

## 基于改进 YOLOv3 的浮游藻类检测算法

储震<sup>1</sup>, 张小玲<sup>1\*\*</sup>, 殷高方<sup>2</sup>, 贾仁庆<sup>2,3</sup>, 漆艳菊<sup>1</sup>, 徐敏<sup>2,3</sup>, 胡翔<sup>4</sup>, 黄朋<sup>4</sup>, 马明俊<sup>2</sup>, 杨瑞芳<sup>2</sup>, 方丽<sup>2</sup>, 赵南京<sup>1,2\*</sup><sup>1</sup>安徽大学物质科学与信息技术研究院安徽省信息材料与智能感知实验室, 安徽 合肥 230601;<sup>2</sup>中国科学院安徽光学精密机械研究所中国科学院环境光学与技术重点实验室, 安徽 合肥 230031;<sup>3</sup>中国科学技术大学环境科学与光电技术学院, 安徽 合肥 230026;<sup>4</sup>合肥学院生物食品与环境学院, 安徽 合肥 230601

**摘要** 浮游藻类的种类多样性和群落结构是水生态环境建设评价的重要指标,利用细胞图像对其进行识别是实现浮游藻类检测的重要手段。相较于传统的显微镜检法,基于深度学习的目标检测算法因更高效的检测能力而越来越多地被运用到浮游藻类检测领域。针对 YOLOv3 目标检测算法对部分形态小、边界模糊和粘连浮游藻类的检测精度低等问题,采用空间金字塔池化(SPP)结构改进了 YOLOv3 目标检测算法的特征提取方式,采用广义交并比(GIoU)边界损失函数改进了 YOLOv3 目标检测算法的边界损失函数,最终构建了一种基于 SPP 和 Giou 改进的 YOLOv3 浮游藻类检测算法(SPP-GIoU-YOLOv3)。实验结果表明:在检测速度无明显差异的情况下,所提 SPP-GIoU-YOLOv3 分类检测算法对实验藻类的平均精度均值达 95.21%,比 YOLOv3 目标检测算法提高了 4.24 个百分点。本研究为发展准确快速的浮游藻类检测方法技术提供了一定的基础。

**关键词** 机器视觉; SPP-GIoU-YOLOv3; 目标检测; 深度学习; 浮游藻类

中图分类号 X835

文献标志码 A

DOI: 10.3788/LOP212807

## Detection Algorithm of Planktonic Algae Based on Improved YOYOv3

Chu Zhen<sup>1</sup>, Zhang Xiaoling<sup>1\*\*</sup>, Yin Gaofang<sup>2</sup>, Jia Renqing<sup>2,3</sup>, Qi Yanju<sup>1</sup>, Xu Min<sup>2,3</sup>, Hu Xiang<sup>4</sup>, Huang Peng<sup>4</sup>, Ma Mingjun<sup>2</sup>, Yang Ruifang<sup>2</sup>, Fang Li<sup>2</sup>, Zhao Nanjing<sup>1,2\*</sup><sup>1</sup>Information Materials and Intelligent Sensing Laboratory of Anhui Province, Institutes of Physical Science and Information Technology, Anhui University, Hefei 230601, Anhui, China;<sup>2</sup>Key Laboratory of Environmental Optics and Technology, Anhui Institute of Optics and Fine Mechanics, Chinese Academy of Sciences, Hefei 230031, Anhui, China;<sup>3</sup>School of Environmental Science and Optoelectronic Technology, University of Science and Technology of China, Hefei 230026, Anhui, China;<sup>4</sup>School of Biological Food and Environment, Hefei University, Hefei 230601, Anhui, China

**Abstract** The species diversity and community structure of planktonic algae are important appraisal indicators for evaluating aquatic ecological environment construction, and the recognition of phytoplankton by cell image is a crucial way to achieve the detection of phytoplankton. Compared with the conventional microscopic detection method, the target detection algorithms based on deep learning have been increasingly employed in planktonic algae detection because of their effective detection capability. Aiming at the low detection accuracy challenges of small shape, fuzzy boundary, and cohesive planktonic algae in the YOLOv3 target detection algorithm, spatial pyramid pooling (SPP) was employed to enhance the feature extraction method of the YOLOv3 target detection algorithm. Additionally, the generalized intersection over union (GIoU) boundary loss function was employed to replace the YOLOv3 target detection algorithm in this study. Finally the SPP-GIoU-YOLOv3 planktonic algae detection algorithm was constructed based on the YOLOv3 algorithm. The findings demonstrate that the mean average precision of the SPP-GIoU-YOLOv3 target detection algorithm for detecting planktonic algae is up to 95.21%, which is 4.24 percentage points higher than that of the YOLOv3 algorithm. These findings are important for developing accurate rapid detection methods and technologies of planktonic algae.

