光电技术及应用

DOI：10.16818/j.issn1001－5868.2023062801

重参数化大核卷积的光学黑色素瘤图像检测算法

苏 炅，曾志高，刘 强*，易胜秋，文志强，袁鑫攀

（湖南工业大学 计算机学院，湖南 株洲 412000）

摘 要： 针对皮肤镜采集的光学黑色素瘤图像，由于其背景信息复杂，干扰信息过多，导致检测精度较低，容易出现误检、漏检等问题，提出一种重参数化大核卷积的光学黑色素瘤图像检测算法。首先，在主干部分设计一种融合大核卷积与 C3 的新模块 C3_RepLK，以增大模型的感受野，提取更多的有效信息。其次，引入感受野模块 RFB，融合不同尺度的特征信息，减少错检。颈部网络中采用混合密集稀疏卷积 GSConv 和轻量化上采样算子 CARAFE，使得网络能够捕捉到丰富的上下文信息，抑制漏检。最后，在算法中融入二阶通道注意力模块 SOCA，加强特征之间的关联性，关注更有用的特征。实验表明，所提检测算法较原 YOLOv5 算法，所有类别平均精度从 85.0％提升至 89.4％，证明所提出的算法对于检测黑色素瘤的有效性。

关键词： 黑色素瘤；注意力机制；YOLOv5；大核卷积；轻量化上采样算子

中图分类号： TP391.4 **文章编号：** 1001－5868(2023)05－0788－08

Optical Melanoma Image Detection Algorithm Based on Heavy Parameterized Large Kernel Convolution

SU Jiong, ZENG Zhigao, LIU Qiang, YI Shengqiu, WEN Zhiqiang, YUAN Xinpan

(School of Computer Science Hunan University of Technology, Zhuzhou 412000, CHN)

Abstract: Due to the complex background information and too much interference information of the optical melanoma image collected by dermoscopy, the detection accuracy is low, and there are problems such as false and missed detection. Therefore, an optical melanoma image detection algorithm based on reparameterized large kernel convolution is proposed. Firstly, in the backbone part, a new module C3_RepLK that combines large kernel convolution and C3 was designed to increase the receptive field of the model and extract more effective information. Secondly, the receptive field module RFB was introduced to fuse the feature information of different scales to reduce the problem of false detection. The hybrid dense sparse convolution GSConv and lightweight upsampling operator CARAFE were used in the neck network, so that the network could capture rich context information and suppress the missed detection problem. Finally, the second-order channel attention module SOCA was integrated into the algorithm to strengthen the correlation between features and focus on more useful features. Experimental results show that compared with the original YOLOv5 algorithm, the proposed detection algorithm improves the average accuracy of all categories from 85.0% to 89.4%, which proves the effectiveness of the proposed algorithm for detecting melanoma.

收稿日期：2023－06－28.

基金项目：科技创新 2030—“新一代人工智能”重大项目(2018AAA0100400)；湖南省教育厅项目(21A0350，21C0439)；湖南省自然科学基金项目(2022JJ50051，2021JJ50058，22A044，2022JJ30231).

* **通信作者：**刘 强 **E-mail：** liuqiang@hut.edu.cn

Key words: melanoma; attention mechanism; YOLOv5; large nuclear convolution; lightweight upsampling operator

0　引言

黑色素瘤是一种恶性皮肤肿瘤，其恶性程度是皮肤类疾病最为严重的。初期可治愈的，若等晚期发现，其生存率会大大降低[1]。近年来，我国皮肤肿瘤类疾病的发病率也在逐步上升[2]。传统上，一般由医生直接目视观察并结合皮肤镜图像的目视检查进行诊断。由于传统检测方法较慢，而且受医生个人经验或状态等其他客观因素影响。所以提高早期诊断准确率，对于减少误诊十分关键。因此，黑色素瘤识别检测具有一定的现实意义。

