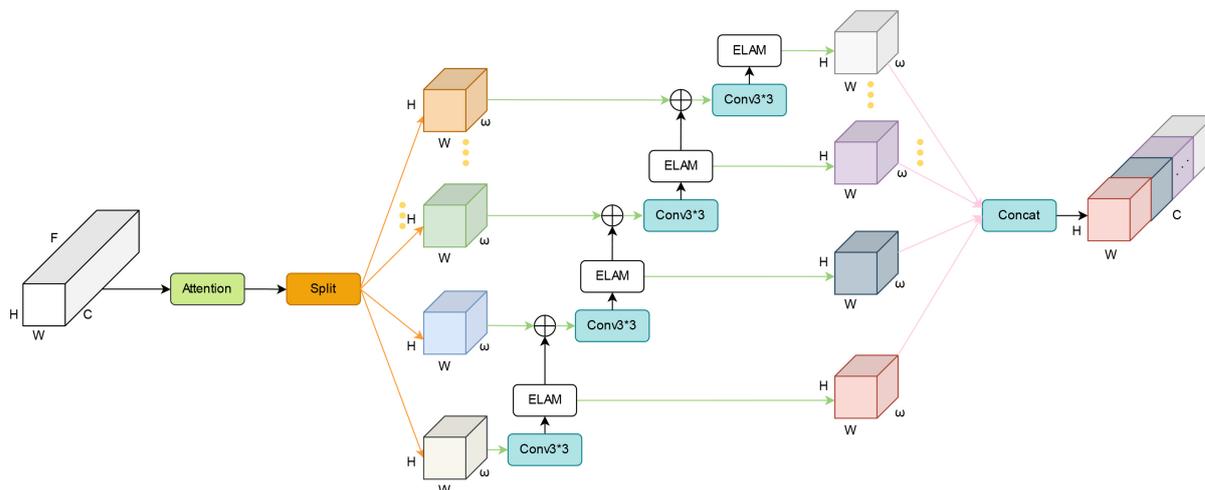


Figure 3. CAEA module

图 3. CAEA 模块

2.2. CAEA 模块

输入图像在经过骨干网络特征提取和SAFS模块处理后,对伪装目标的整体感知效果有了明显提升,但仍存在边缘模糊与背景干扰等问题,CAEA(Channel-Aware Edge Attention)通道感知边缘注意力模块旨在通过融合边缘先验与多粒度通道注意力解决相关问题。如图3所示,给定 $F \in \mathbb{R}^{C \times H \times W}$ 作为输入特征图,首先经过一个通道注意力,处理后的特征图通过split操作将 F 沿通道维度均匀分割成 s 个特征图子集,记为 $F_i \in \mathbb{R}^{\omega \times H \times W}$ (其中 $i \in \{1, 2, \dots, s\}$)。每个特征子集具有与相同的空间形状,但具有 ω 个通道。当 i 为1时, F_1 经过Conv操作后输入到ELAM模块中得到 F_1^e 。接下来,将特征图子集 F_i 与输出 F_{i-1}^e 相加然后经过Conv操作再输入到ELAM中得到 F_i^e 。重复该过程直到处理完所有特征图子集。最后,通过拼接的方式,可以得到整个增强的多尺度特征图 $F^e = \text{Concat}([F_1^e, F_2^e, \dots, F_s^e])$ 。

