

基于优化 SSD 算法的冰鲜鲳鱼新鲜度评估方法研究

李振波^{1,2} 李萌^{1,2} 吴宇峰^{1,2} 赵远洋^{1,2} 郭若皓^{1,2} 陈雅茹^{1,2}

(1. 中国农业大学信息与电气工程学院, 北京 100083; 2. 农业农村部农业信息获取技术重点实验室, 北京 100083)

摘要: 保障冰鲜水产品的质量安全是提升水产行业供求效益的关键环节之一, 冷链储运的发展急需一种快速无损的鱼肉品质检测技术。以冰鲜鲳鱼为研究对象, 提出用于鲳鱼新鲜度质变敏感区域定位与评估的目标检测网络 SSD 优化方法。首先, 建立冰鲜鲳鱼新鲜度目标检测数据集。其次, 依据先验知识, 以鲳鱼的鱼眼和鱼鳃作为感兴趣区域, 基于 SSD 目标检测算法自动定位与识别图像中的质变敏感区域, 构建鲳鱼新鲜度评估目标检测模型, 通过改进主干网络和设计自适应先验框提升网络性能。优化后的 SSD 网络在金鲳鱼和银鲳鱼数据集上的平均检测精度均值分别达到 98.97% 和 99.42%, 检测速度达到 37 帧/s。

关键词: 冰鲜鲳鱼; 新鲜度; 冷链; SSD 目标检测算法; 主干网络; 自适应先验框

中图分类号: S126 **文献标识码:** A **文章编号:** 1000-1298(2021)S0-0472-10

Evaluation Method of Iced Pomfret Freshness Based on Improved SSD

LI Zhenbo^{1,2} LI Meng^{1,2} WU Yufeng^{1,2} ZHAO Yuanyang^{1,2} GUO Ruohao^{1,2} CHEN Yaru^{1,2}

(1. College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China

2. Key Laboratory of Agricultural Information Acquisition Technology, Ministry of Agriculture and Rural Affairs, Beijing 100083, China)

Abstract: Ensuring the quality and safety of iced aquatic products is the key to improve the benefits of the aquatic industry. Traditional aquatic product freshness evaluation faces the following challenges: complicated operations, samples destruction and low efficiency. An effective and scientific method is urgently needed for aquatic products cold chain system. To solve the above problems, an improved object detection network SSD was proposed to realize the sensitive area location and pomfret freshness evaluation. Firstly, image datasets of iced pomfret freshness grade was established based on environmental factors-pomfret image-total volatile basic nitrogen (TVB-N). The image data of pomfret was collected according to the physicochemical index TVB-N of pomfret freshness at a constant temperature of 0℃, with days as the unit of time. Then, the samples of pomfret images were expanded with data augmentation and marked by Labellmg, annotated image datasets of iced pomfret were provided for freshness detection. Secondly, based on prior knowledge, the eyes and gills of the pomfret were chosen as region of interest. Considering the trade-off between detection accuracy and speed in cold chain application, one-stage object detection network SSD performed better. SSD significantly improved the performance by replacing the backbone network and designing adaptive prior boxes. The improved SSD reached mean average precision of 98.97% and 99.42% on the golden and silver pomfret datasets respectively and the detection speed reached 37 frames per second. The results met the demand for real-time and assessment accuracy in application scenarios, and enabled low-cost, efficient and accurate assessment of pomfret freshness.

Key words: iced pomfret; freshness; cold chain; SSD object detection algorithm; backbone; adaptive prior box

0 引言

鲳鱼富含磷钙等营养成分^[1], 然而, 鲳鱼死后

会释放大量内源性酶和嗜冷微生物^[2-3], 加速鱼肉腐败变质, 低温保鲜有利于减缓鱼肉产品储运过程中的品质劣变, 最大程度保证鱼肉品质。目前, 我国

冷链储运体系尚未完善,存在智能化程度不高、对储运信息的跟踪监测和分析利用不足等问题。因此,构建鱼肉新鲜度品质实时评估模型可以有效减少冷链运输环节中水产品的损失,提高鱼肉产品供求效益,具有理论研究意义和实际应用价值。

传统的水产品新鲜度评估方法^[4-6]虽然可以实现新鲜度品质分级,但存在检测效率低、破坏样本等问题。当前,以计算机视觉为代表的人工智能技术已在智慧农业领域得到应用,如作物产量预测、品质分级检测、病虫害防治等^[7-10],其具有低成本、高准确率、快速无损检测的优点^[11]。众多研究人员尝试将计算机视觉技术应用于水产品品质检测领域。

依据鱼类卫生检测标准^[12],鱼眼、鱼鳃和鱼体表在存储过程的颜色、纹理等变化可作为鱼类新鲜度判断依据。基于此特点,计算机视觉技术通过提取图像敏感质变特征,建立新鲜度评估模型,快速无损地完成鱼类产品新鲜度评估^[13]。文献[14]以罗非鱼为研究对象,选择瞳孔和鳃为感兴趣区域(Region of interest,ROI),通过图像分析法建立颜色空间与理化指标的联系,设计了罗非鱼机器视觉系统,实现鱼肉新鲜度检测。文献[15]设计了一套数字彩色成像系统,采集并记录金边鲷鱼鱼眼和鱼鳃的 L^* 、 a^* 、 b^* 值及其视觉成像特征,采用人工神经网络预测金边鲷鱼新鲜度。文献[16]采用聚类法分割鱼鳃感兴趣区域,通过分析小波域内鱼鳃特征信息,实现新鲜度快速评估。文献[17]利用图像采集系统提取草鱼鱼鳃的颜色空间特征,记录贮藏期间鱼鳃的颜色分量以及挥发性盐基氮(Total volatile basic nitrogen,TVB-N)含量,分析草鱼鱼鳃颜色空间、贮藏时间以及TVB-N含量的线性关系,验证了以鱼鳃颜色变化作为鱼类产品品质预测的可行性。