随着深度学习的不断进步，计算机辅助诊断可以给医生带来参考，从而做出更加准确的判断。近年来目标检测也在不断发展，在医学图像领域得到了广泛应用[3]。对黑色素瘤进行检测有望帮助医生和专家做出正确的决定，尽早诊断患者的病情，降低死亡率[4]。目前，目标检测算法一般可分为两类，一类是基于候选框的双阶段算法，如 Fast R-CNN (Fast Region-based Convolutional Network)[5]、Mask RCNN (Mask Region-Based Convolutional Neural Network)[6]等，这类算法计算量大，检测速度较慢。另一类是基于生成的候选框，直接进行分类和微调边界框单阶段算法，如单步多框目标检测 (Single Shot MultiBox Detector, SSD) 算法[7]、YOLO(You Only Look Once)[8]等，这类算法较前一类的复杂度和检测速度有了进一步的提升。

Berman 等[9]利用 YOLOv3 算法对黑色素瘤进行检测，但 YOLOv3 算法模型对检测小目标定位精度和召回率较低。Ali 等[10]使用决策树来预测不对称性皮肤病变图像，识别出可疑颜色的数量和直径值，准确率达到 80%。Gaonkar 等[11]提出了一种新的适应度函数，获得最相关的特征值来识别黑色素瘤，整体的模型复杂度较高。Zunair 等[12]提出了一个两阶段框架网络，使用对抗训练和迁移学习对黑色素瘤进行检测，能显著提高精度，但检测时间过长。传统的模型算法在黑色素瘤检测识别中，存在识别精度较低、模型复杂度过高等问题。

综合上述分析，本文选择轻量化算法 YOLOv5 进行改进，提出一种重参数化大核卷积的黑色素瘤检测算法。在主干部分设计一种融合重参数化大核卷积与 C3 的新模块 C3_RepLK，并且引入 RFB (Receptive Field Block)[13]模块替换原来的 SPPF (Spatial Pyramid Pooling-Fast)模块。颈部网络中采用混合密集稀疏卷积 GSConv[14]替换部分普通卷积，使用轻量化上采样算子(CARAFE)[15]替换原算法的上采样模块。在算法检测头前融入二阶通道注意力模块 SOCA (Second-Order Channel Attention)[16]。改进后的算法可进一步抑制漏检、错检率，提高黑色素瘤检测精度。

1　改进的 YOLOv5 算法

YOLOv5 是一种精度高、速度快的单阶段目标检测网络。根据网络的深度和宽度可以分为四个版本 s，m，l，x，其中 YOLOv5s 的检测速度最快，在实际应用中对设备条件要求较低，能节约成本。所以本实验采用 YOLOv5s 进行改进。通常划分为四个模块，主要包括输入端 (Input)、基准网络 (Backbone)、颈部网络 (Neck Network) 与检测头 (Predict Head)。

本文工作对 YOLOv5s 的结构进行改进，集中在以下几个部分进行体现：

基准网络中提出融合重参数化大核卷积的 C3 模块，其能更好提取有效感受野，突出黑色素瘤形状信息，降低背景毛发等其他无关特征信息干扰的问题。引入 RFB 模块，融合多尺度检测下不同形状大小的位置信息，提升对检测目标的召回率，减少误检。

颈部网络采用轻量化算子替换原本上采样模块，利用混合密集稀疏卷积替换原本普通 CBS 模块，关注病变区域的重要相关信息，抑制漏检，在保证提高精度的同时额外带来的参数量和计算量可忽略不计。

检测头前融合 SOCA 注意力机制，加强检测模型对于病灶区域的关注，降低图像中冗余的无用信息，增强判别能力，进一步提高黑色素瘤的识别精度。其改进后算法结构如图 1 所示。

