doi:10.6041/j.issn.1000-1298.2026.03.033

基于改进 YOLO 11 的海鲜菇生长阶段精细化分类方法

杨淑珍　朱浩宇　杨凯威
（上海第二工业大学智能制造与控制工程学院，上海 201209）

摘要：生长阶段精细化分类是实现海鲜菇菇房环境智慧、精准调控的前提。然而，由于海鲜菇调控所需生长阶段划分较为精细，且相邻阶段的表型特征高度相似，使其生长阶段的精细化分类难度较大。针对此问题本研究提出一种改进 YOLO 11 生长阶段精细化分类方法。首先，在 YOLO 11 主干网络中融合全局注意力机制（Global attention mechanism，GAM），通过增强通道注意力和空间注意力，更有效地提取海鲜菇的关键特征；其次，将激活函数由 SiLU 更改为 Mish，有效增强了网络的非线性表达能力；最后将原始卷积优化为幻影卷积，在保持高精度目标检测的同时，简化模型结构并优化了计算效率。本文所改进模型的识别准确率为 96.97%，召回率为 96.73%，平均精度均值为 96.58%，精确率为 96.81%，并且模型的推理时间和模型参数量分别缩减了 4.28% 和 21.69%，优于 RF－SVM、ResNet50、YOLO v8 和 YOLO 11。这些结果表明，本文所提出的改进方法具备更优的综合性能，能够有效地应用于海鲜菇生长阶段精细化分类。

关键词：海鲜菇；生长阶段精细化分类；图像识别；YOLO 11；深度学习
中图分类号：TP391.4；S126　　**文献标识码**：A　　**文章编号**：1000-1298(2026)03-0342-11　　**OSID**：

Fine-grained Classification of Growth Stages of Seafood Mushroom Based on Improved YOLO 11

YANG Shuzhen　ZHU Haoyu　YANG Kaiwei
(*School of Intelligent Manufacturing and Control Engineering*, *Shanghai Polytechnic University*, *Shanghai* 201209, *China*)

Abstract: Fine-grained classification of growth stages is a prerequisite for achieving intelligent and precise environmental control in seafood mushroom cultivation. However, due to the subtle phenotypic differences between adjacent growth stages and the high granularity of stage division required for regulation, accurate classification remains challenging. An enhanced YOLO 11-based method for fine-grained growth stage classification was proposed. Firstly, a global attention mechanism (GAM) was integrated into the YOLO 11 backbone network to enhance channel and spatial attention, thereby improving the extraction of discriminative features. Secondly, the activation function was replaced with Mish to strengthen the network's nonlinear representation capability. Finally, the original convolution was optimized to GhostConv, simplifying the model architecture while maintaining high detection accuracy and computational efficiency. Experimental results demonstrated that the improved algorithm achieved a recognition accuracy of 96.97%, a recall rate of 96.73%, a mean average precision (mAP) of 96.58%, and a precision of 96.81%. Furthermore, the inference time and model parameters were reduced by 4.28% and 21.69%, respectively, outperforming that of RF－SVM, ResNet50, YOLO v8, and the original YOLO 11. These results indicated that the proposed method exhibited superior comprehensive performance and can be effectively applied to fine-grained classification of seafood mushroom growth stages, providing a robust foundation for intelligent environmental regulation in mushroom cultivation.

Key words: seafood mushroom; fine-grained classification of growth stages; image recognition; YOLO 11; deep learning

收稿日期：2025－04－24　修回日期：2025－07－25
基金项目：上海市农业科技创新项目（沪农科（I2023003））和上海科学技术委员会科研计划项目（21N21900600）
作者简介：杨淑珍（1978—），女，教授，博士，主要从事智慧农业、采摘机器人和深度学习研究，E-mail：szyang@sspu.edu.cn

0　引言

随着全球农业向智能化、精细化方向发展，智慧农业已成为现代农业转型升级的重要方向。智慧农业通过集成物联网、大数据、人工智能等先进技术，实现对农业生产全过程的精准监测与智能调控，从而提高农业生产效率、降低资源消耗、提升农产品品质[1]。食用菌产业作为农业的重要组成部分，也面临着智能化转型迫切需求[2]。海鲜菇作为一种中偏低温型食用菌，近年来在市场上赢得了广泛的认可和持续的青睐。据统计，海鲜菇的市场规模在过去 5 年内以年均超过 6% 的速度快速增长[3-4]。

目前，生产者主要依靠人工识别海鲜菇 27 d 精细生长阶段，据此给出菇房的环境执行装置的控制策略。这种方法需要耗费较多人力，而且主观性强，效果取决于观察者的专业能力和经验。计算机视觉为海鲜菇生长阶段的识别提供了一种创新的解决方案。钟杨等[5-6]针对袋栽模式下海鲜菇的多时期生长状态，提出了一种基于颜色、形状和纹理等关键特征提取的分类方法，结合多种特征选择算法与分类模型，采用 RF－SVM 实现了海鲜菇不同生长时期的分类。该方法在粗粒度分类任务中表现良好，最高分类准确率达到 91.875%，但其在实际应用中仍存在以下不足：海鲜菇相邻精细生长阶段的特征差异更为细微，传统方法难以实现高精度分类；特征提取过程依赖人工设计，通用性和适应性较差，难以满足复杂生产环境下的需求。

相比之下，基于深度学习的目标检测在农业领域表现出色，在智慧农业研究中得到了极大的关注。SCHIECK 等[7]提出了一种基于深度学习的方法来识别葡萄生长阶段，该方法采用级联计算机视觉方法在微水平上对葡萄的发育阶段进行分类和区分，实验结果表明 ResNet 架构提供了最佳的分类效果，平均准确率达到 88.1%，但该网络的召回率仅为 74.7%，所提出网络的鲁棒性和泛化能力欠佳；徐建鹏等[8]提出了一种基于 RAdam 优化器的 ResNet50 卷积神经网络水稻生育期图像识别方法，通过引入图像分割技术和参数调优，该方法在真实场景下分类识别准确率达到 97.33%，相比传统人工观测和未使用 RAdam 优化器的模型，识别精度有了大幅提升，但是对于分蘖期与拔节期等分类特征不明显的生育期识别率仍有待进一步提高，在复杂环境下的稳定性也需加强；为了克服此问题，扶兰兰等[9]提出了一种基于 Swin Transformer 的玉米生长期分类方法，通过迁移学习策略，在测试集上实现了 98.7% 的分类准确率，优于 ResNet 模型，然而，Swin Transformer 模型在计算资源消耗和训练时间成本方面较高，对硬件性能要求较为苛刻，难以适应智慧农业场景中常见的低带宽和资源受限环境。作为目标检测领域的重要框架，YOLO 系列模型因其高效性和实时性在农业领域得到了广泛应用[10-11]。龙洁花等[12]提出了一种基于改进 YOLO v4 的温室环境下草莓生育期识别方法，引入注意力机制和特征融合模块，该方法在温室环境下的草莓生育期识别中，平均精度均值达到 83.79%，相比 YOLO v4 模型提高了 8.7%。尽管精度得到了提升，但增加了模型参数数量，这可能导致模型在类似智慧农业领域计算资源有限的环境中部署困难；SAPKOTA 等[13]提出了一种基于 YOLO 11 的苹果检测分类方法，通过利用 DALL－E 生成的合成数据集和优化的训练策略，显著提高了苹果检测的精度和召回率，为复杂果园环境下的目标分类任务提供了高效解决方案。然而，海鲜菇的生长阶段精细化分类任务与辣椒生长时期分类存在显著差异，海鲜菇生长阶段的识别属于细粒度分类领域，其对分类的精细程度要求更高，面临着更为复杂的挑战。在细粒度分类任务中，不同生长阶段的海鲜菇可能在外观上仅有细微差别，例如菌丝覆盖程度、菌盖的纹理、颜色的深浅变化等，这些细微特征对于准确分类至关重要，但也增加了识别的难度，传统的适用于少分类任务的方法往往难以直接应用于此类精细化分类场景。