上述检测方法通过对鱼眼、鱼鳃特征进行人工选择,建立颜色特征与新鲜度品质预测模型,实现对鱼肉产品的品质评估。其新鲜度评估准确率较大程度上依赖人工特征的选择,存在主观性强和分割效率低的问题。深度学习通过自主学习的方式从大量图像数据中捕捉特征,能够更好地提取图像语义信息,具有低成本、高准确率的优点。目前,学者将深度学习算法应用在多种农产品分级领域,取得了较好的应用效果。

目前,基于深度学习的水产品品质分级研究处于初步探索阶段^[18-20]。基于对研究背景与研究现状的分析,本文利用深度学习技术评估冰鲜鲷鱼品质,从而实现鲷鱼新鲜度低成本、自动化、实时无损检测。

1 材料和方法

针对冰鲜鲷鱼图像数据及新鲜度标签信息不足等问题,本文以鲷鱼为研究对象,依据理化指标TVB-N含量测定鲷鱼新鲜度,以判定鲷鱼图像所属新鲜度等级,建立基于环境因子-鲷鱼图像-TVBN含量的冰鲜鲷鱼新鲜度目标检测数据集,数据集构建过程严格把控采集环境,依据SC/T 3103—2010《鲜、冻鲷鱼》标准划分鲷鱼图像样本新鲜度等级,以确保卷积神经网络学习到正确规范的信息。

1.1 实验鲷鱼样本

实验用鲜活金鲷、银鲷鱼各60条(平均质量为 (500 ± 10) g),购于北京农贸市场,将鱼体宰杀、去腮盖、去内脏、放入冰袋,将所有样本在30 min内运输到北京农业信息技术研究中心实验室,期间严格监控鱼类运输环境。到达实验室后,快速清洗鲷鱼内脏、血渍,使用厨房专用纸巾将鱼体表面擦干,然后将每条鱼放入样品袋中。样品竖立置于0℃的冷藏箱中存放30 d。每次随机取样6条,每天特定时间采集鲷鱼图像,每3 d测定一次TVB-N含量直至样品腐败。每日检查3次实验样品的存储环境。

1.2 TVB-N含量测定

TVB-N是检测鱼类新鲜度的理化指标,其含量随内源性酶和腐败细菌活性的增加而增加^[21]。TVB-N含量越高,鱼肉品质劣变程度越严重,SC/T 3103—2010《鲜、冻鲷鱼》标准规定,鲷鱼样品TVB-N含量(质量比)在18 mg/(100 g)以内为一级品,样品质量等级新鲜可食用;18~30 mg/(100 g)为合格品,样品质量等级较新鲜可食用;30 mg/(100 g)以上为不合格品,样品质量等级腐败不可食用。

表1为存储条件下鲷鱼TVB-N含量的变化情况。最初,鲷鱼样品TVB-N含量增长缓慢,在0~14 d样品质量等级为一级品。从15 d起,样品TVB-N

表 1 0℃存储条件下鲷鱼 TVB-N 含量变化

Tab.1 Values of TVB-N in pomfret under 0℃ storage

mg/(100g)							
时间/d	样品 1	样品 2	样品 3	样品 4	样品 5	样品 6	平均值
0	10.73	10.73	12.13	12.13	12.13	12.13	11.67
3	11.20	12.60	12.60	14.00	14.00	12.60	12.83
6	12.60	12.60	14.00	14.00	14.00	14.00	13.53
9	15.40	15.40	14.00	16.80	15.40	15.40	15.40
12	15.40	18.20	15.40	16.80	15.40	16.80	16.33
15	16.33	16.33	17.73	19.13	20.05	19.13	18.20
18	21.00	18.20	21.00	21.00	28.00	22.40	21.98
21	26.60	25.20	25.20	26.60	28.00	28.00	26.60
24	26.60	25.20	33.60	30.80	32.20	32.20	30.10

含量增长速度加剧,在 15 ~ 23 d 样品质量等级为合格品。第 24 天,样品 TVB-N 含量大于 30 mg/(100 g),到达贮藏终点,样品腐败变质不可食用。

1.3 鲳鱼图像采集与处理

鲳鱼图像在照明室环境采集,鲳鱼样本上方固定一盏 144 颗灯珠的 LED 光源以获得均匀的采光效果,下方放置黑色背景板,使得鲳鱼主体更突出,成像更清晰。使用 X-S10 型数码单反相机拍摄鲳鱼图像。将鲳鱼样品水平放置,相机镜头位于样品上方 30 cm 的垂直固定位置,所获图像包含样品两侧全貌以及鱼头部位,鲳鱼图像数据采集耗时 30 d,共采集金鲳鱼图像样本 2 387 幅,银鲳鱼图像样本 445 幅,尺寸为 5 184 像素 × 3 456 像素。