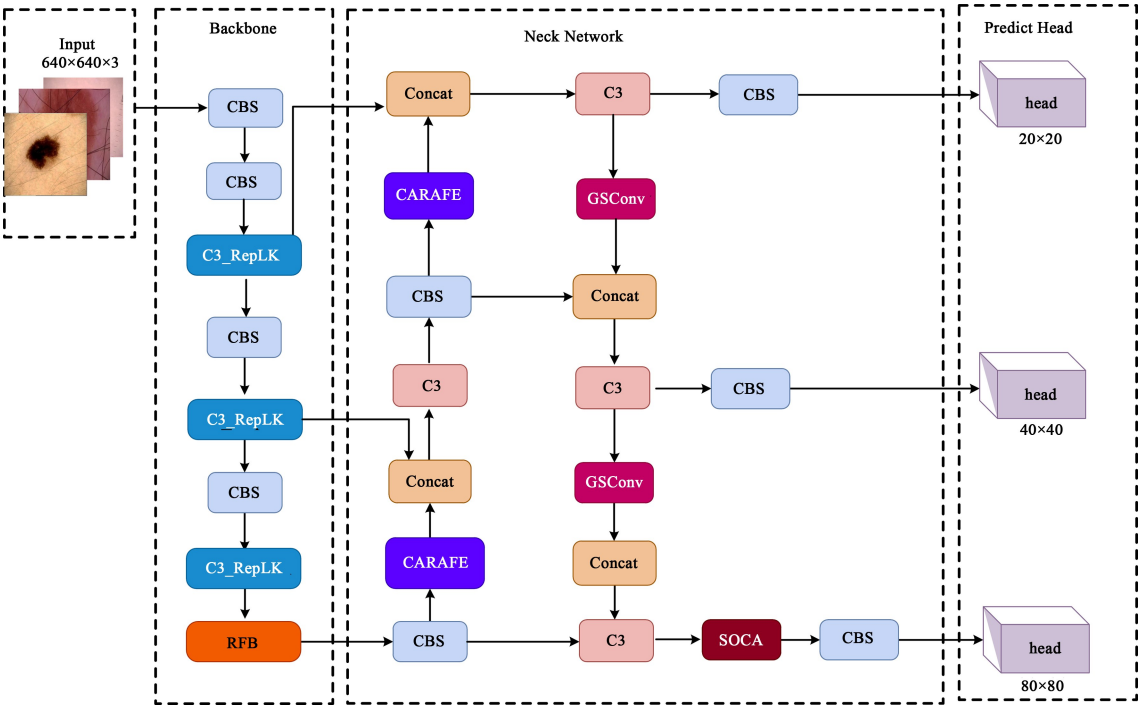

图 1 改进后算法结构图

1.1 Backbone 改进

1.1.1 重参数化大核卷积

YOLOv5 算法的基准网络有效深度不深，从而有效感受野不大，可提取的有效特征比较少。在基准网络中使用 CBS 模块和 C3 模块相结合提取其特征，C3 模块能增加网络的深度和感受野，提高特征提取的能力。但是通过深层网络结合小卷积核堆叠容易产生优化问题，大量复杂冗余的背景信息没有得到有效的过滤，导致输出特征图所包含的有效信息比较少。大核卷积通过增加卷积核尺寸来增大感受野，抑制小卷积多次堆叠带来有效信息丢失问题，但同时大卷积核会带来计算量的增加。

RepLKNet[17] 提出了一种 RepLK Block 的大卷积核结构，在不显著增加计算量的同时能够增大感受野，增加网络对有效特征的提取能力。RepLK Block 是通过一个归一化批处理，两个 1×1 Conv 卷积和具有残差结构的重参数化大核卷积 RepLK Conv 组成。其中，RepLK Conv 中使用大卷积核的深度可分离卷积层，用于结构重参数化，再并行深度可分离卷积，分别经过 BN 处理后将其特征图相加作为输出。其详细结构如图 2 所示。

大核参数化卷积可以显著增加有效感受野，可包含更多的上下文等信息。大卷积的计算成本很高，参数量和计算量与卷积核大小成二次方关系，而深度可分离卷积恰好可以弥补这一缺点。如图所示，在深度可分离卷积前用 1×1 卷积增加特征维度，增加非线性和通道间的信息交流。