综上所述，尽管计算机视觉在图像分类、目标检测等任务上取得了显著进展，但在针对特定农产品如海鲜菇的生长阶段精细化分类领域，目前的研究仍相对匮乏。传统的计算机视觉方法在面对海鲜菇这种相邻阶段特征相近、难以直观区分的挑战时，往往难以达到理想的分类效果。本文在充分调研和分析现有技术的基础上，提出一种改进 YOLO 11 的海鲜菇生长阶段精细化分类方法，以满足食用菌行业智慧栽培的迫切需要，为实现海鲜菇菇房环境智慧、精准调控提供智能精细化分类基础。

1　材料与方法

1.1　海鲜菇生长图像采集

本研究的海鲜菇图像数据采集工作于工厂化生产的标准化海鲜菇出菇房内完成。图像采集系统由固定式成像装置构成，并通过千兆工业以太网传输到戴尔 R750 型服务器（总存储容量 8 TB）中。工业相机（索尼 IMX586 型图像传感器）通过防震支架固定于不锈钢工作平台。物距控制在（500 ± 50）mm 范围内，采集系统示意图如图 1a 所示。摄像头焦距为 0.85 mm，分辨率为 4 000 像素 ×3 000 像素。实

验期间,摄像头每隔 6 h 采集一次海鲜菇生长图像,现场采集环境如图 1b 所示。

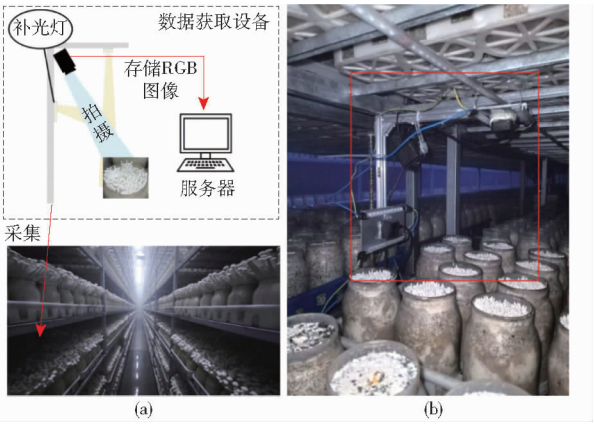

图 1 生长图像采集示意图

Fig. 1 Schematics of growth image capture

1.2 海鲜菇生长图像数据集构建

数据集记录了海鲜菇 27 个阶段的整个生长周期,涵盖了菌丝萌发、子实体形成和成熟期全时期,主要生长阶段示例如图 2 所示。

基于 YOLO v8 的实时检测框架,构建全自动图像预处理流程:首先通过部署在服务器内的 ONNX 推理引擎实现海鲜菇目标区域的自动识别与 ROI 提取[14],采用非极大值抑制(NMS 为 0.45)确保单株菌体定位精度;随后执行自适应尺寸归一化,使用双线性插值算法将裁剪后的子图像统一缩放至 1 280 像素 ×1 280 像素;最后同步运行质量评估模块,采用 Laplacian 梯度算子(阈值大于 120)自动剔除模糊帧,最终生成标准数据集[15]。

将数据集按照比例 8∶1∶1划分为训练集、验证集和测试集。随机选择亮度变换、旋转、加噪、缩放以及镜像对训练集图像进行增强,提升模型的鲁棒性。

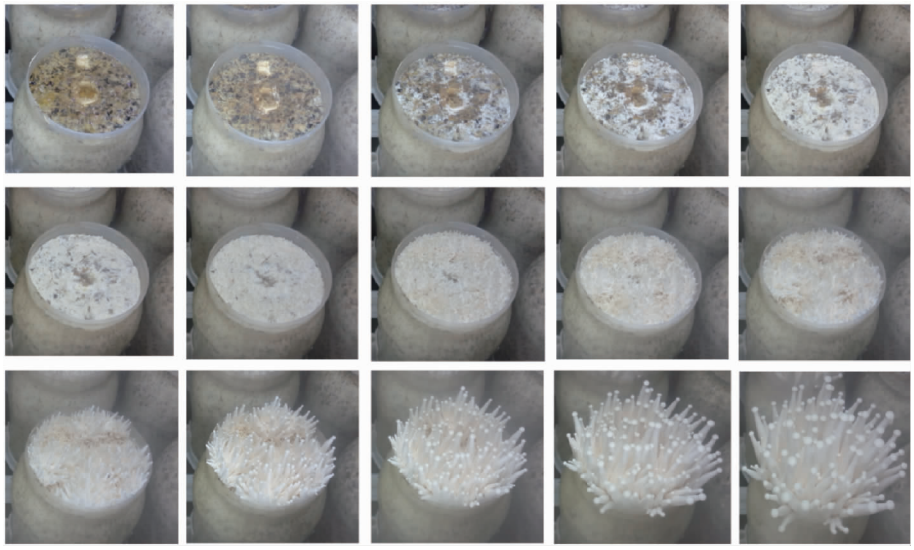

图 2 海鲜菇主要生长阶段图像示例

Fig. 2 Image examples of main growth stages of seafood mushrooms

数据预处理后海鲜菇精细化生长阶段数据集共计 8 640 幅图像,每个精细阶段各 320 幅。

2 海鲜菇生长阶段精细化分类模型设计

2.1 改进的 YOLO 11 分类模型总体框架

作为最新版本的 YOLO 系列模型,YOLO 11 在多尺度特征融合与轻量化架构方面有显著突破。相较于前代模型,YOLO 11 通过引入自适应跨阶段特征聚合机制,有效提升了复杂生物特征的表征能力[16];同时采用动态稀疏卷积核技术,在保持检测精度的前提下将推理速度也得到提升。这些改进策略适用于处理海鲜菇生长阶段精细化分类中存在的相邻阶段表型特征相似度高、形态渐变过程难以检测等技术难点[17]。

YOLO 11 的网络架构由输入模块(Input)、主干网络(BackBone)、颈部网络(Neck)和检测头(Head)4 个关键部分组成,它们分别负责数据输入、特征提取、特征处理和目标检测任务。在预处理环节,通过数据增强技术提升样本多样性,同时采用无锚点检测机制优化非极大值抑制(Non - maximum suppression,NMS)的后处理效率。主干网络采用基于 CSP(Cross stage partial)的设计,结合 C3k2 模块实现计算效率与模型性能的平衡,在保证检测精度的同时降低了计算度。其中 C3k2 模块是基于传统 C3 模块的改进设计,它通过结合可变卷积核(例如 3 ×3、5 ×5 等)和通道分离策略,提供更强大的特征提取能力。另外,C2PSA 模块是 YOLO 11 中用于增强特征提取的一个高级模块,结合了 CSP 结构和 PSA(Pyramid squeeze attention)注意力机制,从而提