**Key words** machine vision; SPP-GIoU-YOLOv3; target detection; deep learning; planktonic algae

收稿日期: 2021-10-26; 修回日期: 2021-10-29; 录用日期: 2021-11-05; 网络首发日期: 2021-11-16

基金项目: 国家自然科学基金(62005001,61875207)、安徽省科技重大专项(202003a07020007)

通信作者: \*njzhao@aiofm.ac.cn; \*\*xlzhang@ahu.edu.cn

# 1 引言

浮游藻类是水生态系统的重要组成部分,准确检测浮游藻类对水质监测和水生态系统生物多样性调查有非常重要的意义<sup>[1]</sup>,利用浮游藻类图像对其进行准确检测是实现其分类监测的重要手段之一。实验室常用的浮游藻类检测方法为传统的显微镜检法,该方法分析速度慢、误判率高、对操作者具有相当的经验要求。随着计算机视觉技术的发展,目标检测方法被逐渐应用于浮游藻类检测领域。传统目标检测算法过程复杂,检测精度低且速度慢,无法满足大面积水域的浮游藻类快速准确检测需求。近年来,深度学习的出现给浮游藻类检测带来了新的突破,尤其是基于卷积神经网络的深度学习目标检测算法能够自动提取浮游藻类图像的深层次特征,避免了传统目标检测算法人工提取图像特征时的差异性和不确定性,大大提高了目标检测的效率<sup>[2]</sup>。

基于卷积神经网络的目标检测算法主要分为两阶段目标检测算法和单阶段目标检测算法。两阶段目标检测算法首先对待检测目标进行区域推荐,然后再进行目标分类。具有代表性的两阶段目标检测算法有 RCNN<sup>[3]</sup>、Fast-RCNN<sup>[4]</sup>和 Faster-RCNN<sup>[5]</sup>等,此类算法一般检测精度高,但是速度较慢。单阶段目标检测算法可以直接回归目标的位置和类别信息,并输出目标检测结果。具有代表性的单阶段目标检测算法有 SSD<sup>[6]</sup>和 YOLO 系列算法<sup>[7-9]</sup>等,此类算法一般检测速度快,但检测精度相对较低,其中 YOLOv3 目标检测算法凭借着高效的目标检测性能被广泛运用到各类目标检测任务中。例如:孙迎春等<sup>[10]</sup>采用 YOLOv3 目标检测算法实现了交通灯的较高精度检测;Liu 等<sup>[11]</sup>采用 YOLOv3 目标检测算法实现了自然环境下番茄病虫害种类和位置的快速准确检测;柯宝生等<sup>[12]</sup>基于 YOLOv3 目标检测算法构建了 DetectNet 目标检测算法,该算法能够高效地识别和定位有丝分裂细胞。

之后,YOLOv3 目标检测算法逐渐被用于浮游藻类的检测研究中。例如,王晓阳<sup>[13]</sup>采用 YOLOv3 目标检测算法研究了实球藻、楔形藻和裸形藻等海洋微藻的图像分类识别问题,结果表明 YOLOv3 目标检测算法对海洋微藻的平均精度均值(mAP)为 88.22%。然而,由于浮游藻类细胞图像目标尺寸一般较小,通过普通光学显微镜或其他拍照设备得到的图像特征信息比同等条件下的大尺寸目标包含的特征信息更少,且部分具有链、囊、孢或其他团簇结构的藻类细胞和自然水体中由于细菌、无机悬浮物等的作用而被团聚聚集的藻类细胞,其显微图像更容易出现粘连、遮挡、景深模糊等影响浮游藻类检测精度的问题。在目标检测算法方面,YOLOv3 目标检测算法中的深层卷积会使图像的感受野变大,经过多次下采样后特征图会不断减小,

导致形态小和低辨识度的浮游藻类图像特征很难被提取。另外,YOLOv3 目标检测算法采用交并比(IoU)为边界损失函数,IoU 为检测目标真实框与预测框交集与并集之比,当浮游藻类的真实框与预测框不相交时,IoU 值为 0,导致目标检测算法无法进一步学习训练<sup>[14]</sup>。这些原因在一定程度上降低了 YOLOv3 目标检测算法在浮游藻类上的检测能力。

基于此,本文将空间金字塔池化(SPP)结构运用到 YOLOv3 目标检测算法中,将浮游藻类图像的局部特征和全局特征进行融合,以提高图像特征的表达能力,采用广义交并比(GIoU)边界损失函数代替原算法中 IoU 边界损失函数,解决浮游藻类图像因模糊粘连等造成的预测框和真实框不相交时无法量化的问题,最终构建了一种基于 YOLOv3 目标检测算法的浮游藻类检测算法(SPP-GIoU-YOLOv3),来实现浮游藻类的快速准确检测。