图 1 鲳鱼样本在 0℃ 存储条件下 30 d 的图像变化
Fig. 1 Images of pomfret samples stored at 0℃ for 30 d

图像预处理包括图像缩放和数据增强两部分。考虑到将高分辨率图像直接送入深度学习网络会导致内存溢出,本实验编写 Python 脚本实现对鲳鱼图像统一缩放,将鲳鱼图像尺寸降低至 2 660 像素 × 1 260 像素。考虑到本文自建银鲳鱼数据集样本量

鲳鱼样本在 0℃ 存储条件下 30 d 的图像变化如图 1 所示。无论是金鲳鱼还是银鲳鱼样本,随着贮藏时间的增加,鱼眼和鱼鳃的特征变化明显:新鲜的鱼眼珠清澈透亮、眼睛微凸,鱼鳃颜色鲜艳;随着贮藏时间增加,鲳鱼样本的新鲜度变差,表现为眼珠暗淡浑浊,眼部微凹,鱼鳃颜色暗淡。结合先验知识以及对鲳鱼图像样本的观察,本实验选择鲳鱼的鱼眼和鱼鳃作为目标检测算法 ROI(感兴趣区域)。鲳鱼新鲜度标签分为 3 类:一级品、合格品以及不合格品。相应地,鱼眼部位标签分别命名为:eye1、eye2、eye3;鱼鳃部位标签分别命名为:gill1、gill2、gill3。使用 LabelImg 工具标注鱼眼和鱼鳃质变敏感部位作为目标检测算法的 ROI。

少,不足以支撑网络的训练,本实验通过数据增强的方法扩充原数据集的样本量,以提高网络的泛化能力与识别性能,降低模型训练中的过拟合现象,本实验银鲳鱼图像采用如图 2 所示的数据增强方法,得到自扩展鲳鱼新鲜度分类数据集。




图 2 银鲳鱼图像数据扩展
Fig. 2 Image data augmentation of silver pomfret

1.4 鲳鱼新鲜度等级划分

经过图像预处理,共得到金鲳鱼 2 387 幅,银鲳鱼 1 780 幅。鲳鱼图像数据集依据新鲜度等级评判标准划分为 3 类,具体见表 2。

将 3 类不同新鲜度等级的鲳鱼图像数据集分别以 3:1:1 的比例随机划分为训练集、验证集和测试集,

表 2 冰鲜鲳鱼图像数据集新鲜度等级划分

Tab. 2 Iced pomfret image freshness grade

种类	一级品	合格品	不合格品	总数量
金鲳鱼	721	676	990	2 387
银鲳鱼	468	576	736	1 780

构建的冰鲜鲳鱼新鲜度目标检测数据集如表 3 所示。

表 3 冰鲜鲟鱼新鲜度目标检测数据集

Tab.3 Iced pomfret object detecion dataset

品种	训练集	验证集	测试集	总数量
金鲟鱼	1 432	478	477	2 387
银鲟鱼	1 068	356	356	1 780

2 基于 SSD 算法的鲟鱼新鲜度评估

2.1 模型建立

2.1.1 SSD 算法结构

SSD 是基于回归的目标检测算法,它通过一个 CNN 卷积神经网络将生成候选框与目标分类任务合并,以提升网络检测效率。原始 SSD 算法结构主要包括 VGG-16 主干网络、辅助卷积与预测层。首先,VGG-16 网络的两个全连接层被替换为卷积层以提取低维度特征信息,之后添加 4 个辅助卷积层以提取高维度特征信息。其次,对 6 个不同尺度特征图进行多尺度预测。最后,利用非极大值抑制方法,比较各预测框与真实框的交并比,输出最优的预测框。

2.1.2 主干网络改进

随着计算机对大规模参数计算性能的提高,SSD 模型以 VGG-16 为主干网络的优势已经不再明显。加强主干网络对图像特征的提取能力,是提

升网络检测精度的重要因素。本文采用 ResNet-50 作为主干网络,在一定程度上加深主干网络,加强对目标语义位置信息的抽象能力,提升网络性能。主干网络 ResNet-50 残差单元根据特征图尺寸是否发生改变分为两种:① CONV BLOCK^[22] (Convolutional block),该结构使输出特征图尺寸发生变化。②ID BLOCK^[23] (Identity block),该结构使输出特征图尺寸保持不变。

SSD-ResNet 网络结构如图 3 所示。SSD-ResNet 网络以 ResNet-50 为主干网络,并添加 5 个辅助卷积层构成一个深度残差网络。首先,保留 ResNet-50 中 Conv1 至 Conv4_x 的卷积层结构,将 Conv4_x 卷积层的步长由原始的 2 设置为 1,以保证 Conv3_x 到 Conv4_x 特征图尺寸不变。其次,在 Conv4_x 之后增加 5 个额外的辅助卷积层 Layer1~Layer5 用以提取不同尺寸的特征图,辅助卷积层均由卷积层、BN(批量归一化)层和 ReLU 激活函数组成。SSD-ResNet 网络分别在 Conv4_x 和 Layer1~Layer5 特征图上进行回归预测。其中,辅助卷积层中 S1 代表卷积核的步长为 1,S2 代表卷积核步长为 2,P0 代表 padding 设置为 SAME 方式,P1 代表 padding 设置为 VALID 方式。