2.3. ELAM 模块

伪装目标通常与背景在颜色和纹理上高度相似,因此,边缘信息在伪装目标检测中起着至关重要的作用。为了增强模型对目标边缘的感知能力,我们设计了边缘学习注意力模块(Edge Learning Attention Module, ELAM),其目的是通过引导模型关注伪装目标的边缘区域,提升检测精度和鲁棒性。如图4所示,ELAM模块的设计包括两个主要步骤:边缘先验图的生成和边缘注意力的学习。首先,通过经典的索贝尔算子(Sobel Operator)对输入图像进行处理,生成边缘先验图(Edge Prior Map)。索贝尔算子能够有效地捕捉图像中的梯度变化,提取出伪装目标与背景之间的边缘特征,从而确保模型获得可靠的边缘信息。随后,ELAM模块接收边缘先验图和当前特征图作为输入。为了保证两者的一致性,边缘特征图首先被上采样至与当前特征图相同的尺寸,并与当前特征图进行逐元素相乘,生成边缘增强特征图。此增强特征图经过卷积、BatchNormalization和ReLU激活(CBR)处理后,生成初步特征表示。为了进一步优化特征表达,处理后的特征图通过注意力机制进行加权,并与原始输入特征图进行残差连接,确保原始信息的保留。最后,ELAM通过卷积块注意力模块(CBAM)进一步提升特征的辨识度,最终生成优化后的输出特征图。

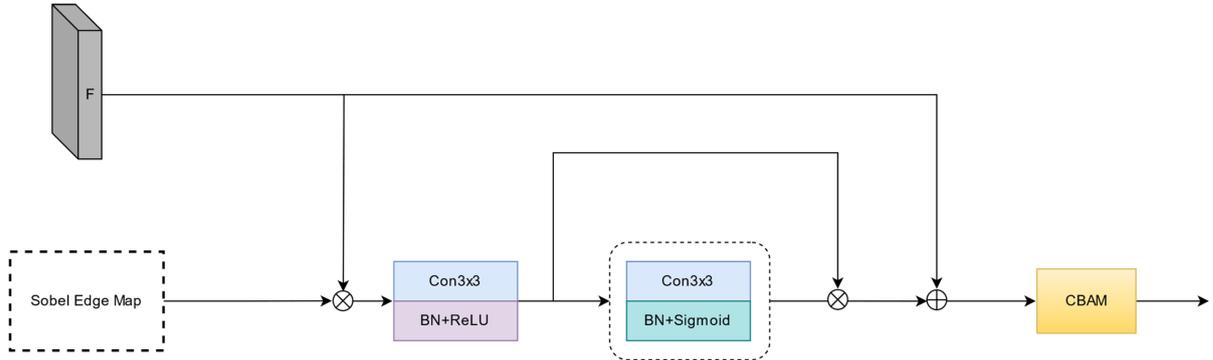


Figure 4. ELAM module
图 4. ELAM 模块

2.4. 动态迭代反馈

针对植物伪装场景中光照变化与枝叶晃动导致的特征不稳定性，本文提出一种边缘强度驱动的动态迭代反馈机制。另外动态迭代反馈机制让网络在处理简单图像时能够高效运行，而在处理复杂图像时则能够进行更多次的迭代，从而获得更精确的特征表达。在实现上，首先将输入图像转为灰度图像 G ，然后使用 Sobel 滤波器提取图像的边缘信息。边缘信息的计算通过对灰度图像进行水平和垂直方向的边缘检测，得到并通过平方和开根号的方式计算图像的边缘强度 E 。然后通过对边缘强度的均值进行计算得到当前图像的复杂度，计算方式如下： $C = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W E_{i,j}$ 接下来，根据当前图像的复杂度系统会动态调

$$\text{迭代次数: } \text{iter} = \begin{cases} 3, & \text{if } C > 0.5 \\ 2, & \text{if } 0.2 < C \leq 0.5 \\ 1, & \text{if } C \leq 0.2 \end{cases}$$

每次迭代中，特征图与之前迭代的输出进行相加，形成新的输入。

这种反馈机制使得网络能够根据前一次迭代的结果进行调整，从而逐步改进特征图的表达。通过引入动态迭代反馈机制，网络能够在复杂背景和动态变化的场景下，自动适应不同图像的复杂度，提升检测精度的同时，保持计算效率。这种灵活的计算过程使得模型能够在各种环境中表现出更强的鲁棒性，特别适用于植物伪装检测任务中的复杂场景。