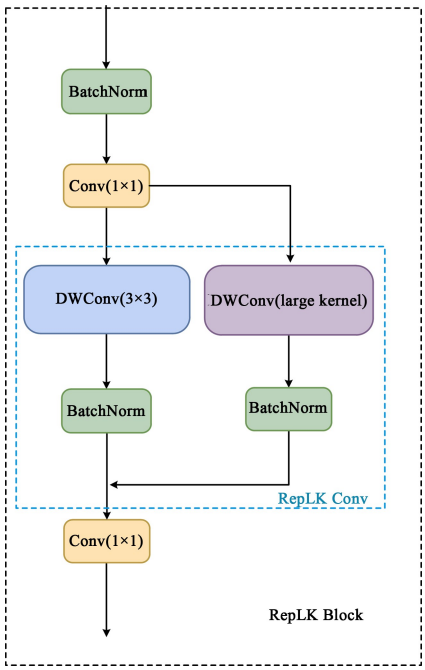

图 2 RepLK Block 结构图

为了提取有效感受野，突出黑色素瘤形状信息，降低背景毛发等其他无关特征信息的干扰。本文提出一种 C3_RepLK 模块，将 RepLK Block 和 C3 模块相结合，替换原本的 C3 模块，其模块结构图如图

3 所示。

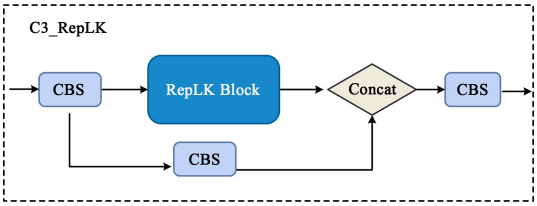

图 3　C3_RepLK 模块结构图

1.1.2　引入 RFB 模块

RFB 模块是基于多尺度特征提取网络，它借鉴了 Inception[18] 的思想，融合多尺度不同分支的特征。引入空洞卷积扩大网络模型的有效感受野，在参数量不增加的同时，输出更大分辨率特征图，如图 4 所示。

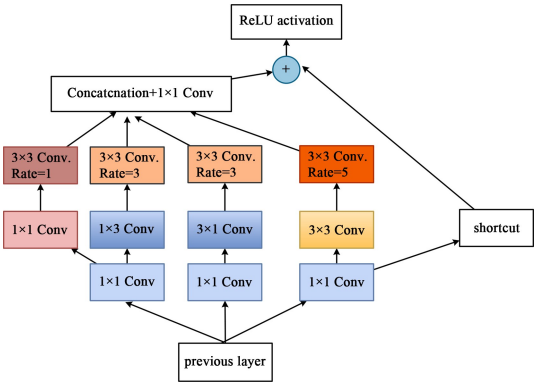

图 4　RFB 模块结构图

图 4 中，Rate 为空洞卷积的膨胀率因子。从左到右看，第一个分支采用两个 1×1 的卷积，一个 3×3 的空洞卷积，Rate 为 1。第二、三个分支使用一个 1×1 的卷积，一个 1×3 的卷积和一个 3×3 的空洞卷积，Rate 为 3。第四个分支使用一个 1×1 的卷积，一个 3×3 的卷积和一个 3×3 的空洞卷积，Rate 为 5。然后将四个分支的输出在通道维度进行拼接，接着通过 1×1 的 Conv 进行降维，再和 shortcut 分支输出的特征图做 add 操作，最后经过激活函数得到不同尺度的特征，从而建立局部和全局的依赖关系，学习更多有用的特征。因此，将 YOLOv5 原特征融合模块 SPPF 替换为 RFB 模块，充分提取不同尺度的感受野，丰富网络模型对特征的提取能力。