## 2 材料与方法

### 2.1 浮游藻类图像采集和处理

选择海洋中常见的 5 种浮游藻类作为实验对象,分别为杜氏盐藻(*Dunaliella Salina*)、海洋小球藻(*Marine Chlorella*)、威氏海链藻(*Thalassiosira Weissflogii*)、三角褐指藻(*Phaeodactylum Tricornutum*)和利玛原甲藻(*Prorocentrum Lima*)。培养条件如下:光照叠加式恒温振荡器(美国精骐,IS-6),白色 LED 灯带,光照强度为 3000 lx,光暗周期为 12 h:12 h,温度为(25±1)℃。本研究采用的海洋浮游藻种购自上海光语生物科技有限公司。

采用实验室正置荧光显微镜(日本尼康,NI-U)采集 5 种浮游藻类的单一图像和混合图像共 635 张,随机选取其中 500 张图像作为训练集和验证集,其余 135 张图像作为测试集。通过顺时针旋转 45°、锐化、随机增加或降低图像亮度的方式将作为训练集和验证集的 500 张浮游藻类图像数据集增强至 2000 张,此 2000 张图像最终共包含 6460 个浮游藻类对象,具体浮游藻类对象分布情况如表 1 所示。

表 1 实验选用的浮游藻类及其数据增强后的数量情况  
Table 1 Planktonic algae selected in experiment and number of its data after enhancement

Class name	Abbreviation	Number	Number after data enhancement
<i>Dunaliella Salina</i>	DS	258	1032
<i>Marine Chlorella</i>	MC	385	1540
<i>Thalassiosira Weissflogii</i>	TW	331	1324
<i>Phaeodactylum Tricornutum</i>	PT	339	1356
<i>Prorocentrum Lima</i>	PL	302	1208

### 2.2 实验环境配置

实验中计算机硬件环境配置为 Intel Core i5-10600KF CPU, 8 GB Nvidia GeForce RTX2080 GPU, 软件环境配置为 Windows 10, CUDA 11.0, Pytorch 框架, Pycharm 软件。

### 2.3 SPP-YOLOv3 目标检测算法

YOLOv3 目标检测算法主要由两个部分构成, 分别为特征提取主干网络 Darknet-53 和多尺度检测 YOLO 层网络。Darknet-53 是一种由全卷积和残差控制结构组成的 53 层网络结构, 它没有全连接层, 因此特征提取的时候更加快速、灵活, 同时可避免梯度爆炸或消失等问题。YOLO 层网络中有 3 个不同尺度预测模块, 它借鉴了图像特征融合金字塔结构的思想, 将低层次图像特征和高层次图像特征进行融合, 其中低层次图像特征可以提供更加准确的位置信息, 深层次图像特征可以提供更加准确的类别信息。为了进一步提高 YOLOv3 目标检测算法的检测精度和召回率, 本研究将 SPP<sup>[15]</sup> 结构运用到 YOLOv3 目标检测算法中。SPP 结构由 4 个并行的分支构成, 分别是 kernel size 为 5×5、9×9、13×13 的最大池化和一个跳跃连接, SPP

结构如图 1 所示。




图 1 SPP 结构  
Fig. 1 SPP structure

本研究将 SPP 结构置于 YOLOv3 目标检测算法第 5 层和第 6 层卷积之间, 如图 2 所示。SPP 结构能够实现图像局部特征和全局特征的融合, 丰富最终特征图的表达能力, 降低目标误检和漏检的概率, 特别是对于复杂的多目标检测, SPP 结构能够在一定程度上提升目标检测的效率<sup>[16]</sup>。SPP 改进后的 YOLOv3 目标检测算法能够将 Darknet-53 提取到的局部图像特征和全局图像特征进一步融合, 提高图像特征的表达能力。