升了多尺度特征提取能力，可有效地提高分类的准确率[18]。

然而，YOLO 11 应用于海鲜菇生长阶段精细化分类时，仍暴露出一些局限性。一方面，原始模型在处理海鲜菇生长相邻阶段时，特征区分度不够敏锐，容易出现误判，致使分类准确率有所下滑。另一方面，由于海鲜菇生长环境复杂，无法较好地排除冗余噪声的影响，捕捉海鲜菇的生长特征。因此，本研究以 YOLO 11 为主干，针对卷积、注意力机制以及激活函数 3 个关键模块实施了改进。改进后的 YOLO 11 是一种准确、高效的目标检测模型，优化后模型网络结构如图 3 所示。

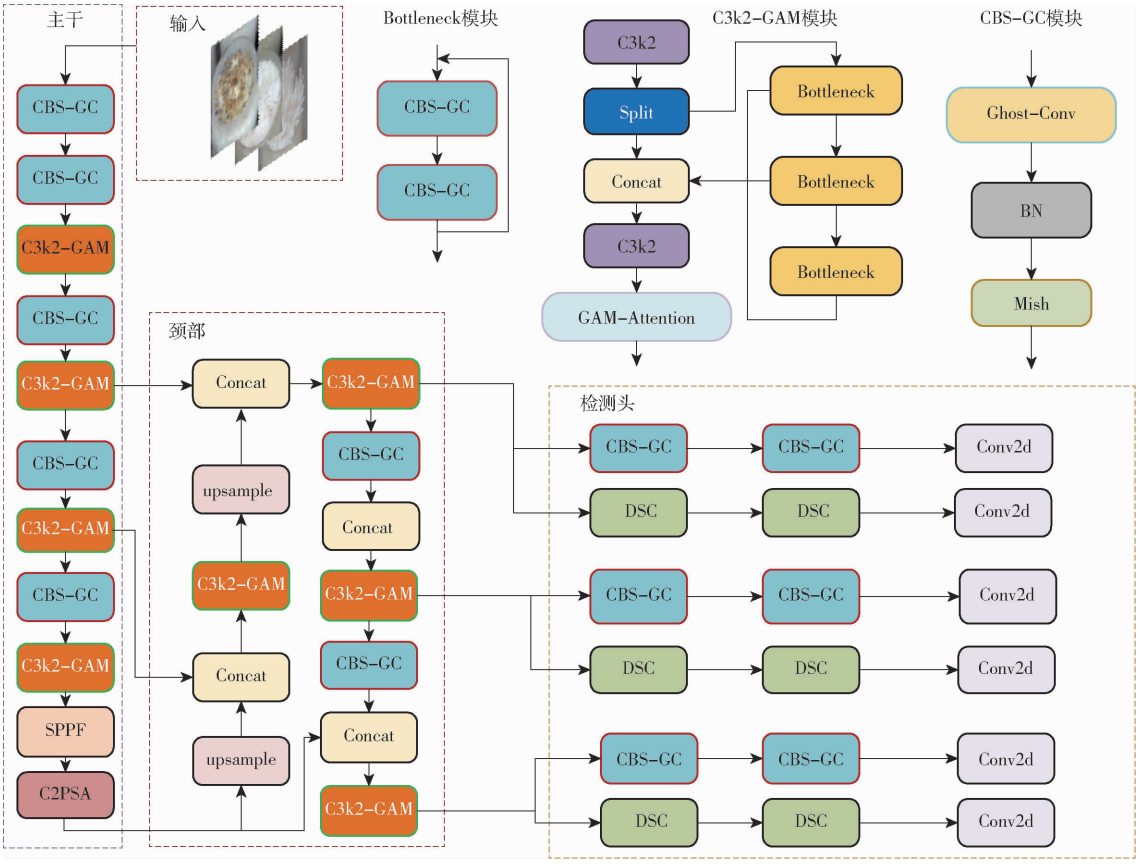

图 3　改进的 YOLO 11 网络结构图

Fig. 3　Network structure diagram of improved YOLO 11

2.2　Conv 优化为 GhostConv

幻影卷积（GhostConv）作为轻量化神经网络架构设计的新型模块[19]，在海鲜菇生长阶段精细化分类任务中可减少模型运行的参数量。其网络结构如图 4 所示：首先对输入的海鲜菇生长图像进行深度特征编码，通过标准卷积核生成基础特征图；随后采用多组参数共享的线性变换操作，在低计算代价下扩展生成具有互补表征的幻影特征图组。这些特征图通过多尺度感受野捕获海鲜菇关键生长指标，形成多维特征表达矩阵。最终将原始特征图与幻影特征图沿通道维度进行深度融合，构建高信息密度的特征向量送入分类器。研究表明，GhostConv 模块通过特征生成机制与参数复用策略，相较于传统卷积模块，GhostConv 可在不影响性能的情况下，简化模型结构，提高计算效率，实现更快速、更准确的海鲜菇精细化分类[20-21]。

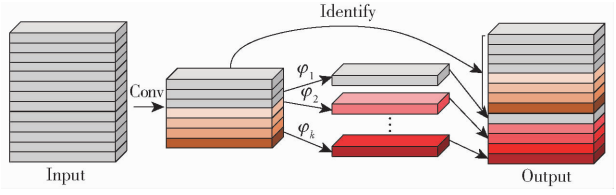

图 4　GhostConv 网络结构图

Fig. 4　GhostConv network structure

2.3　SiLU 激活函数替换为 Mish

在优化目标检测模型时，引入 Mish 激活函数替换传统 YOLO 11 中的 SiLU 激活函数，以强化网络模型的非线性映射能力。Mish 激活函数具有非单调性和平滑特性[22-23]，在深度神经网络中可提升精度。

在海鲜菇生长阶段精细化分类任务中，YOLO 11 中原有的 SiLU 激活函数在当深度神经网络输入值较小或较大时会出现梯度消失的问题，导致模型训练困难。此外，SiLU 激活函数存在零梯度和偏置偏移问题，在处理复杂的非线性特征时，其激活神经元的效果不够理想，从而影响模型对海鲜菇不同生

长阶段特征的捕捉。相比之下,Mish 激活函数能够更有效地激活神经元,避免梯度消失和神经元失活问题,增强模型的稳定性和鲁棒性,使其能够更精确地捕捉海鲜菇随不同阶段变化的非线性特征,区分不同阶段的海鲜菇,以及排除非海鲜菇的噪声,提高模型的泛化能力和鲁棒性。在 YOLO 11 网络模型中将原来的激活函数替换为 Mish 激活函数,增强模型的表达能力和学习能力,进一步提高模型的精确性。Mish 激活函数如图 5 所示,其计算公式为