1.2　Neck Network 改进

1.2.1　混合密集稀疏卷积

普通卷积(SC)计算最大限度地保留了每个通道之间的隐藏连接，而深度可分离卷积(DSC)则完全切断连接。因此引入混合密集稀疏卷积 GSConv，将两者的优势结合起来，将 SC 中的有用信息融入到 DSC 中，在空间维度最小、通道维度最大时使用可以提高网络性能。

SC，DSC 和 GSConv 的时间复杂度分别可以用式(1)～(3)表示：

$$T_{SC} \sim O(W \cdot H \cdot K_1 \cdot K_2 \cdot C_1 \cdot C_2) \quad (1)$$

$$T_{DSC} \sim O(W \cdot H \cdot K_1 \cdot K_2 \cdot 1 \cdot C_2) \quad (2)$$

$$T_{GSC} \sim O\left[W \cdot H \cdot K_1 \cdot K_2 \cdot \frac{C_2}{2}(C_1+1)\right] \quad (3)$$

可以看出 GSConv 的时间复杂度最小，计算性能最优。在颈部网络中，特征图的通道维度达到最大，宽高维度达到最小，不需要进行变换，在这个阶段使用 GSConv 处理拼接特征最优，能提炼出更多有效信息，除去冗余复杂信息的干扰。其详细结构图如图 5 所示。

GSConv 包含标准卷积和深度可分离卷积两个分支。首先将两个分支输出的内容在通道维度上进行 concat，然后经过 shuffle 操作将标准卷积生成的信息融合到深度可分离卷积生成信息的每个部分。在降低计算量的同时，保持标准卷积对特征的提取能力。

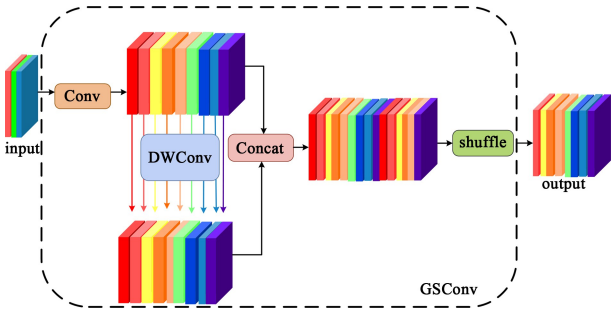

图 5　混合密集稀疏卷积结构图

1.2.2　轻量化上采样算子

YOLOv5 颈部网络采用普通的上采样算子，然而其对高维度特征信息的提取能力有限。为了解决此问题，引入轻量化上采样算子 CARAFE。CARAFE 由上采样预测模块和特征重组模块两部分构成。其详细结构如图 6 所示。

第一个模块：给定一个 $C \times H \times W$ 的输入特征图 X，上采样率为 σ。使用一个 1×1 卷积之后使其通道数压缩为 C_m，得到特征图 $C_m \times H \times W$。对此特征图进行编码，输出尺寸大小为 $H \times W \times \sigma^2 \times k_{up}^2$，代表预测上采样核的尺寸，$k_{up}^2$ 即重组核大小，

再利用 softmax 进行归一化处理。

第二个模块：在输出特征图 X' 的随机选择位置 $l'=(a',b')$，利用尺寸大小 k_{up}^2 在空间维度组合，得到特征重组核 W'_l。针对输出特征图 X 的位置 L，定义表示以位置 L 为中心的输入特征图 X 的 $k\times k$ 大小的子区域 M，结合预测出来此时的上采样核 W'_l 做卷积运算从而计算输出最终的上采样结果。相关计算公式如下所示：