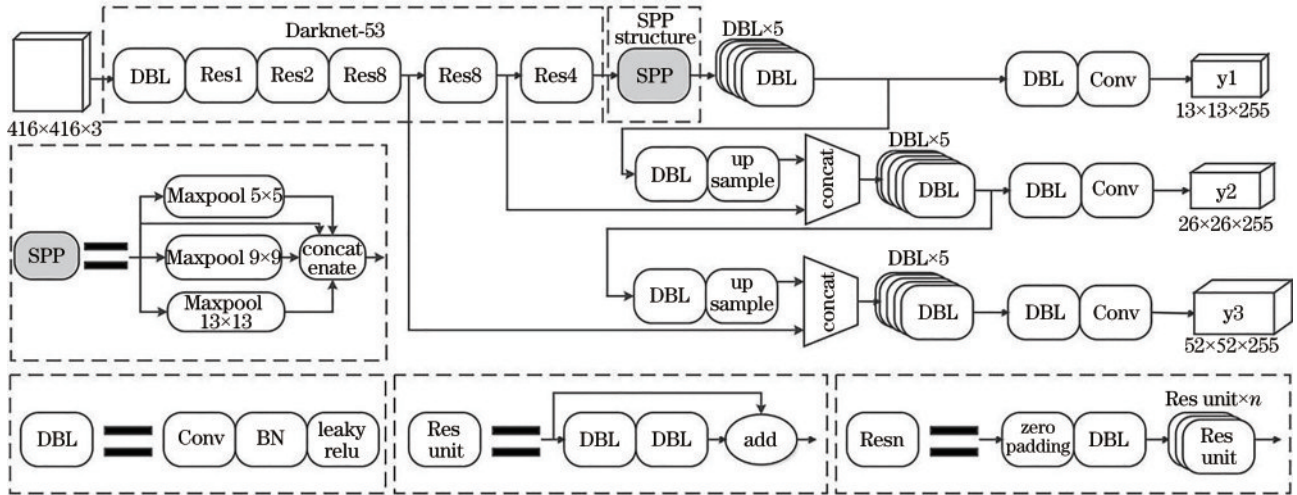


图 2 SPP-YOLOv3 目标检测算法结构图  
Fig. 2 SPP-YOLOv3 target detection algorithm structure diagram

### 2.4 GIoU 边界损失函数

在 YOLOv3 目标检测算法中, 使用 IoU 作为边界损失函数来判断正负样本, 并根据此依据来计算置信度损失<sup>[17]</sup>。IoU 是两个区域重叠部分除以两个区域集合部分得出的结果, 如图 3 所示, 其中 A、B 各表示一个区域。

IoU 具有尺度不变性的优点, 任意两个方框 A 和 B 的相似性和它们的空间尺度无关。然而, 一方面, 如果两个目标区域没有重叠的部分, 此时 IoU 会为 0, 并且无法反应两个目标之间的距离, 在这种情况下, 如果将 IoU 作为损失函数, 就会导致优化损失函数时梯度

$$IoU = \frac{|A \cap B|}{|A \cup B|}$$

图 3 IoU 计算方式示意图  
Fig. 3 Schematic of IoU calculation method

为 0, 无法进行优化。另一方面, IoU 无法区分两个目标之间不同的对齐方式, 这就造成了不同方向上目标重叠区域相同会得到相同的 IoU 值, 如图 4 所示, 图 4




图 4 相同 IoU 下不同目标重叠方式

Fig. 4 Overlapping modes of different targets under same IoU

这 3 种重叠方式 IoU 相同,但是两个目标框区域对齐方式是不一样的,因此需要一种新的 IoU 策略来优化。

GIoU<sup>[18]</sup>作为 IoU 的改进形式,同样具有尺度不变性的优点,与 IoU 相比,GIoU 考虑到了目标的非重叠区域,能够充分反应目标重叠的方式,弥补了 IoU 边界损失函数无法量化真实框与预测框不相交时的不足。对于任意的两个  $A$ 、 $B$  框,首先找到一个能包住它们的虚线框  $C$ ,然后计算  $C \setminus (A \cup B)$  的面积与  $C$  的面积之比,其中  $C \setminus (A \cup B)$  的面积为  $C$  的面积减去  $A \cup B$  的面积,再用  $A$ 、 $B$  的 IoU 值减去这个比值得到 GIoU:

$$R_{\text{GIoU}} = R_{\text{IoU}} - \frac{|C \setminus (A \cup B)|}{|C|}. \quad (1)$$

将 GIoU 作为 YOLOv3 目标检测算法中两个目标框距离度量的时候,其损失函数为

$$L_{\text{GIoU}} = 1 - R_{\text{GIoU}}. \quad (2)$$

## 2.5 目标检测评价标准

目标检测评价标准一般分为检测精度和检测速度两个部分。采用平均精度 (AP) 和 mAP 对浮游藻类目标的检测结果进行评价,采用每秒的帧数 (FPS) 对浮游藻类目标的检测速度进行评价。





图 5 学习率曲线和损失曲线。(a)学习率曲线;(b)损失曲线

Fig. 5 Learning rate curve and loss curve. (a) Learning rate curve; (b) loss curve

经过模型训练可得到 SPP-GIoU-YOLOv3 和 YOLOv3 浮游藻类检测权重,分别将其用于浮游藻类检测的测试中,其中置信度阈值设为 0.5,测试集为第 2.1 节随机选择的 135 张浮游藻类图像。

$$R_{\text{AP}} = \int_0^1 P(r) dr, \quad (3)$$

$$R_{\text{mAP}} = \frac{\sum_{n=1}^N \int_0^1 P(r_n) dr_n}{N}, \quad (4)$$

$$P_{\text{precision}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}}, \quad (5)$$

$$R_{\text{recall}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}}, \quad (6)$$