图 3 SSD-ResNet 网络结构

Fig.3 SSD-ResNet network structure

2.1.3 自适应先验框设计

在改进 SSD 主干网络的基础上,对先验框设置进行了优化。原 SSD 网络先验框的设计依据人工经验,具有一定主观性。本文依据鱼眼和鱼鳃的尺寸特点设计自适应先验框,实现目标精准定位,使模型更适用于鲟鱼新鲜度评估场景下的目标检测任务。

原 SSD 网络先验框尺寸设计针对 VOC2007 标准数据集上不同的类别,这些类别的外形特征具有多样性,故依据人工经验设计了 5 种不同长宽比的先验框 $a_r = \{1, 2, 3, 1/2, 1/3\}$,以提高模型的泛化

能力。

对于第 k 个特征图,先验框尺寸计算方法为

$$S_k = S_{\min} + \frac{S_{\max} - S_{\min}}{m - 1}(k - 1) \quad (k \in [1, m]) \quad (1)$$

式中 $S_{\min}$ ——最低尺寸,取 0.2
 $S_{\max}$ ——最高尺寸,取 0.9
 m ——模型目标检测的特征图层数

SSD 网络先验框高度 h_k^a 和宽度 w_k^a 的计算公式为

$$\begin{cases} h_k^a = S_k / \sqrt{a_r} \\ w_k^a = S_k \sqrt{a_r} \end{cases} \quad (2)$$

此外,为了提高特征图间的连续性,对于长宽比为 1 的先验框,添加了尺寸 $S'_k = \sqrt{S_k S_{k+1}}$,即每个像素点有 6 个先验框,先验框的中心位置为 $\left(\frac{i+0.5}{|f_k|}, \frac{j+0.5}{|f_k|}\right)$, $|f_k|$ 表示第 k 个特征图的尺寸, $i, j \in [0, |f_k|)$ 。

对于鲳鱼新鲜度评估目标检测场景,鱼眼和鱼鳃的宽高比一般不会超过 1,若采用原始宽高比的先验框生成候选框,会造成候选框冗余,消耗计算资源。为了消除人工设计先验框存在的

主观因素,使用 K-means 方法设计自适应先验框,对冰鲜鲳鱼新鲜度目标检测数据集作聚类分析,得到先验框的最优个数以及宽高比。改进后的网络记为 DA_SSD-ResNet (Decrease anchor SSD-ResNet), DA_SSD-ResNet 网络结构如图 4 所示。K-means 聚类结果如图 5 所示,当先验框聚类个数在 1~4 时,平均交并比持续增长,当先验框聚类个数大于 4 时,平均交并比曲线趋于平缓。故本文 DA_SSD-ResNet 网络确立先验框个数为 4。




图 4 DA_SSD-ResNet 网络结构

Fig. 4 DA_SSD-ResNet network structure




图 5 平均交并比与聚类个数关系曲线

Fig. 5 Relationship between average IoU and number of clusters

依据聚类结果设计的自适应先验框宽高比为 $\alpha'_l = \{7/25, 3/10, 16/25, 17/25\}$,各层特征图先验框个数由 $\{4, 6, 6, 6, 4, 4\}$ 依次修改为 $\{4, 2, 2, 2, 2, 4\}$,改进后先验框个数由原始的 8 732 减少到 6 770。此外,为照顾鱼眼小目标检测效果,最低特征图尺寸 $S_{\min}$ 设置为 0.1,以提升模型检测效果。SSD 算法改进前后先验框参数设置如表 4 所示。设计的自适应先验框有利于优化目标检测的结果定位,加快网络模型训练。

2.2 损失函数

SSD 模型损失函数对位置和类别同时进行回

表 4 先验框参数设置对比

Tab. 4 Comparison of prior boxes parameter settings

特征图尺寸	原宽高比	原先验框个数	改进宽高比	改进先验框个数
38 × 38	{1/2, 1, 2}	38 × 38 × 4	{7/25, 3/10, 16/25, 17/25}	38 × 38 × 4
19 × 19	{1/3, 1/2, 1, 2, 3}	19 × 19 × 6	{3/10, 16/25}	19 × 19 × 2
10 × 10	{1/3, 1/2, 1, 2, 3}	10 × 10 × 6	{3/10, 16/25}	10 × 10 × 2
5 × 5	{1/3, 1/2, 1, 2, 3}	5 × 5 × 6	{3/10, 16/25}	5 × 5 × 2
3 × 3	{1/3, 1/2, 1, 2, 3}	3 × 3 × 4	{3/10, 16/25}	3 × 3 × 2
1 × 1	{1/2, 1, 2}	1 × 1 × 4	{7/25, 3/10, 16/25, 17/25}	1 × 1 × 4

归,总损失函数 L 定义为

$$L(x, c, l, g) = \frac{1}{N} (L_{conf}(x, c) + \alpha L_{loc}(x, l, g))$$

(3)