$$X'_{l'}=\sum_{n=-r}^{r}\sum_{m=-r}^{r}w'_{l(n,m)}\cdot X_{(a+n,b+m)} \tag{4}$$

重组之后特征图能关注病变区域的重要相关信息，与原始的方法相比额外带来的参数量和计算量可忽略不计。

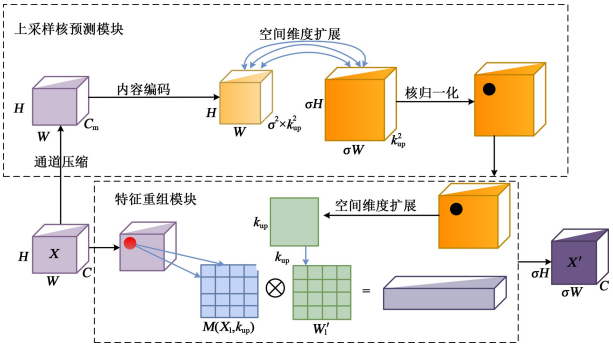

图 6 轻量化上采样算子结构图

1.2.3 SOCA 注意力模块

SE Net[19] 中使用全局平均池化按通道维度对特征信息提取，仅用了一阶特征向量的数据。然而，更高阶别的数据能够使网络关注更多的信息特征。

SOCA 包括协方差归一化和通道注意力两个部分。与之前提出的通道注意力不同，高于一阶的特征统计量可以被更灵活地用来重新缩放特征，利用特征图各元素的协相关信息，能使网络学习更多的重要信息并增强判别性学习能力，加强特征之间的关联性。其具体结构如图 7 所示。

首先输入尺寸大小为 $C\times H\times W$ 的特征图，通过 H_{GCP}，即全局协方差池化，算出其对应的协方差矩阵。最后对 C 个列向量分别求均值得到通道描述符 Z_n，Z_n 用在最开始输入的特征，实现通道注意。计算公式如式(5)所示：

$$Z_n=H_{GCP}(y_c)=\frac{1}{c}\sum y_c(i) \tag{5}$$

式中，W_D，W_U 表示卷积层，第一个卷积进行通道降维，第二个卷积进行通道还原，学习到二阶信息的特征图。输出最终的二阶通道注意力向量 w，计算公式如式(6)所示。最终将 w 与输入特征按通道相乘，再得到新的特征图。其中 f 表示 sigmoid 函数。

$$w=f(W_U\delta(W_DZ_n)) \tag{6}$$

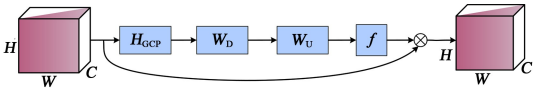

图 7 SOCA 注意力模块结构图

2 实验结果及分析

2.1 实验环境配置

本文使用的实验环境配置如表 1 所示。

表 1 实验环境

Item	Configuration
CPU	Inter(R)Core(TM)i5-12400
GPU	GeForce RTX 3060
OS version	Windows11
Cuda version	11.4
Pytorch version	1.13

2.2 数据集及评价指标

实验使用来自国际皮肤成像合作组织 ISIC (International Skin Imaging Collaboration)提供的公开数据集[20]，其中的皮肤病变图像是由专业的医学专家判断得出的，可保证数据的真实有效性。实验使用标注好的 2 051 张图像，其中包含来自 1 025 张良性黑色素瘤和 1 026 张恶性黑色素瘤图像。实验中训练集、验证集划分的比例为 9∶1。

实验采用的评价标准是检测领域中比较常见的指标：准确率(Precision，P)、召回率(Recall，R)、平均精度(Average Precision，AP)和类别平均精度(mean Average Precision，mAP)，分别由公式(7)～(10)表示：

$$P=\frac{TP}{TP+FP} \tag{7}$$

$$R=\frac{TP}{TP+FN} \tag{8}$$

$$AP=\int_0^1 P\,\mathrm{d}R \tag{9}$$

$$mAP=\frac{\sum_{i=1}^{c}AP_i}{c} \tag{10}$$

式中，TP 为模型正确识别出黑色素瘤数量，FN 为模型未识别出的黑色素瘤数量，FP 为模型错误识别的黑色素瘤数量，c 表示需识别类别的数量。

2.3 网络参数设置

在训练时，以 YOLOv5s 为基础的改进前后模

型均使用 Mosaic4 数据增强，同时使用 YOLOv5s 的预训练权重来提高模型的性能。将批次 batchsize 设置为 16，初始学习率设置为 0.01，动量参数设置为 0.937，使用余弦退火函数降低学习率，并设置训练轮次为 100 epochs。