3. 实验

3.1. 数据集

我们使用由 Yang 等人最新构建的 PlantCamo 数据集[4]。PlantCAMO 数据集涉及 58 种伪装植物，涵盖了植物伪装研究中调查的大多数类型。PlantCamo 数据集分为 3 个子集：PlantCamo-full、PlantCamotrain 和 PlantCamo-test。PlantCamo-full 集包含 1250 张伪装植物图像的全部集合，主要用于评估 COD 模型的泛化能力。PlantCamo-train，包含 1000 张用于训练的图像，PlantCamo-test，包含 250 张指定用于测试的图像。

3.2. 实验细节和评价指标

我们采用了四种常见的评估指标，分别是 Structure-measure (S_α) [8]、Adaptive E measure (E_ϕ) [9]、Weighted F-measure (F_ω^β) [10]和 Mean Absolute Error (M) [11]。这些指标能够全面衡量 MFENet 在伪装目标检测任务中的性能，从结构、感知、准确率和误差等多个维度进行评估。 S_α 是一种基于结构相似性的评估指标，它衡量预测图和真实掩膜在空间结构上的相似性。 S_α 通过计算两者的区域相似性和边缘相

似性，将局部和全局的结构信息结合起来进行评价，能够有效反映伪装目标检测中的空间结构一致性。 E_ϕ 是一种结合感知和数学评估的指标，专门用于衡量预测结果与真实标签的相似性。 E_ϕ 通过考虑全局和局部的像素对齐性，将用户的感知特性和计算结果结合起来，可以更加准确地反映模型的感知效果，特别是在复杂背景下伪装目标的分割能力。 F_ω^β 综合了 Precision 和 Recall，针对目标区域和背景的像素不均衡情况进行加权处理，旨在准确衡量模型在不同重要性区域的表现。通过对较难检测的伪装区域赋予更高权重， F_ω^β 能够更加准确地评估模型在伪装目标检测中的精确度和召回率。 M 主要用于衡量预测结果与真实标签在像素级的平均误差。它计算预测掩码与真实掩码之间的逐像素差异，能够直接反映模型的整体误差水平，是衡量伪装目标检测中分割精度的重要标准。这些评估指标从不同的角度出发，能够全面评估模型在伪装目标检测任务中的性能表现，确保在不同类型的场景和目标下都能取得优异的结果。

3.3. 实验细节

我们的模型使用 PyTorch 框架进行实现，并在两张 NVIDIA GeForce RTX 3090 GPU 上进行加速。在训练过程中，我们使用来自 PlantCAMO-train 的 1000 张伪装植物图像作为训练集。为了提高训练的泛化能力，我们对输入图像进行了数据增强操作，包括将图像分辨率调整为 702×702 ，并应用了随机水平翻转策略。我们采用了 Adam 优化器，设置批次大小(batch size)为 8，epoch 为 100，学习率设置为 1×10^{-4} ，衰减率为 0.1。

3.4. 实验结果

Table 1. Evaluation results of different network models on the PlantCamo dataset
表 1. 不同网络模型在 PlantCamo 数据集上的评估结果

Model	$S_\alpha \uparrow$	$E_\phi \uparrow$	$F_\omega^\beta \uparrow$	$M \downarrow$
SINet [3]	0.766	0.842	0.583	0.066
ZoomNet [12]	0.798	0.874	0.680	0.049
SINet-V2 [13]	0.801	0.873	0.678	0.050
BGNet [14]	0.786	0.873	0.552	0.076
HitNet [15]	0.854	0.929	0.794	0.034
PCNet [4]	0.880	0.937	0.818	0.028
MFENet (Ours)	0.886	0.939	0.816	0.028