式中 $L_{conf}(x, c)$ ——置信度损失值

$L_{loc}(x, l, g)$ ——定位损失值

N ——先验框与真实标注框的匹配个数

x ——指示参数,结果匹配则为 1

c ——预测框类别置信度

α ——权重系数

l ——预测框位置信息

g ——真实标注框位置信息

置信度损失函数的计算采用 Softmax loss 思想, 具体公式为

$$L_{conf}(x, c) = - \sum_{i \in D_+} x_{ij}^p \lg(\hat{c}_i^p) - \sum_{i \in D_-} \lg(\hat{c}_i^0) \quad (4)$$

$$\text{其中 } \hat{c}_i^p = \frac{\exp(c_i^p)}{\sum_p \exp(c_i^p)} \quad (5)$$

式中 x_{ij}^p ——第 i 个先验框与第 j 个真实框匹配类别是否为 p , 若匹配 $x_{ij}^p = 1$, 否则 $x_{ij}^p = 0$

c_i^p ——第 i 个先验框类别置信度的输出

$\hat{c}_i^p$ ——第 i 个先验框类别为 p 的概率

$\hat{c}_i^0$ ——第 i 个先验框类别为背景的概率

D_+ ——正样本集

D_- ——负样本集

定位损失函数计算正样本误差, 其计算公式为

$$L_{loc}(x, l, g) = \sum_{i \in D_+} \sum_{m \in \{c_x, c_y, w, h\}} x_{ij}^k \text{smooth}_{L1}(l_i^m - \hat{g}_j^m) \quad (6)$$

式中 l_i^m ——预测第 i 个正样本的回归参数

$\hat{g}_j^m$ ——正样本 i 匹配到第 j 个实际预测框的回归参数

(c_x, c_y) ——中心坐标

w, h ——宽、高

x_{ij}^k 中 k 值为 0 或者 1。

$$\begin{cases} \hat{g}_j^{cx} = (g_j^{cx} - d_i^{cx}) / d_i^w \\ \hat{g}_j^{cy} = (g_j^{cy} - d_i^{cy}) / d_i^h \\ \hat{g}_j^w = \lg\left(\frac{g_j^w}{d_i^w}\right) \\ \hat{g}_j^h = \lg\left(\frac{g_j^h}{d_i^h}\right) \end{cases} \quad (7)$$

式中 (g^{cx}, g^{cy}) ——真实框位置

g^w, g^h ——真实框宽、高

(d^{cx}, d^{cy}) ——先验框位置

d^w, d^h ——先验框宽、高

Smooth L1 loss 函数计算为

$$\text{smooth}_{L1}(x) = \begin{cases} 0.5x^2 & (|x| < 1) \\ |x| - 0.5 & (|x| \geq 1) \end{cases} \quad (8)$$

2.3 模型训练

DA_SSD-ResNet 模型训练超参数设置均是进行了充分实验对比后得到的最优参数。使用的冰鲜鲳鱼新鲜度目标检测数据集规模小, 为了提高对鲳鱼有效特征的提取能力、缩短模型的训练时间, 本实验采用迁移学习方法, 利用在 VOC2007 标准数据集预训练所得网络权重进行参数初始化, 模型训练选择 Adam 优化器, 交并比 (IoU) 阈值设置为 0.5。此

外, DA_SSD-ResNet 网络修改了原 SSD 网络中先验框的尺寸和数量, 包括所有检测层的先验框尺寸以及 2~5 层的先验框数量。因此对所有检测层的类别置信度参数以及 2~5 层的位置回归参数进行随机初始化, 并在冰鲜鲳鱼新鲜度目标检测数据集上进行训练。

2.4 模型评估

鲳鱼新鲜度目标检测模型性能评价指标有精确率、召回率、平均精度、检测速度 (每秒检测图像的数量)。

鲳鱼新鲜度目标检测网络的最终预测结果是 3 类新鲜度等级, 理论上, 每一幅图像都会检测到鱼眼和鱼鳃目标位置及其类别置信度。鲳鱼新鲜度等级检测样例如图 6 所示。




图 6 鲳鱼新鲜度等级检测样例

Fig. 6 Example of pomfret freshness grade detection

图 6a 为理想情况, 目标检测网络预测得到鱼鳃类别为 gill3, 置信度 $\text{Conf}(\text{gill3})$ 为 0.87, 鱼眼类别为 eye3, $\text{Conf}(\text{eye3})$ 为 0.99, 鱼眼和鱼鳃的品质预测结果均为不合格品, 即本样品新鲜度等级为不合格品。然而, 也可能会出现鱼眼和鱼鳃置信度等级隶属于不同类别的情况, 如图 6b 所示, 目标检测网络预测得到鱼鳃类别为 gill2, 置信度 $\text{Conf}(\text{gill2})$ 为 0.98, 鱼眼类别为 eye1, $\text{Conf}(\text{eye1})$ 为 0.87, 此时鱼眼和鱼鳃的新鲜度预测等级隶属于不同类别。对于鱼眼和鱼鳃新鲜度等级预测不一致的情况, 选取置信度高的结果作为最终的鲳鱼品质评定等级, 即该样品新鲜度等级为合格品。

3 结果与分析

3.1 不同策略优化 SSD 网络性能对比分析

通过改进主干网络和设计自适应先验框的优化策略对 SSD 网络进行训练, 并在金鲳测试集和银鲳测试集上验证模型结果。

3.1.1 改进主干网络

表 5 展示了改进主干网络对 SSD 网络检测性能的影响。以金鲳测试集为例, 以 ResNet-50 为主干网络的 SSD-ResNet 模型 (平均精度均值) 为 96.90%, 比 SSD 模型提升 5.71 个百分点, 并且对鱼眼目标的检测精度提升了 10 个百分点。以 ResNet-50 为主干网络可以更好地抽象鲳鱼图像语义和位