目标检测算法的损失函数由目标框损失（Box Loss）、置信度损失（Obj Loss）和分类损失构成（Cls Loss）。目标框损失使用 CIOU loss，后两个损失使用 BCE loss。在相同环境下进行实验，可以得出改进前后模型在验证集上的各损失曲线，改进模型前后的 Box loss，Obj loss 和 Cls loss 分别如图 8，9，10 所示。

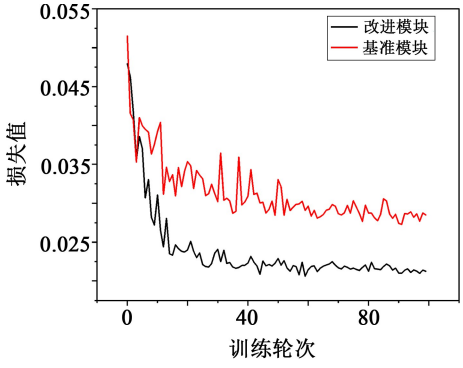

图 8　目标框损失

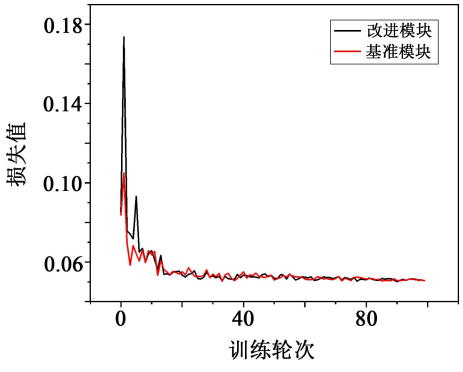

图 9　置信度损失

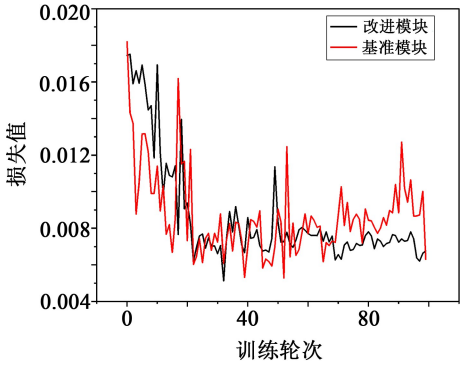

图 10　分类损失

从图 8，9，10 可以看出，相对改进前，改进后的 Box loss，Obj loss 和 Cls loss 都相对降得更低，且在 0 附近波动，最终趋于收敛。

2.4　实验结果分析

为验证各个改进模块的有效性，通过在标注好的 ISIC 数据集上，以 YOLOv5s 为基准加入不同模块进行消融实验。具体结果如表 2 所示。

表 2　消融实验

Model	P/%	R/%	$mAP_{0.5}$/%	$mAP_{0.5:0.95}$/%	FPS/(frame·s^{-1})
YOLOv5s	79.2	76.9	85.0	49.4	101.7
＋C3_RepLK	81.4	84.5	86.2	50.8	76.7
＋RFB	76.4	84.9	87.0	51.0	89.2
＋CARAFE	80.9	81.4	86.2	49.2	103.3
＋GSConv	83.7	81.9	87.1	49.7	63.1
＋SOCA	83.3	77.0	87.0	50.4	94.4
Ours	85.4	83.6	89.4	52.5	60.8