$$\begin{cases} g(x) = \ln(1 + e^x) \\ f(x) = x\tanh(\ln(1 + e^x)) \end{cases}$$

式中 $\tanh(\cdot)$——双曲正切函数

$g(x)$——softplus 表示公式

$f(x)$——Mish 激活函数

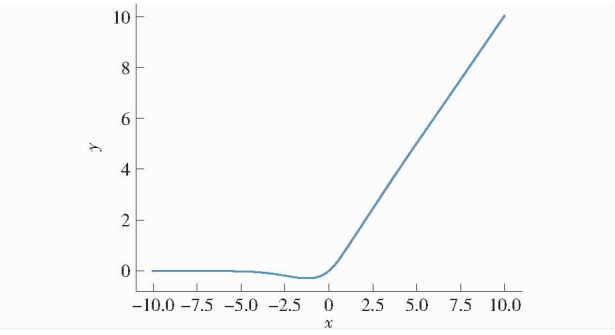

图 5 Mish 激活函数

Fig. 5 Mish activation function

图 6 为 CBS − GC 结构示意图。该结构在 YOLO 11 的 CBS 结构基础上进行了优化。

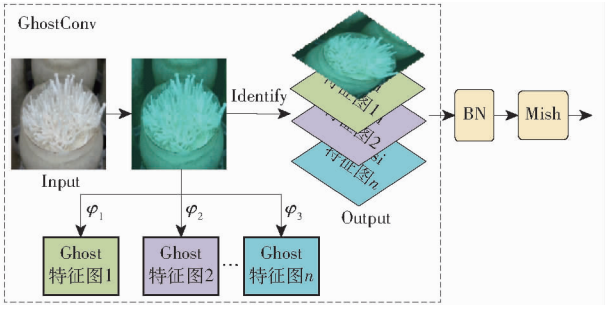

图 6 CBS − GC 结构示意图

Fig. 6 CBS − GC structure

2.4 融合 GAM 注意力模块

在目标检测模型中融合 GAM 注意力模块,可显著增强卷积神经网络对多尺度目标的特征表征能力[24]。如图 7 所示,GAM 注意力模块由通道注意力子模块(Channel attention module,CAM)与空间注意力子模块(Spatial attention module,SAM)级联构成,其工作机制为:针对输入的海鲜菇特征图,通道注意力首先通过维度重构实现通道间全局依赖建模,将特征图进行矩阵变换后输入多层感知机(Multilayer perceptron,MLP),经跨通道非线性映射

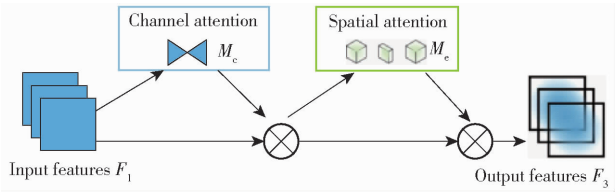

图 7 全局注意力机制网络结构图

Fig. 7 Network structure of global attention mechanism

后还原原始维度,最终通过 Sigmoid 函数激活生成通道权重系数矩阵,该过程可有效捕获跨通道的长程语义关联。空间注意力采用双阶段卷积架构实现特征选择,先通过 7×7 卷积核执行通道降维以压缩计算复杂度,再利用同尺寸卷积核重构通道维度,最终经 Sigmoid 函数构建非线性空间特征筛选机制[25]。2 个子模块通过顺序执行通道−空间双域注意力调控,协同优化网络对海鲜菇图像中的色彩、纹理及形态关键特征的聚焦能力并抑制冗余噪声的干扰。同时,通过引入自适应平均池化和最大池化机制来计算通道权重,使网络能够同时整合输入海鲜菇图像特征图的均值与极值信息[26]。GAM 注意力模块在 YOLO 11 中的实验表明,它可以较大提高改进的 YOLO 11 在数据集上的准确率。

基于上述理论,本方法在 Backbone 和 Neck 的 C3k2 结构中引入了 GAM 模块,将其改进为新的模块 C3k2 − GAM,其具体结构如图 8 所示。

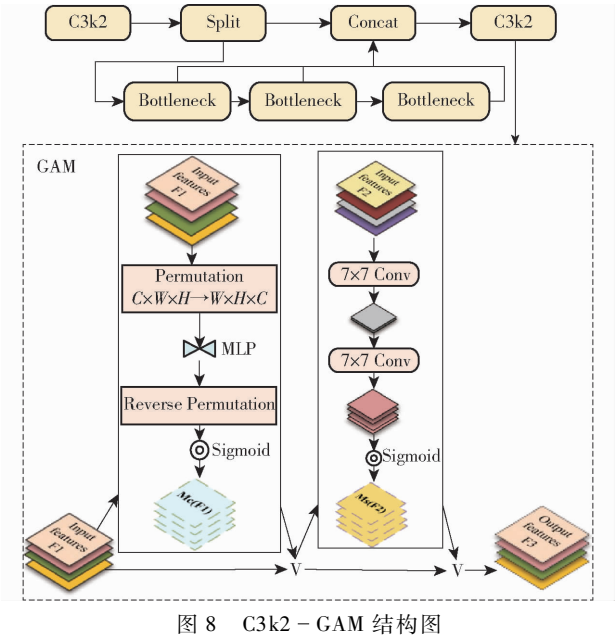

图 8 C3k2 − GAM 结构图

Fig. 8 C3k2 − GAM structure

3 实验与结果分析

3.1 实验环境及超参数设计

本文模型的训练与测试实验在以下硬件和软件环境下进行:搭载 Intel Xeon W − 2255 处理器(主频

3.70 GHz)、64 GB 内存、NVIDIA GeForce RTX 4090 显卡的计算机平台，运行 Windows 10 64 位操作系统。实验采用 PyTorch 1.12.0 深度学习框架，基于 Python 3.8 编程环境实现。网络模型的输入分辨率为 640 × 640 × 3，训练参数设置为：迭代周期(epoch)600，批量大小 16，最大学习率 0.000 1，并选用随机梯度下降作为优化算法。

3.2　实验评价指标

为了评估神经网络的性能，引入准确率(Accuracy，Acc)、精确率(Precision，P)、召回率(Recall，R)和平均精度均值(Mean average precision，mAP)对识别结果进行评价[27]。准确率是指所有的海鲜菇样本中，识别生长阶段正确的图像占比。精确率是模型所检测出的处于某一海鲜菇生长阶段的结果中，正确判断的部分占所有检测结果的比例。召回率表示在所有海鲜菇生长阶段的图像中，模型成功检测到的目标海鲜菇生长阶段图像的占比。平均精度均值表示在所有海鲜菇生长阶段类别上，每个类别的平均精度(AP)的平均值，AP 表示某一生长阶段的识别准确率。

3.3　模型对比实验

3.3.1　不同激活函数对比实验

为评估 Mish 激活函数在海鲜菇生长阶段识别中的性能优势，本研究以 YOLO 11 为基础框架，系统对比了 Mish、SiLU、PReLU 及 Hardswish 4 种激活函数。在改进型 YOLO 11 目标检测框架中，卷积神经网络用来提取海鲜菇图像的空间特征，全连接层则负责将特征向量映射到目标检测任务中的生长阶段和空间坐标输出。采用 Mish 激活函数替代 SiLU 激活函数作为各层激活单元，可有效改善卷积层特征提取模块及全连接层非线性变换环节中的梯度传播特性，从而提升海鲜菇精细化生长阶段分类模型的性能。实验结果如图 9 所示，采用 Mish 激活函数的 YOLO 11 模型在性能指标上表现突出，其准确率和召回率分别达到 95.32% 和 95.73%，与 YOLO 11 - SiLU、YOLO 11 - Hardswish、YOLO 11 - PReLU 相比，准确率分别提高 0.51、0.98、0.74 个百分点，召回率分别提高 1.13、1.27、0.56 个百分点。

3.3.2　不同注意力机制对比实验

为探究 GAM 注意力机制的性能，在保持实验条件一致的情况下，将 CBAM(Convolutional block attention module)注意力机制[28]、CA(Coord attention)注意力机制[29]和 SEA(Squeeze and excitation attention)注意力机制[30]分别嵌入到 YOLO 11 的特征提取网络中。通过对比不同注意力机制作用下的网络模型识别精度，评估各注意力