式中: $P(r)$ 为 Precision-Recall 曲线方程; $N$ 表示目标类别数; $N_{\text{TP}}$ 表示正样本中被正确识别为正的样本数目; $N_{\text{FP}}$ 表示负样本中被误识别为正的样本数目; $N_{\text{FN}}$ 表示正样本中被误识别为负的样本数目。

## 3 实验和结果分析

### 3.1 改进前后目标检测算法的训练和测试

将增强后的 2000 张浮游藻类图像按照 4:1 的比例随机分成训练集和验证集,即训练集 1600 张图像,验证集 400 张图像。采用 SPP-GIoU-YOLOv3 和 YOLOv3 目标检测算法分别对 2000 张浮游藻类图像数据集进行训练和验证。

训练中采用余弦衰减学习率<sup>[19]</sup>,结果如图 5(a)所示。从图 5(a)可以看出,余弦衰减学习率在开始时缓慢降低,然后在中间变得几乎线性减少,最后再次缓慢下降。经过 2000 次迭代训练的损失值如图 5(b)所示,由损失曲线可知,SPP-GIoU-YOLOv3 和 YOLOv3 目标检测算法在训练迭代了大约 1800 次时损失值趋于稳定,最终 SPP-GIoU-YOLOv3 目标检测算法的损失值下降到 0.67 左右,YOLOv3 目标检测算法的损失值下降到 0.84 左右。

### 3.2 实验结果定性分析

随机选择具有代表性的存在模糊、粘连和不完整浮游藻类对象作为测试集图像,分别采用 SPP-GIoU-YOLOv3 和 YOLOv3 目标检测算法对其进行检测,得到检测结果如图 6 所示。图 6(1a)~(4a)表示

YOLOv3 目标检测算法对测试集样本的检测结果, 图 6(1b)~(4b) 表示 SPP-GIoU-YOLOv3 目标检测算法对测试集样本的检测结果, 图中的误检和漏检对象已用虚线框标出。图 6 结果表明: 与 YOLOv3 目标检测算法结果相比, SPP-GIoU-YOLOv3 目标检测算法

对模糊 (PT/MC/TW)、粘连 (PT) 和不完整 (PT/MC) 的浮游藻类细胞对象具有更低的漏检率, 即 SPP-GIoU-YOLOv3 目标检测算法具有更强的鲁棒性和泛化能力, 能够更准确地定位和识别不同大小、形态和清晰度的浮游藻类对象。




图 6 SPP-GIoU-YOLOv3 和 YOLOv3 目标检测算法对实验浮游藻类检测结果对比图。(1a)~(4a) YOLOv3 检测结果; (1b)~(4b) SPP-GIoU-YOLOv3 检测结果。

Fig. 6 Comparison of SPP-GIoU-YOLOv3 and YOLOv3 detection results of test set planktonic algae. (1a)~(4a) YOLOv3 detection results; (1b)~(4b) SPP-GIoU-YOLOv3 detection results

表 2 为图 6 不同算法对测试图像检测结果的统计表。由表 2 可知: SPP-GIoU-YOLOv3 和 YOLOv3 目标检测算法对 4 张待检测藻类图像中浮游藻类目标的漏检个数分别为 2 和 10, 误检个数分别为 0 和 1, 表明 SPP-GIoU-YOLOv3 目标检测算法对形态小、模糊、粘连和不完整的浮游藻类对象具有更好的识别检测能力; SPP-GIoU-YOLOv3 目标检测算法在各个图像上

的平均置信度比 YOLOv3 目标检测算法分别提高了 6.1 个百分点、9.1 个百分点、2.9 个百分点和 31.9 个百分点, 且 SPP-GIoU-YOLOv3 目标检测算法对每个浮游藻类对象的识别置信度几乎都高于 YOLOv3 目标检测算法的识别置信度, 表明 SPP-GIoU-YOLOv3 目标检测算法对浮游藻类具有更好的检测性能。

表 2 SPP-GIoU-YOLOv3 和 YOLOv3 浮游藻类检测结果详细统计表

Table 2 Detail statistics results of test set planktonic algae detected by SPP-GIoU-YOLOv3 and YOLOv3 algorithm