为了证明模型的有效性，我们对 MFENet 与其他通用 COD 方法以及专门用于植物伪装检测任务的 PCNet 进行比较，实验结果如表 1 所示。其中，通用 COD 模型(SINet 等)的评价指标均是模型在 PlantCamo 数据集中进行了训练后测试的结果。可以发现，相较于通用 COD 模型，在植物伪装检测任务中，MFENet 在各项指标均有大幅提升。MFENet 以 0.886 的 S_α 值显著优于所有模型，这一优势主要归功于 SAFS 模块的多尺度频率分离策略，提升了模型对检测目标的整体结构感知能力。 E_ϕ 结合局部像素对比度与全局统计量，动态调整误差权重，适用于评估复杂背景下的像素级预测准确性。MFENet 以 0.939 的值达到最优，这一提升主要得益于动态迭代反馈机制和 CAEA 模块的边缘强化驱动，使得模型在边缘细节上拥有更好的表现。 F_ω^β 通过平衡精度和召回率来评估分割结果的整体性能，实验结果显示，本文模型 F_ω^β 值为 0.816，略低于 PCNet (0.818)，但显著优于其他模型(HitNet: 0.794)。 M 是预测值与真实值之间差值的绝对值的平均值，MFENet 值为 0.028，与 PCNet 相同且优于其他模型。

3.5. 消融实验

为验证本文所提模块的有效性，我们在 PlantCamo 数据集上进行了系统的消融实验，分别测试 SAFS 模块、CAEA 模块、ELAM 模块及动态迭代机制对模型性能的影响。首先删除所有模块作为基准模型，随后依次在模型中添加 SAFS 模块、CAEA 模块、ELAM 模块。实验结果见表 2。可以发现，引入 SAFS 后， S_α 从 0.862 提升至 0.877， M 从 0.034 下降至 0.031，降低了 8.8%。表明其通过多尺度频率分离策略，有效缓解了低信噪比问题。SAFS 与 CAEA 联合作用使 MAE 降低 17.6% (0.034 \rightarrow 0.028)，表明了各模块协同对细粒度误差抑制的关键作用。表 3 反映了不同迭代次数对模型性能的影响，实验中，我们取固定迭代次数 1, 2, 3 次和动态迭代进行对比，结果也证明了动态迭代的有效性。

Table 2. Quantitative evaluation for ablation studies
表 2. 消融研究的定量评估

SAFS	CAEA (no ELAM)	ELAM	$S_\alpha \uparrow$	$E_\phi \uparrow$	$F_\omega^\beta \uparrow$	$M \downarrow$
			0.862	0.925	0.790	0.034
√			0.877	0.931	0.808	0.031
√	√		0.880	0.936	0.814	0.030
√	√	√	0.886	0.939	0.816	0.028

Table 3. Ablation study on different iteration numbers
表 3. 不同迭代次数的消融研究

Iteration times	$S_\alpha \uparrow$	$E_\phi \uparrow$	$F_\omega^\beta \uparrow$	$M \downarrow$
iter = 1	0.879	0.927	0.808	0.032
iter = 2	0.884	0.939	0.812	0.029
iter = 3	0.880	0.934	0.814	0.030
Dynamic	0.886	0.939	0.816	0.028

4. 结束语

本文提出一种新的植物伪装检测模型 MFENet，设计的主要思想是通过 SAFS 模块的多尺度频率分离策略处理低信噪比问题，以让网络更好地感知目标整体结构，通过 CAEA 模块提高网络对微小边缘特征的敏感性。实验结果显示，本文提出的 MFENet 在 PlantCamo 数据集上表现明显优于通用 COD 模型，与专用于植物伪装的 PCNet 相比也有一定提升。尽管如此，在极端低信噪比的场景下，模型仍然存在细微的检测误差，未来的研究可以从多模态数据融合，三维形态感知增强、跨任务迁移与自监督学习等方面展开，以进一步提升模型性能。

参考文献

- [1] Stevens, M. and Merilaita, S. (2008) Animal Camouflage: Current Issues and New Perspectives. *Philosophical Transactions of the Royal Society B: Biological Sciences*, **364**, 423-427. <https://doi.org/10.1098/rstb.2008.0217>
- [2] Skelhorn, J. and Rowe, C. (2016) Cognition and the Evolution of Camouflage. *Proceedings of the Royal Society B: Biological Sciences*, **283**, 20152890. <https://doi.org/10.1098/rspb.2015.2890>
- [3] Fan, D., Ji, G., Sun, G., Cheng, M., Shen, J. and Shao, L. (2020) Camouflaged Object Detection. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, 13-19 June 2020, 2774-2784. <https://doi.org/10.1109/cvpr42600.2020.00285>