置特征,从而提升模型的检测精度。改进主干网络后,检测速度虽降低了 2 帧/s,但依旧能够满足实时检测的需求,在保证速度的同时换来了精度

的快速提升。该结论对于银鲮鱼测试集依旧适用,说明 SSD – ResNet 具备较好的可扩展性和可迁移性。

表 5 改进主干网络对 SSD 网络检测性能的影响
Tab. 5 Influence of backbone on SSD network performance

数据集	算法	主干网络	平均精度/%						平均精度	检测速度/
			eye1	eye2	eye3	gill1	gill2	gill3	均值/%	(帧 · s ⁻¹)
金鲮鱼	SSD	VGG – 16	84. 01	81. 56	88. 14	99. 09	96. 99	98. 37	91. 19	36
	SSD – ResNet	ResNet – 50	98. 91	94. 19	98. 99	98. 62	94. 17	96. 64	96. 90	34
银鲮鱼	SSD	VGG – 16	96. 44	95. 87	98. 45	98. 03	98. 92	98. 12	97. 62	35
	SSD – ResNet	ResNet – 50	99. 93	97. 02	99. 89	99. 52	98. 38	99. 87	99. 06	33

图 7a 和图 7b 分别展示了 SSD 和 SSD – ResNet 模型在金鲮鱼数据集的损失值和学习率, SSD – ResNet 的损失收敛速度快于 SSD,且收敛的损失值更低。图 8 展示了 SSD 和 SSD – ResNet 模型在金鲮鱼数据集不同类别的 PR(精确率-召回率),可以直观地看到, SSD – ResNet 模型提升了不同目标类别的平均精度,对鱼眼目标平均精度的提升尤为明显,以 ResNet – 50 为主干网络加强了模型对鱼眼细粒度特征的提取效果。此外, eye3 类别的召回率由 92% 提升至 100%,表明 SSD – ResNet 模型对鱼眼目标漏检率降低。




图 7 SSD、SSD – ResNet 在金鲮鱼数据集的损失值和学习率曲线
Fig. 7 Loss and learning rate curves of SDD and SSD – ResNet in golden pomfret dataset

3. 1. 2 设计自适应先验框

表 6 为设计自适应先验框对 SSD 网络检测性




图 8 SSD 和 SSD – ResNet 在金鲮鱼数据集的不同类别 PR 曲线
Fig. 8 Precision recall curves of SDD and SSD – ResNet in golden pomfret dataset

能的影响。

以金鲮鱼测试集为例,设计自适应先验框的 DA_SSD – ResNet 的平均精度均值最高,达到 98. 97%,比 SSD – ResNet 高 2. 07 个百分点。设计自适应先验框的 DA_SSD 的平均精度均值为 94. 97%,比 SSD 高 3. 78 个百分点;此外,改进先验框的 SSD 网络对鱼眼、鱼鳃的单目标检测精度均有提升,这表明设计自适应先验框实现了对鱼眼和鱼鳃目标自动定位与精准识别。本优化策略设计了符合鲮鱼鱼眼、鱼鳃尺寸特点的先验框以及更小的 S_{min} ,减少了无用先验框的产生,增强了对小目标的提取能力,使模型更适用于鲮鱼新鲜度评估场景下的目标检测任务。由于设计的自适应先验框减少了先验框的生成数量,模型检测速度因此提升了 3 ~ 5 帧/s,

表 6 设计自适应先验框对 SSD 网络检测性能的影响

Tab.6 Influence of designing adaptive prior boxes on SSD network performance

数据集	算法	主干网络	先验框设计	平均精度/%						平均精度	检测速度/
				eye1	eye2	eye3	gill1	gill2	gill3	均值/%	(帧·s ⁻¹)
金鲳鱼	SSD	VGG-16	否	84.01	81.56	88.14	99.09	96.99	98.37	91.19	36
	DA_SSD	VGG-16	是	94.43	83.20	94.10	99.97	99.59	98.53	94.97	41
	SSD-ResNet	ResNet-50	否	98.91	94.19	98.99	98.62	94.17	96.64	96.90	34
	DA_SSD-ResNet	ResNet-50	是	99.56	97.60	99.67	99.28	98.55	99.34	98.97	37
银鲳鱼	SSD	VGG-16	否	96.44	95.87	98.45	98.03	98.92	98.12	97.62	35
	DA_SSD	VGG-16	是	97.94	98.25	98.86	98.90	98.87	98.89	98.63	41
	SSD-ResNet	ResNet-50	否	99.93	97.02	99.89	99.52	98.38	99.87	99.06	33
	DA_SSD-ResNet	ResNet-50	是	99.95	97.98	99.99	99.82	97.82	99.98	99.42	39