Model	Image number	Number of planktonic algae detected	Confidence / %	Average confidence / %	Missed	False
YOLOv3	(1a)	10	95, 94, 92, 91, 90, 87, 87, 85, 82, 81	88.4	3	0
	(2a)	15	96, 95, 95, 93, 93, 92, 91, 90, 87, 86, 84, 82, 81, 79, 58	86.8	1	0
	(3a)	20	95, 94, 94, 94, 92, 90, 90, 89, 88, 88, 86, 84, 82, 81, 80, 79, 77, 73, 70, 69	84.8	5	0
	(4a)	4	71, 68, 57, 53	62.3	1	1
SPP-GIoU-YOLOv3	(1b)	13	98, 97, 97, 97, 97, 96, 96, 96, 95, 94, 94, 94, 78	94.5	0	0
	(2b)	16	99, 98, 98, 98, 97, 97, 97, 97, 97, 96, 96, 96, 95, 95, 92, 87	95.9	0	0
	(3b)	23	99, 98, 98, 98, 98, 97, 97, 97, 97, 97, 96, 95, 95, 93, 90, 88, 85, 76, 73, 70, 65, 59, 56	87.7	2	0
	(4b)	5	97, 97, 96, 93, 88	94.2	0	0

### 3.3 实验结果定量分析

使用 SPP-GIoU-YOLOv3 和 YOLOv3 目标检测算法分别对测试集 135 张浮游藻类图像进行检测,结

果如图 7 和图 8 所示。图 7 为 SPP-GIoU-YOLOv3 和 YOLOv3 浮游藻类检测 Precision-Recall 曲线图。

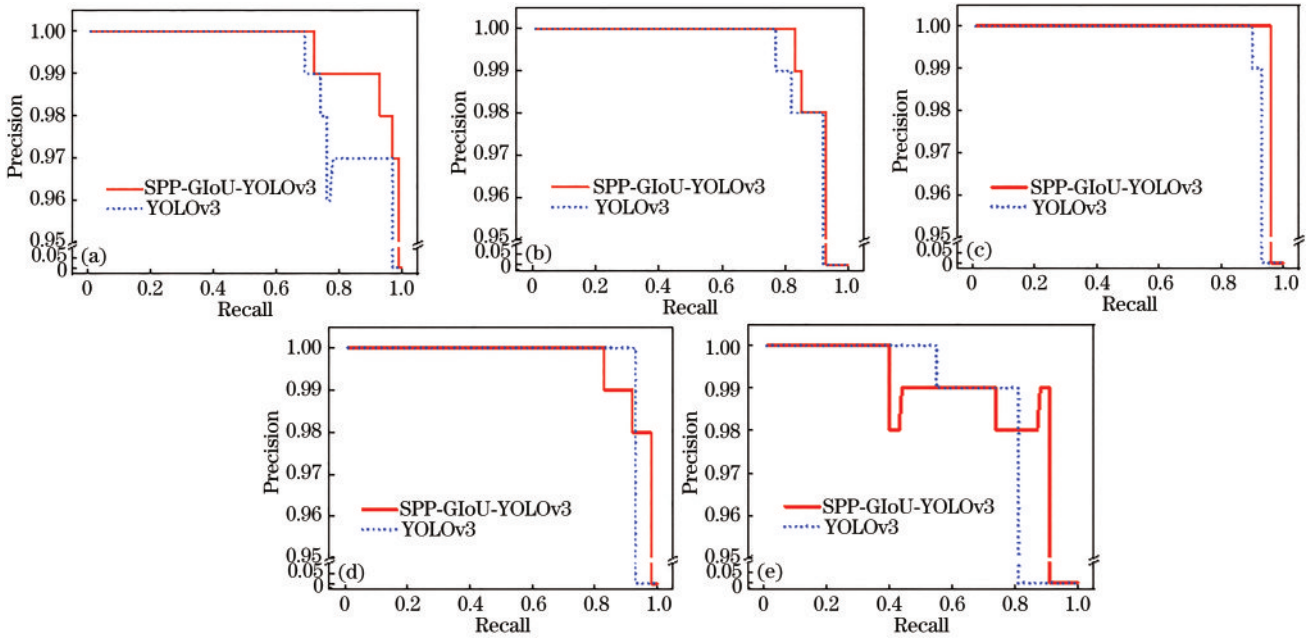


图 7 SPP-GIoU-YOLOv3 和 YOLOv3 对测试集浮游藻类的检测精度-召回率曲线图。(a) (b) (c) (d) (e) DS、PL、TW、MC、PT 的检测精度-召回率曲线图

Fig. 7 Precision-Recall curves of test set planktonic algae detected by SPP-GIoU-YOLOv3 and YOLOv3 algorithm. (a) (b) (c) (d) (e) curves of DS, PL, TW, MC, and PT respectively