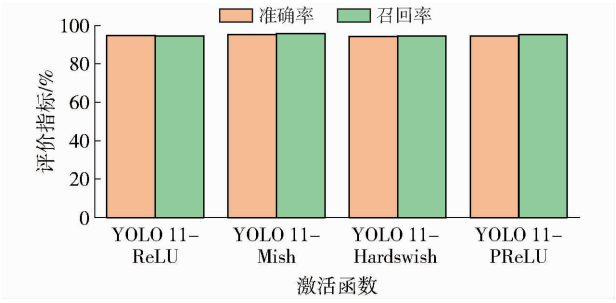

图 9　YOLO 11 结合不同激活函数结果图

Fig. 9　Histogram of results of YOLO 11 combined with different activation functions

的效果。

如图 10 所示，在海鲜菇生长周期的细粒度分类任务中，将 GAM 注意力机制整合至特征提取网络的方案展现出最优性能，其准确率和召回率分别达到 96.64% 和 95.92%，这一优势主要源于 GAM 注意力机制的多重优化策略，具体而言，SE 模块通过全局池化和全连接层生成通道权重；SK 模块实现卷积核的动态选择以增强网络性能；BAM 模块则采用瓶颈结构计算像素级权重，强化关键特征区域。实验结果表明，YOLO 11 - GAM 模型与 YOLO 11 - CBAM、YOLO 11 - CA、YOLO 11 - SEA 相比，准确率分别提高 1.59、3.11、2.42 个百分点，召回率分别提高 2.13、1.64、2.61 个百分点。

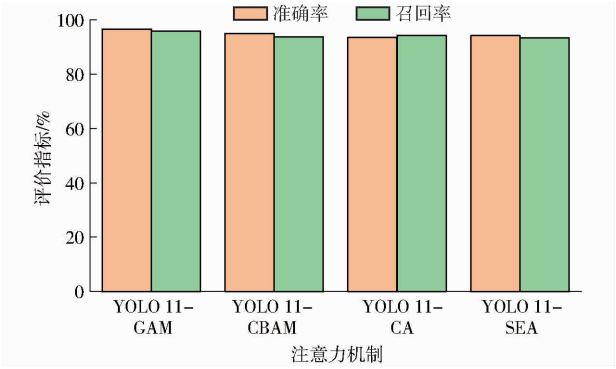

图 10　YOLO 11 融合不同注意力机制结果柱状图

Fig. 10　Histogram of results of YOLO 11 integrating different attention mechanisms

3.3.3　不同网络模型对比实验

为验证改进的 YOLO 11 模型在海鲜菇生长阶段精细化分类任务中的有效性，引入 RF - SVM、ResNet50、YOLO v8 和 YOLO 11 等模型，进行对比实验。实验过程中控制变量条件，未使用预训练权重迁移及多模型集成策略。比较结果如表 1 所示。

由表 1 可知，改进的 YOLO 11 模型与 RF - SVM、ResNet50、YOLO v8、YOLO 11 相比，平均精度均值分别提升 14.50、10.37、1.92、1.01 个百分点，准确率分别提升 12.20、9.00、3.60、2.58 个百分点，召回率分别提升 13.41、9.35、5.48、3.22 个百分点，

精确率分别提升 12.35、8.22、3.83、2.17 个百分点。

表 1 不同模型检测结果对比

Tab.1 Comparison of detection results of different models %

模型	准确率	平均精度均值	精确率	召回率
RF－SVM	84.77	82.08	84.46	83.32
ResNet50	87.97	86.21	88.59	87.38
YOLO v8	93.37	94.66	92.98	91.25
YOLO 11	94.39	95.57	94.64	93.51
改进的 YOLO 11	96.97	96.58	96.81	96.73

这说明改进的 YOLO 11 对于海鲜菇生长阶段精细化分类任务有着明显的优势和作用。

此外，如图 11a 所示，本文所提方法的训练损失函数曲线在初始的 50 个 epochs 内，梯度快速下降，随后过渡到更稳定的下降阶段，最终达到 0.116。通过对 Loss 曲线的对比分析可知，改进后的 YOLO 11 神经网络不仅损耗值最低，且其损失曲线变异性较小，展现出卓越的收敛特性。如图 11b 所示，改进的 YOLO 11 验证准确率曲线在初始阶段增长较为缓慢，随着迭代次数增加至约 100 次后，增长速度加快，随后逐渐趋于平稳。通过对验证准确率曲线的对比分析可知，改进后的 YOLO 11 不仅达到了较高的准确率，且其曲线波动相对较小，展现出良好的稳定性和收敛特性。

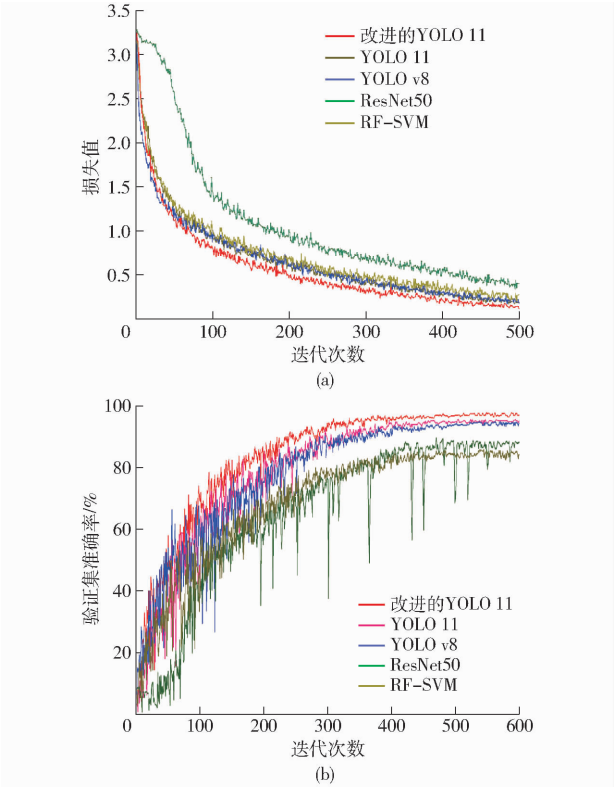

图 11 损失函数和准确率对比曲线

Fig. 11 Loss function and accuracy comparison curves

同时，为验证改进的模型能实现更快的检测速度以满足实际智慧农业场景中硬件部署要求，将改进的 YOLO 11 与 YOLO 11、YOLO v8、RF－SVM、ResNet50 模型在测试数据集上进行了对比，以模型的推理时间和参数量作为评价指标。

由表 2 可知，由于改进的 YOLO 11 模型引入 GhostConv，有效降低了传统卷积操作的计算复杂度。在对海鲜菇生长阶段精细化分类时，这一改进减少了模型计算复杂度和参数量。改进的 YOLO 11 模型参数量为 2.6×10^7，推理时间为 60.12 ms。相比于 YOLO v8 模型，参数量降低 22.85%，推理时间减少 11.12%；相比于 ResNet50 模型，参数量降低 75%，推理时间减少 38.67%；相比于 RF－SVM 模型，参数量提高 6.99%，推理时间减少 63.42%；相比于 YOLO 11 模型，参数量降低 21.69%，推理时间减少 4.28%。

表 2 不同模型性能参数对比

Tab.2 Comparison of different model performance parameters

模型	推理时间/ms	参数量
RF－SVM	164.37	2.43×10^7
ResNet50	98.03	1.03×10^8
YOLO v8	67.64	3.37×10^7
YOLO 11	62.81	3.32×10^7
改进的 YOLO 11	60.12	2.6×10^7