实现了模型精度与时间效率的提高。该结论对于银鲳鱼测试集依旧适用,说明设计自适应先验框的 SSD 算法在保证网络高性能的同时具备较好的可扩展性和可迁移性。

图 9 ~ 11 分别为 SSD-ResNet 和 DA_SSD-ResNet 模型的平均精度均值曲线、损失值和学习率曲线、PR 曲线对比图。




图 9 SSD-ResNet 和 DA_SSD-ResNet 在金鲳鱼数据集的平均精度均值曲线

Fig.9 The mAP curves of SDD-ResNet and DA_SSD-ResNet in golden pomfret dataset

如图 10 所示,DA_SSD-ResNet 网络的初始损失值比 SSD-ResNet 网络大,且需要更多的迭代次数使模型平均精度均值趋于稳定,原因是 DA_SSD-ResNet 弃用了检测层类别置信度与位置回归参数的预训练权重,通过权重随机初始化对冰鲜鲳鱼新鲜度目标检测数据集进行训练,因此训练初期的损失值较大,需要较长训练时间。在整个训练过程中,SSD-ResNet 的损失值收敛于 1.2 附近,DA_SSD-ResNet 收敛于 0.8 附近,具有更低的损失值。如图 9 所示,SSD-ResNet 经过 14 次迭代平均精度均值稳定在 96.90%,DA_SSD-ResNet 经过 60 次迭代平均精度均值稳定在 98.97%。图 11 可以直观地看到,DA_SSD-ResNet 在单类别检测精度方面远高于 SSD-ResNet 模型。与人工设计先验框的方式相比,采用 K-means 聚类方法设计自适应先验框显著地提升了不同目标类别的平均精度。

3.1.3 识别效果对比

图 12 展示了 DA_SSD-ResNet 与 SSD 模型在




图 10 SSD-ResNet、DA_SSD-ResNet 在金鲳鱼数据集的损失值和学习率曲线

Fig.10 Loss and learning rate curves of SSD-ResNet and DA_SSD-ResNet in golden pomfret dataset

金鲳鱼图像上的检测效果,实验的非极大值抑制阈值设置为 0.8。从图中可以看出,DA_SSD-ResNet 有效缓解了 SSD 中存在的目标漏检、误检和标框位置不准确问题。实验证明,DA_SSD-ResNet 的检测效果明显优于 SSD。

3.2 与其他目标检测方法对比分析

为了测试 DA_SSD-ResNet 的网络性能,对比实验选取了 Faster R-CNN^[24]、YOLO^[25]、SSD^[26] 模型等经典目标检测算法,并对金鲳鱼数据集进行测试,统计平均精度、平均精度均值、检测速度等性能指标。表 7 展示了不同模型方法对金鲳鱼新鲜度检测的结果。




图 11 SSD-ResNet、DA_SSD-ResNet 在金鲷鱼数据集的不同类别 PR 曲线

Fig. 11 Precision recall curves of SSD-ResNet and DA_SSD-ResNet in golden pomfret dataset




图 12 SSD 与 DA_SSD-ResNet 检测效果对比

Fig. 12 Detection results comparison of SSD and DA_SSD-ResNet

表 7 金鲷鱼测试集中不同模型的测试结果比较

Tab. 7 Results of each model in golden pomfret test set

算法	主干网络	平均精度/%						平均精度	检测速度/
		eye1	eye2	eye3	gill1	gill2	gill3	均值/%	(帧·s ⁻¹)
Faster R-CNN	VGG-16	98.60	92.51	99.27	98.26	91.03	99.57	96.54	13
	ResNet-50	99.72	98.55	99.78	99.96	99.89	100	99.70	11
	ResNet-101	99.22	98.59	99.44	99.94	99.80	99.99	99.48	6
YOLO v3	Darknet-53	95.07	92.55	96.23	95.24	94.01	95.34	94.51	76
SSD	VGG-16	84.01	81.56	88.14	98.09	96.99	98.37	91.19	36
	ResNet-50	98.91	94.19	98.99	98.62	94.17	96.64	96.90	34
DA_SSD-ResNet	ResNet-50	99.56	97.60	99.67	99.28	98.55	99.34	98.97	37

从表 7 中可以看到,Faster R-CNN 的平均精度均值最高,达到了 99.70%,但检测速度无法满足实时检测的需求。YOLO v3 的检测速度最高,为 76 帧/s,但检测精确度较低。改进的 DA_SSD-ResNet 既有较高的检测精度与识别能力又能满足实时检测的需求,很好地平衡了识别精度与检测速度的关系。

4 结束语

本文以冰鲜鲷鱼为研究对象,依据先验知识划分鲷鱼鱼眼和鱼鳃为 ROI,基于改进 SSD 的目标检

测算法探究鲷鱼新鲜度等级评估方法,用于区分鲷鱼一级品、合格品和不合格品新鲜度等级。首先,本文选取 ResNet-50 作为主干网络,提升对鲷鱼图像语义和位置信息的提取能力,以提升网络检测精度。其次,采用 K-means 聚类方法设计自适应先验框实现目标精准定位,避免了人为设计先验框的主观性,使模型更适用于鲷鱼新鲜度评估场景下的目标检测任务。优化后的 DA_SSD-ResNet 模型平均精度均值达到 98.97%,检测速度达到 37 帧/s,满足应用场景中对实时性和评估准确率的需求,实现鲷鱼新鲜度低成本、高效、准确的评估。