-
- [4] Yang, J., Wang, Q., Zheng, F., *et al.* (2024) PlantCamo: Plant Camouflage Detection. <https://doi.org/10.48550/arXiv.2410.17598>
- [5] Roy, P.S. (1989) Spectral Reflectance Characteristics of Vegetation and Their Use in Estimating Productive Potential. *Proceedings/Indian Academy of Sciences*, **99**, 59-81. <https://doi.org/10.1007/bf03053419>
- [6] Lv, Y., Zhang, J., Dai, Y., Li, A., Liu, B., Barnes, N., *et al.* (2021) Simultaneously Localize, Segment and Rank the Camouflaged Objects. 2021 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Nashville, 20-25 June 2021, 11586-11596. <https://doi.org/10.1109/cvpr46437.2021.01142>
- [7] Wang, W., Xie, E., Li, X., Fan, D., Song, K., Liang, D., *et al.* (2022) PVT V2: Improved Baselines with Pyramid Vision Transformer. *Computational Visual Media*, **8**, 415-424. <https://doi.org/10.1007/s41095-022-0274-8>
- [8] Fan, D., Cheng, M., Liu, Y., Li, T. and Borji, A. (2017) Structure-measure: A New Way to Evaluate Foreground Maps. 2017 *IEEE International Conference on Computer Vision (ICCV)*, Venice, 22-29 October 2017, 4558-4567. <https://doi.org/10.1109/iccv.2017.487>
- [9] Fan, D., Gong, C., Cao, Y., Ren, B., Cheng, M. and Borji, A. (2018) Enhanced-Alignment Measure for Binary Foreground Map Evaluation. *Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence*, Stockholm, 13-19 July 2018, 698-704. <https://doi.org/10.24963/ijcai.2018/97>
- [10] Margolin, R., Zelnik-Manor, L. and Tal, A. (2014) How to Evaluate Foreground Maps. 2014 *IEEE Conference on Computer Vision and Pattern Recognition*, Columbus, 23-28 June 2014, 248-255. <https://doi.org/10.1109/cvpr.2014.39>
- [11] Perazzi, F., Krahenbuhl, P., Pritch, Y. and Hornung, A. (2012) Saliency Filters: Contrast Based Filtering for Salient Region Detection. 2012 *IEEE Conference on Computer Vision and Pattern Recognition*, Providence, 16-21 June 2012, 733-740. <https://doi.org/10.1109/cvpr.2012.6247743>
- [12] Pang, Y., Zhao, X., Xiang, T., Zhang, L. and Lu, H. (2022) Zoom in and Out: A Mixed-Scale Triplet Network for Camouflaged Object Detection. 2022 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, New Orleans, 18-24 June 2022, 2150-2160. <https://doi.org/10.1109/cvpr52688.2022.00220>
- [13] Fan, D., Ji, G., Cheng, M. and Shao, L. (2022) Concealed Object Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **44**, 6024-6042. <https://doi.org/10.1109/tpami.2021.3085766>
- [14] Sun, Y., Wang, S., Chen, C. and Xiang, T. (2022) Boundary-guided Camouflaged Object Detection. *Proceedings of the Thirty-First International Joint Conference on Artificial Intelligence*, Vienna, 23-29 July 2022, 1335-1341. <https://doi.org/10.24963/ijcai.2022/186>
- [15] Hu, X., Wang, S., Qin, X., Dai, H., Ren, W., Luo, D., *et al.* (2023) High-Resolution Iterative Feedback Network for Camouflaged Object Detection. *Proceedings of the AAAI Conference on Artificial Intelligence*, **37**, 881-889. <https://doi.org/10.1609/aaai.v37i1.25167>