为了深入探究各对比模型在海鲜菇生长阶段细粒度分类任务中的性能瓶颈，进而验证改进 YOLO 11 模型的优越性，对各模型的架构特性与技术局限性展开系统性分析。首先 RF－SVM 是一种基于传统机器学习的分类方法，依赖人工设计的特征（如颜色、纹理和形状）进行分类。针对 RF－SVM 在特征提取过程缺乏自适应能力，难以捕捉海鲜菇相邻生长阶段如菌丝覆盖度的渐变或菌盖纹理等细微的表型差异，改进的 YOLO 11 模型通过融合 GAM 注意力机制模块增强学习能力，平均精度均值提高 14.50 个百分点，准确率提高 12.20 个百分点，召回率提高 13.41 个百分点，精确率提高 12.35 个百分点。其次，ResNet50 通过残差结构提高了模型的自适应能力且缓解了深层网络的梯度消失问题，但其密集的卷积层和庞大的参数量导致模型计算复杂度高，推理时间长达 98.03 ms。尽管 ResNet50 具备较强的特征提取能力，但在处理海鲜菇生长阶段分类时，冗余的网络层可能引入噪声干扰，且复杂的结构降低了模型对微小特征差异的敏感度，改进的 YOLO 11 模型通过融合 GhostConv 模块将单层卷积的计算量降低，在提高精度的同时降低了模型复杂

度，相比于 ResNet50 模型，参数量降低 75%，推理时间减少 38.67%，且平均精度均值提高 10.37 个百分点，准确率提高 9.00 个百分点，召回率提高 9.35 个百分点，精确率提高 8.22 个百分点。YOLO v8 模型采用无锚点检测机制和动态标签分配策略，提升了目标检测的灵活性，但其主干网络缺乏针对细粒度特征的优化设计，改进的 YOLO 11 模型通过对通道注意力和空间注意力的的级联组合，增强了卷积神经网络对细粒度目标的特征表征能力。相较于 YOLO v8，平均精度均值提高 1.92 个百分点，准确率提高 3.60 个百分点，召回率分别提高 5.48 个百分点，精确率提高 3.83 个百分点。原始的 YOLO 11 模型通过自适应跨阶段特征聚合和 C3k2 模块增强了多尺度特征融合能力，但仍存在两点不足：①模型处理小梯度变化时易导致神经元失活，影响对海鲜菇生长阶段连续变化的建模能力。②难以在复杂背景中聚焦菌丝、菌盖等关键区域。本文提出的改进的 YOLO 11 模型通过轻量化卷积设计、平滑非线性激活函数与多尺度注意力机制，有效强化了关键特征的提取能力，同时降低模型复杂度，显著提升了细粒度分类性能，平均精度均值提高 1.01 个百分点，准确率提高 2.58 个百分点，召回率提高 3.22 个百分点，精确率提高 2.17 个百分点，且参数量降低 21.69%，推理时间减少 4.28%。

实验结果表明，改进后的模型在参数量和推理时间展现了其在图像检测方面的优势，既保证了检测精度，又实现了模型轻量化，适合部署于海鲜菇环境智能调控系统的设备上。

3.4　消融实验

本文设计了消融实验，将改进模型与仅嵌入单一模块的变体及原始 YOLO 11 进行性能比较。通过系统性的消融实验，依次考察激活函数替换、GAM 注意力机制引入以及 GhostConv 应用对模型准确率的影响。实验结果如表 3 所示：单独采用 Mish 激活函数可使准确率提升 0.92 个百分点；仅集成 GAM 注意力机制可使准确率提升 2.19 个百分点；仅集成 GhostConv 可使准确率提升 0.37 个百分点；当 Mish、GAM 和 GhostConv 三者协同作用时，准确率提升幅度达到 2.58 个百分点。消融实验证实了所提方法在提升海鲜菇生长周期分类精度方面的有效性。

表 3　各个模块对 YOLO 11 网络性能的影响

Tab.3　Effects of each module on performance of YOLO 11 network

模型编号	Mish	GAM	GhostConv	准确率/%
1	×	×	×	94.39
2	√	×	×	95.31
3	×	√	×	96.58
4	×	×	√	94.76
5	√	√	√	96.97

注：√表示在网络中添加该模块，×表示在网络中不添加该模块。

3.5　海鲜菇生长阶段精细化分类实验结果

混淆矩阵是评价图像分类结果的有效方法之一[31]。在测试集上基于本文所提方法的海鲜菇生长阶段精细化分类混淆矩阵如图 12 所示，对角线元素代表模型正确预测的情况，从矩阵可以看出，对角线元素大多为 1，这表明模型在大部分类别上的预测准确率较高。

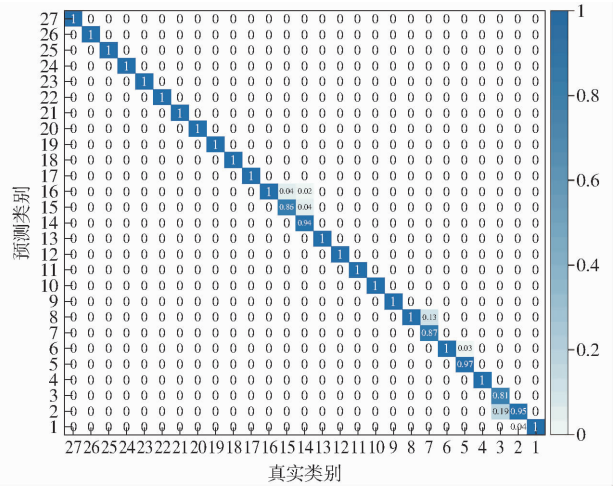

图 12　本文模型在测试集上生成的混淆矩阵

Fig. 12　Confusion matrix generated by proposed model on test set

其中准确预测部分：如第 1、8、9、10、12、13、18、19、20、21、22、23、24、25、26、27 阶段在对应自身真实类别的预测上概率为 1，说明模型对于这些类别的分类效果较优。

图 13 为基于改进的 YOLO 11 网络模型在海鲜菇生长阶段精细化分类结果样例。通过分析可知，海鲜菇生长阶段的预测偏差主要归因于以下因素：首先，相邻生长阶段（如第 2 阶段与第 1 阶段、第 15 阶段与 14/16 阶段）具有连续演变的生物学特征，其形态与生理指标的相似性较高，导致分类边界模糊；其次，生长过渡阶段的动态特征（如第 15 阶段兼具 14 阶段与 16 阶段的复合表型）增加了分类难度。具体而言，第 2 阶段因处于菌丝分化期，其特征信号弱且与第 1 阶段存在重叠，导致 4% 的样本被误判；而第 15 阶段海鲜菇帽尺寸、数量以及菇柄长度，特征都较为相似，误判率累计达 15%，表明其多维度特征耦合作用已超出当前模型的表征范围。因此，尽管本模型取得了较好的效果，但仍存在一些局限性。模型的性能可能受到数据集规模和质量的影