参 考 文 献

- [1] NAGARAJARAO R. Recent advances in processing and packaging of fishery products: a review[J]. Aquatic Procedia, 2016, 7: 201 – 213.
- [2] 李秀霞, 马莹莹, 赵利爽. 中国对虾冻藏期间新鲜度和质构的变化[J]. 食品工业, 2019, 40(1): 122 – 126.
LI Xiuxia, MA Yingying, ZHAO Lishuang. Changes of freshness and texture of *Fenneropenaeus chinensis* during frozen storage[J]. The Food Industry, 2019, 40(1): 122 – 126. (in Chinese)
- [3] WU L, PU H, SUN D. Novel techniques for evaluating freshness quality attributes of fish: a review of recent developments[J]. Trends in Food Science & Technology, 2019, 83(2): 259 – 273.
- [4] DU L, CHAI C, GUO M, et al. A model for discrimination freshness of shrimp[J]. Sensing and Bio-sensing Research, 2015, 6: 28 – 32.
- [5] CRISTINA B, TEIXEIRA M, DE F. Quality index method (QIM) to assess the freshness and shelf life of fish[J]. Brazilian Archives of Biology and Technology, 2013, 56(4): 587 – 598.
- [6] PIVARNIK L, KAZANTZIS D, KARAKOLTSIDIS P, et al. Freshness assessment of six New England fish species using the torryster[J]. Journal of Food Science, 2010, 55(1): 79 – 82.
- [7] LI Z, LI Y, YANG Y, et al. A high-precision detection method of hydroponic lettuce seedlings status based on improved Faster RCNN[J]. Computers and Electronics in Agriculture, 2021, 182: 106054.
- [8] LI Z, YANG Y, LI Y, et al. A solanaceae disease recognition model based on SE-Inception[J]. Computers and Electronics in Agriculture, 2020, 178: 105792.
- [9] YU Z, CAO Z, WU X, et al. Automatic image-based detection technology for two critical growth stages of maize: emergence and three-leaf stage[J]. Agricultural and Forest Meteorology, 2013, 174: 65 – 84.
- [10] 董春旺, 朱宏凯, 周小芬, 等. 基于机器视觉和工艺参数的针芽形绿茶外形品质评价[J]. 农业机械学报, 2017, 48(9): 38 – 45.
DONG Chunwang, ZHU Hongkai, ZHOU Xiaofen, et al. Quality evaluation for appearance of needle green tea based on machine vision and process parameters[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(9): 38 – 45. (in Chinese)
- [11] BALABAN M. Quantifying nonhomogeneous colors in agricultural materials part I: method development[J]. Journal of Food Science, 2008, 73(9): S431 – S437.
- [12] GB/T 18108—2019 鲜海水鱼通则[S]. 2019.
- [13] AGHBASHLO M, HOSSEINPOUR S, GHASEMI M. Computer vision technology for real-time food quality assurance during drying process[J]. Trends in Food Science & Technology, 2014, 39(1): 76 – 84.
- [14] SHI C, QIAN J, HAN S, et al. Developing a machine vision system for simultaneous prediction of freshness indicators based on tilapia (*Oreochromis niloticus*) pupil and gill color during storage at 4℃[J]. Food Chemistry, 2018, 243(1): 134 – 140.
- [15] DUTTA M, ISSAC A, MINHAS N, et al. Image processing based method to assess fish quality and freshness[J]. Journal of Food Engineering, 2016, 177(3–4): 50 – 58.
- [16] 许澄, 赵启蒙, 黄雯, 等. 草鱼鱼鳃颜色变化作为新鲜度快速检测指标的可行性探究[J]. 上海农业学报, 2017, 33(1): 149 – 154.
XU Cheng, ZHAO Qimeng, HUANG Wen, et al. Feasibility research on the color changes of grass carp gill as a rapid detection index of freshness[J]. Acta Agriculturae Shanghai, 2017, 33(1): 149 – 154. (in Chinese)
- [17] TAHERI A, FATAHI S, BANAN A, et al. Real-time nondestructive monitoring of common carp fish freshness using robust vision-based intelligent modeling approaches[J]. Computers and Electronics in Agriculture, 2019, 159(3): 16 – 27.
- [18] TAHERI-GARAVAND A, NASIRI A, BANAN A, et al. Smart deep learning-based approach for non-destructive freshness diagnosis of common carp fish[J]. Journal of Food Engineering, 2020, 278: 109930.
- [19] 杨晋琪. 基于计算机视觉的冰鲜鲳鱼新鲜度评估方法研究[D]. 北京: 中国农业大学, 2020.
YANG Jinqi. Freshness evaluation of iced pomfret based on computer vision[D]. Beijing: China Agricultural University, 2020. (in Chinese)
- [20] HE K, GKIOXARI G, DOLLÁR P, et al. Mask R – CNN[C] // Proceedings of the IEEE International Conference on Computer Vision, 2017: 2961 – 2969.
- [21] FERNÁNDEZ-SEGOVIA I, FUENTES A, ALIÑO M, et al. Detection of frozen-thawed salmon (*Salmo salar*) by a rapid low-cost method[J]. Journal of Food Engineering, 2012, 113(2): 210 – 216.
- [22] WOO S, PARK J, LEE J, et al. CBAM: convolutional block attention module[C] // Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3 – 19.
- [23] HE K, ZHANG X, REN S, et al. Identity mappings in deep residual networks[C] // European Conference on Computer Vision, 2016: 630 – 645.
- [24] REN S, HE K, GIRSHICK R, et al. Faster R – CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis Machine Intelligence, 2016, 39(6): 1137 – 1149.
- [25] REDMON J, FARHADI A. YOLOv3: an incremental improvement[J]. Computer Vision Pattern Recognition, 2018, 1804: 02767.
- [26] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C] // European Conference on Computer Vision, 2016: 21 – 37.