图 7 结果表明:SPP-GIoU-YOLOv3 目标检测算法对 DS、PL 和 TW 的检测结果在任意 Recall 值时的 Precision 均大于或等于在 YOLOv3 目标检测算法上的 Precision 值;对 MC 和 PT 的检测结果虽然分别在 Recall 区间 $[0.83, 0.93]$ 和 $[0.41, 0.55] \cup [0.75, 0.81]$ 上的 Precision 值小于 YOLOv3 目标检测算法,但是在整个 Recall 区间上,SPP-GIoU-YOLOv3 目标检测算法对 MC 和 PT 检测结果的 Precision-Recall 曲线面积仍均大于 YOLOv3 目标检测算法结果。即较 YOLOv3 目标检测算法而言,SPP-GIoU-YOLOv3 目标检测算法对 5 种实验浮游藻类均有更好的目标检测能力。

图 8 表示 SPP-GIoU-YOLOv3 和 YOLOv3 目标检测算法对 5 种浮游藻类检测结果的 AP 对比图。图 8 结果表明,SPP-GIoU-YOLOv3 目标检测算法对 5 种浮游藻类的检测结果 AP 值均高于 YOLOv3 目标检测算法结果。较 YOLOv3 目标检测算法而言,SPP-GIoU-YOLOv3 目标检测算法对 5 种浮游藻类检测结果的 AP 值分别提高了 2.23 个百分点、5.30 个百分点、3.22 个百分点、1.48 个百分点和 9.00 个百分点。根据式(3)和图 8 中 5 种浮游藻类 AP 值可分别计算得到 SPP-GIoU-YOLOv3 和 YOLOv3 目标检测算法对 5 种浮游藻类检测结果的 mAP 值。结果表明,SPP-GIoU-YOLOv3 目标检测算法对 5 种浮游藻类样品检测结果

的 mAP 达 95.21%,比 YOLOv3 目标检测算法结果 mAP 值提高了 4.24 个百分点。

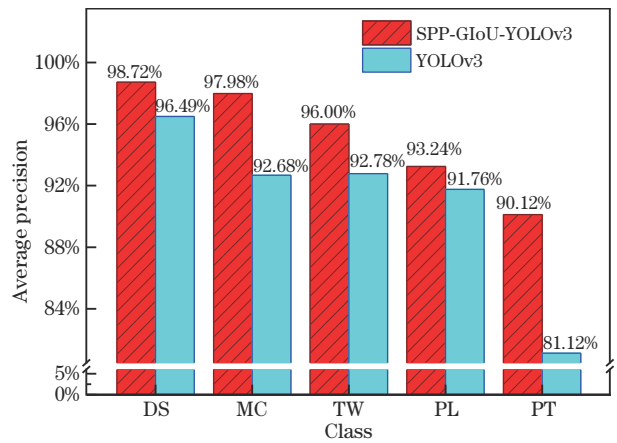


图 8 SPP-GIoU-YOLOv3 和 YOLOv3 对测试集浮游藻类检测平均精度对比

Fig. 8 Comparison of average accuracy of test set planktonic algae detected by SPP-GIoU-YOLOv3 and YOLOv3

图 7 和图 8 对测试集的检测结果表明:SPP-GIoU-YOLOv3 目标检测算法能够有效提高 YOLOv3 目标检测算法对浮游藻类图像的识别精度。尤其是对某些细胞图像不理想的浮游藻类,SPP-GIoU-YOLOv3 目标检测算法具有更好的识别能力。如本实验采用的三角褐指藻,在显微镜下其细胞两端呈现半透明状,由于

景深的不同,其全部清晰的细胞形态显微镜图像很难获得。此外,三角褐指藻的细胞很容易团聚在一起,造成藻类目标图像的粘连与遮挡。这些客观因素导致 YOLOv3 目标检测算法很可能会对此类目标漏检与误检, SPP-GIoU-YOLOv3 浮游藻类检测算法中的 SPP 结构能够充分融合三角褐指藻的局部和全局特征,提高三角褐指藻图像特征的表达能力。GIoU 边界损失函数能够优化三角褐指藻真实框与预测框不相交时的情况,也在一定程度上提高了算法对三角褐指藻目标的检测性能。

为了进一步研究 SPP-GIoU-YOLOv3 浮游藻类检测算法的综合性能,在相同实验条件下将其与 Faster-RCNN、SSD 和 YOLOv3-Tiny<sup>[20]</sup> 目标检测算法进行了对比,结果如表 3 所示。表 3 结果表明: SPP-GIoU-YOLOv3 浮游藻类检测算法在 FPS 没有明显降低的情况下, mAP 值比 YOLOv3 目标检测算法提高了 4.24 个百分点;且与目前主流目标检测算法的检测结果相比, SPP-GIoU-YOLOv3 浮游藻类检测算法仍具有较好的综合性能。

表 3 不同目标检测算法检测结果比较  
Table 3 Comparison of detection results of different target detection algorithms

Model	mAP / %	FPS
Faster-RCNN	93.64	6.96
SSD	90.99	14.92
YOLOv3-Tiny	78.28	33.75
YOLOv3	90.97	23.44
SPP-GIoU-YOLOv3	95.21	23.24