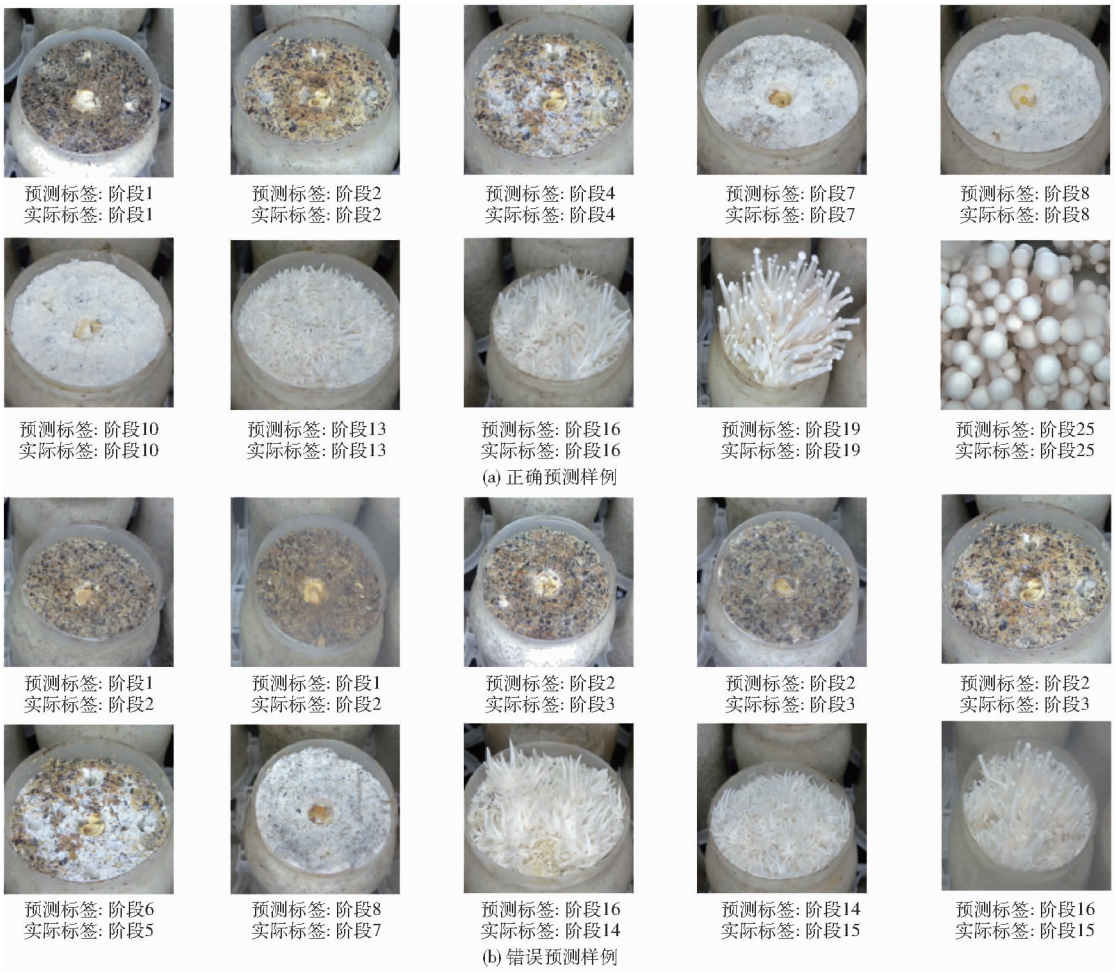

图 13 本文模型的海鲜菇生长阶段精细化分类结果

Fig. 13 Refined classification results of growth stages of seafood mushrooms in proposed model

响,虽然进行了数据增强,但实际生产环境中海鲜菇生长条件复杂多变,可能需要更大规模、更多样化的数据集来进一步提高模型的泛化能力,以适应不同环境下的海鲜菇精细化生长阶段识别任务。

4 结论

(1)针对海鲜菇生长阶段精细化分类的难点,本文对 YOLO 11 模型进行了多项改进。通过引入 GAM 注意力机制,增强了通道注意力和空间注意力,提高了关键特征的提取能力;将激活函数由 SiLU 更改为 Mish,有效增强了网络的非线性表达能力;采用幻影卷积(GhostConv)替代原始卷积,简化了模型结构并优化了计算效率。这些改进使得模型在保持高精度目标检测的同时,显著降低了推理时间和模型参数量。

(2)改进后的 YOLO 11 在海鲜菇生长阶段精细化分类任务中表现出色。与 RF - SVM、ResNet50、YOLO v8 和 YOLO 11 等模型相比,改进后的模型准确率、召回率、平均精度均值和精确率等关键指标均有显著提升。具体来说,识别准确率达到 96.97%,召回率为 96.73%,平均精度均值为 96.58%,精确率为 96.81%,均优于其他对比模型。此外,模型的推理时间和模型参数量分别缩减 4.28% 和 21.69%,展现出更高的效率和更低的资源消耗。

(3)本文提出的改进 YOLO 11 模型不仅具有优异的分类性能,还具备较高的实际应用潜力。它能够快速、准确地识别海鲜菇的生长阶段,为海鲜菇菇房环境的智慧、精准调控提供了可行的方案。

参 考 文 献

[1] 赵春江. 智慧农业的发展现状与未来展望[J]. 华南农业大学学报,2021,42(6):1 - 7.
ZHAO Chunjiang. Current situations and prospects of smart agriculture[J]. Journal of South China Agricultural University, 2021,42(6):1 - 7. (in Chinese)

[2] 鲍大鹏. 食用菌科学研究为食用菌产业发展提供越来越重要的科学支撑[J]. 菌物学报,2021,40(12):3061 - 3063.

BAO Dapeng. Scientific researches on edible mushrooms provide more and more important scientific support for the development of edible mushrooms industry[J]. Mycosystems,2021,40(12):3061 - 3063. (in Chinese)

[3] 谭硕果,王盈,孙颖慧. 海鲜菇的人工栽培、营养成分及加工利用研究进展[J]. 中国食用菌,2024,43(3):1 - 5.
TAN Shuoguo,WANG Ying,SUN Yinghui. Research progress on the artificial cultivation, nutrient composition, processing and utilization of *Hypsizygus marmoreus*[J]. Edible Fungi of China,2024,43(3):1 - 5. (in Chinese)

[4] 白雪萍,赵丽,田鑫,等. 海鲜菇栽培环境因子监控系统设计[J]. 中国农机化学报,2016,37(5):66 - 70.
BAI Xueping, ZHAO Li, TIAN Xin, et al. Design on monitoring system for environmental cultivation factors of *Hypsizygus marmoreus*[J]. Journal of Chinese Agricultural Mechanization, 2016, 37(5): 66 - 70. (in Chinese)

[5] 钟杨,杨淑珍,杜万和,等. 袋栽模式下海鲜菇的关键特征提取及多时期分类研究[J]. 计量与测试技术,2023,50(12):1 - 8.
ZHONG Yang,YANG Shuzhen, DU Wanhe,et al. Study on substantial features extraction and multi-period classification of sea mushroom under bag planting mode[J]. Metrology & Measurement Technique,2023,50(12):1 - 8. (in Chinese)

[6] ZHONG Y, DU W, YANG S, et al. Feature extraction and multi-period classification of sea mushroom based on image information[C] // 2022 International Conference on Artificial Intelligence, Information Processing and Cloud Computing (AIIPCC),2022:235 - 238.

[7] SCHIECK M, KRAJSIC P, FELIX L, et al. Comparison of deep learning methods for grapevine growth stage recognition[J]. Computers and Electronics in Agriculture, 2023, 211: 107944.