## 4 结 论

针对 YOLOv3 目标检测算法对部分形态小、辨识度不高的浮游藻类检测精度低等问题,将 SPP 结构运用到 YOLOv3 目标检测算法中,增加了检测目标局部特征和全局特征的融合,提高了图像特征的表达能力,采用 GIoU 边界损失函数代替原算法中 IoU 边界损失函数,避免了目标真实框与预测框不相交时无法量化等问题,最终构建了一种基于 YOLOv3 目标检测算法的浮游藻类检测算法 SPP-GIoU-YOLOv3。实验结果表明,与 YOLOv3 浮游藻类检测算法相比, SPP-GIoU-YOLOv3 浮游藻类检测算法在检测速度几乎不变的情况下,对实验浮游藻类检测的 mAP 提高了 4.24 个百分点,达 95.21%。且与目前主流目标检测算法相比, SPP-GIoU-YOLOv3 目标检测算法仍具有较好的综合性能,能够满足当前对大面积水域水生态环境建设和评价中的浮游藻类快速准确检测需求。

## 参 考 文 献

[1] Drakard V F, Lanfranco S, Schembri P J. Macroalgal

fouling communities as indicators of environmental change: potential applications for water quality monitoring [J]. Journal of the Marine Biological Association of the United Kingdom, 2018, 98(7): 1581-1588.

- [2] Pant G, Yadav D P, Gaur A. ResNeXt convolution neural network topology-based deep learning model for identification and classification of *Pediastrum*[J]. Algal Research, 2020, 48: 101932.
- [3] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA. New York: IEEE Press, 2014: 580-587.
- [4] Girshick R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision, December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 1440-1448.
- [5] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [6] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[M]//Leibe B, Matas J, Sebe N, et al. Computer vision-ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9905: 21-37.
- [7] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 779-788.
- [8] Redmon J, Farhadi A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6517-6525.
- [9] Redmon J, Farhadi A. YOLOv3: an incremental improvement[EB/OL]. (2018-04-08)[2019-12-05]. <https://arxiv.org/abs/1804.02767>.
- [10] 孙迎春, 潘树国, 赵涛, 等. 基于优化 YOLOv3 算法的交通灯检测[J]. 光学学报, 2020, 40(12): 1215001.
- Sun Y C, Pan S G, Zhao T, et al. Traffic light detection based on optimized YOLOv3 algorithm[J]. Acta Optica Sinica, 2020, 40(12): 1215001.
- [11] Liu J, Wang X W. Tomato diseases and pests detection based on improved YOLOv3 convolutional neural network [J]. Frontiers in Plant Science, 2020, 11: 898-909.
- [12] 柯宝生, 李颖, 任振波, 等. 基于深度学习的活体细胞有丝分裂检测方法 [J]. 光学学报, 2021, 41(15): 1511001.
- Ke B S, Li Y, Ren Z B, et al. Deep learning-based detection method for mitosis in living cells[J]. Acta Optica Sinica, 2021, 41(15): 1511001.
- [13] 王晓阳. 基于图像的海洋微藻识别系统的设计与实现 [D]. 大连: 大连海洋大学, 2020.
- Wang X Y. Design and implementation of image-based marine microalgae identification system[D]. Dalian: Dalian Ocean University, 2020.

- [14] Ma H J, Liu Y L, Ren Y H, et al. Detection of collapsed buildings in post-earthquake remote sensing images based on the improved YOLOv3[J]. *Remote Sensing*, 2019, 12(1): 44-62.
- [15] He K M, Zhang X Y, Ren S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 37(9): 1904-1916.
- [16] Dong S, Ma Y H, Li C M. Implementation of detection system of grassland degradation indicator grass species based on YOLOv3-SPP algorithm[J]. *Journal of Physics: Conference Series*, 2021, 1738(1): 012051.
- [17] 许凯, 邓超. 基于改进 YOLOv3 的安全帽佩戴识别算法[J]. *激光与光电子学进展*, 2021, 58(6): 0615002.  
Xu K, Deng C. Research on helmet wear identification based on improved YOLOv3[J]. *Laser & Optoelectronics Progress*, 2021, 58(6): 0615002.
- [18] Rezaatofghi H, Tsoi N, Gwak J, et al. Generalized intersection over union: a metric and a loss for bounding box regression[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 658-666.
- [19] He T, Zhang Z, Zhang H, et al. Bag of tricks for image classification with convolutional neural networks[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 558-567.
- [20] Fu L S, Feng Y L, Wu J Z, et al. Fast and accurate detection of kiwifruit in orchard using improved YOLOv3-tiny model[J]. *Precision Agriculture*, 2021, 22(3): 754-776.