[8] 徐建鹏,王杰,徐祥,等. 基于 RAdam 卷积神经网络的水稻生育期图像识别[J]. 农业工程学报,2021,37(8):143 - 150.
XU Jianpeng, WANG Jie, XU Xiang, et al. Image recognition for different developmental stages of rice by RAdam deep convolutional neural networks[J]. Transactions of the CSAE,2021,37(8):143 - 150. (in Chinese)

[9] 扶兰兰,黄昊,王恒,等. 基于 Swin Transformer 模型的玉米生长期分类[J]. 农业工程学报,2022,38(14): 191 - 200.
FU Lanlan, HUANG Hao, WANG Heng, et al. Classification of maize growth stages using the Swin Transformer model[J]. Transactions of the CSAE,2022, 38(14):191 - 200. (in Chinese)

[10] 王泰华,郭亚州,张家乐,等. 基于改进 YOLO v5s 的水稻害虫识别研究[J]. 农业机械学报,2024,55(11):39 - 48.
WANG Taihua,GUO Yazhou,ZHANG Jiale,et al. Rice pest identification based on improved YOLO v5s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(11):39 - 48. (in Chinese)

[11] 苗荣慧,李港澳,黄宗宝,等. 基于 YOLO v7 - ST - ASFF 的复杂果园环境下苹果成熟度检测方法[J]. 农业机械学报,2024,55(6):219 - 228.
MIAO Ronghui, LI Gang'ao, HUANG Zongbao, et al. Maturity detection of apple in complex orchard environment based on YOLO v7 - ST - ASFF[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(6): 219 - 228. (in Chinese)

[12] 龙洁花,郭文忠,林森,等. 改进 YOLOv4 的温室环境下草莓生育期识别方法[J]. 智慧农业(中英文),2021,3(4):99 - 110.
LONG Jiehua, GUO Wenzhong, LIN Sen, et al. Strawberry growth period recognition method under greenhouse environment based on improved YOLOv4[J]. Smart Agriculture, 2021, 3(4): 99 - 110. (in Chinese)

[13] SAPKOTA R, MENG Z, KARKEE M, et al. Synthetic meets authentic: leveraging LLM generated datasets for YOLO 11 and YOLOv10-based apple detection through machine vision sensors[J]. Smart Agricultural Technology, 2024,9:100614.

[14] 姜红花,杨祥海,丁睿柔,等. 基于改进 ResNet18 的苹果叶部病害多分类算法研究[J]. 农业机械学报,2023,54(4): 295 - 303.
JIANG Honghua,YANG Xianghai,DING Ruirou,et al. Identification of apple leaf diseases based on improved ResNet18[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(4):295 - 303. (in Chinese)

[15] ANDERSSON M, AVELIN B. Exploring singularities in data with the graph Laplacian: an explicit approach[J]. Journal of Computational Mathematics and Data Science, 2025, 14: 100113.

[16] JEGHAM N, KOH C Y, ABDELATTI M, et al. Evaluating the evolution of YOLO (You only look once) models: a comprehensive benchmark study of YOLO 11 and its predecessors[J]. arXiv Preprint, arXiv:2411.00201v1,2024.

[17] SAPKOTAA R, MENGB Z, CHURUVIJAA M, et al. Comprehensive performance evaluation of YOLO 11, YOLOv10, YOLOv9 and YOLOv8 on detecting and counting Fruitlet in complex orchard environments[J]. arXiv Preprint, arXiv:2407.12040, 2024.

[18] ZHANG H, ZU K, LU J, et al. EPSANet: an efficient pyramid squeeze attention block on convolution neural network[C] // Proceedings of the Asia Conference on Computer Vision (ACCV). Cham: Springer, 2020:1161 - 1177.

[19] HAN K, WANG Y, TIAN Q, et al. GhostNet: more features from cheap operations[J]. arXiv Preprint, arXiv:1911.11907v2, 2020.

[20] 肖伸平,赵倩颖,曾甲元,等. 基于 YOLO - DCL 的复杂环境油茶果遮挡检测与计数研究[J]. 农业机械学报,2024, 55(10): 318 - 326.

XIAO Shenping, ZHAO Qianying, ZENG Jiayuan, et al. Camellia oleifera fruits occlusion detection and counting in complex environments based on improved YOLO - DCL[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(10):318 - 326. (in Chinese)

[21] 冀汶莉,刘洲,邢海花. 基于 YOLO v5 的农田杂草识别轻量化方法研究[J]. 农业机械学报,2024,55(1):212 - 222.
JI Wenli, LIU Zhou, XING Haihua. Lightweight method for identifying farmland weeds based on YOLO v5[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(1):212 - 222. (in Chinese)

[22] 刘双喜,刘思涛,屈慧星,等. 基于 MS - YOLO v7 的多尺度稻飞虱识别分类方法[J]. 农业机械学报,2023,54(增刊 1):212 - 222.
LIU Shuangxi, LIU Sitao, QU Huixing, et al. Multi-scale rice planthopper image recognition and classification based on lightweight MS - YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp. 1):212 - 222. (in Chinese)

[23] MISRA D. Mish: a self regularized non-monotonic activation function[J]. arXiv Preprint, arXiv:1908.08681v3, 2020.

[24] WANG Y, WANG Y. Research on micro-expression recognition based on GAM attention mechanism and transfer learning[C]// 2024 4th Asia-Pacific Conference on Communications Technology and Computer Science (ACCTCS), 2024: 350 - 355.

[25] HOFFMANN N, LIU Y, SHAO Z. Global attention mechanism: retain information to enhance channel-spatial interactions[J]. arXiv Preprint, arXiv:2112.05561v1, 2021.

[26] 陆健强,袁家俊,余超然,等. 融合多源评价数据的荔枝果期表型特征评估[J]. 农业机械学报,2025,56(3):91 - 100.
LU Jianqiang, YUAN Jiajun, YU Chaoran, et al. Evaluation of phenotypic characteristics in litchi fruiting stage using multi-source evaluation data[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(3): 91 - 100. (in Chinese)

[27] 杨斯利,王永胜,陈辉,等. 基于改进 YOLO v6 - tiny 的蛋鸡啄羽行为识别与个体分类[J]. 农业机械学报,2023,54(5):268 - 277.
YANG Sili, WANG Yongsheng, CHEN Hui, et al. Feather pecking abnormal behavior identification and individual classification method of laying hens based on improved YOLO v6 - tiny[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(5):268 - 277. (in Chinese)

[28] 张铮,鲁祥,胡庆松. 基于图像增强与 GC - YOLO v5s 的水下环境河蟹识别轻量化模型研究[J]. 农业机械学报,2024,55(11):124 - 131.
ZHANG Zheng, LU Xiang, HU Qingsong. Lightweight model for river crab detection based on image enhancement and improved YOLO v5s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11):124 - 131. (in Chinese)

[29] 赵春江,梁雪文,于合龙,等. 基于改进 YOLO v7 的笼养鸡/蛋自动识别与计数方法[J]. 农业机械学报, 2023, 54(7):300 - 312.
ZHAO Chunjiang, LIANG Xuewen, YU Helong, et al. Automatic identification and counting method of caged hens and eggs based on improved YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(7):300 - 312. (in Chinese)

[30] 张宏鸣,沈寅威,杨光,等. 融合注意力机制与多尺度信息的葡萄种植区变化检测[J]. 农业机械学报,2024,55(5):196 - 206.
ZHANG Hongming, SHEN Yinwei, YANG Guang, et al. Change detection of grape growing areas based on integrating attention mechanism and multiscale information[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(5):196 - 206. (in Chinese)

[31] ALI K, SHAIKH Z A, KHAN A A, et al. Multiclass skin cancer classification using EfficientNets-a first step towards preventing skin cancer[J]. Neuroscience Informatics, 2022, 2(4):100034.