其中，＋C3_RepLK 代表在主干网络中的 C3 模块中融入重参数化大核卷积；＋RFB 代表 RFB 模块；＋CARAFE 代表轻量化上采样算子；＋GSConv 代表混合密集稀疏卷积；＋SOCA 表示加入 SOCA 注意力机制。表中 $mAP_{0.5}$ 具体表示将交并比设为 0.5 时检测所有类别图像的平均精度，$mAP_{0.5:0.95}$ 表示在不同交并比阈值（0.5：0.95，步长 0.05）的平均精度，FPS（Frames Per Second）为每秒传输帧数。

实验提出改进方法的消融实验结果如表 2 所示，提出的新模块 C3_RepLK，P，R，$mAP_{0.5}$，$mAP_{0.5:0.95}$ 分别提升 2.2%，7.6%，1.2%，1.4%；使用 RFB 模块，P 下降了 2.8%，R，$mAP_{0.5}$，$mAP_{0.5:0.95}$ 分别提升 8%，2%，2.1%；采用 GSConv，P，R，$mAP_{0.5}$，$mAP_{0.5:0.95}$ 分别提升 4.5%，5%，2.1%，0.3%；利用 CARAFE 算子，P，R，$mAP_{0.5}$ 分别提升 1.7%，4.5%，1.2%，$mAP_{0.5:0.95}$ 下降了 0.2%；使用 SOCA 注意力机制，整体的 P，R，$mAP_{0.5}$，$mAP_{0.5:0.95}$ 分别提升了 4.1%，0.1%，2%，1%。

另外，加入 GSConv 后，算法的 mAP 有所提升，同时计算量也相对降低，如表 3 所示。

表 3　算法计算量对比

model	$mAP_{0.5}$/%	GFLOPs
YOLOv5s	85	15.8
＋GSConv	87.1	15.2

本文方法 P，R，$mAP_{0.5}$，$mAP_{0.5:0.95}$ 较原模型分别提高了 6.2%，6.7%，4.4%，3.1%，且 FPS 为 60.8 frame/s，满足实时检测帧率范围。虽然本文

方法的 R 不是最高，但是综合其他指标来看，整体性能相较于原模型都有较大提升，检测精度更高、更准确。

为直观感受算法改进前后变化，通过原始算法和改进后算法的良性黑色素瘤精度和恶性黑色素瘤精度，以及总平均精度进行对比可视化，如图 11 所示。由图可知良性和恶性黑色素瘤的平均精度 AP 相比原算法分别提升了 4%，5%，总类别平均精度 mAP 提升了 4.4%。

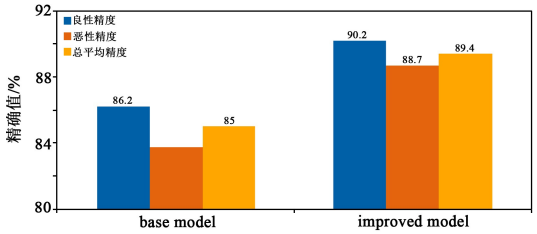

图 11 改进前后各类别精度对比

为体现改进算法的优势，使用相同的数据集以及参数，同主流算法 SSD，Faster-RCNN，YOLOv3-tiny，YOLOv3-spp，YOLOv3，YOLOv8 等进行训练验证，结果如表 4 所示。

表 4 对比实验

model	$mAP_{0.5}$/%	$mAP_{0.5:0.95}$/%
SSD	41.0	29.4
Faster-RCNN	43.0	28.0
YOLOv3-tiny	72.1	31.0
YOLOv3-spp	73.9	37.0
YOLOv3	84.5	49.5
YOLOv8	84.2	50.3
YOLOv5s	85.0	49.4
Ours	89.4	52.5

结合实验数据表明，所提出的算法在 $mAP_{0.5}$ 和 $mAP_{0.5\sim0.95}$ 指标上较其他算法最优。

2.5 检测结果可视化

为了评估验证算法的有效性，在改进前后算法上进行验证可视化。图 12(a)，(b)，(c)表示黑色素瘤在验证集上的检测效果，分别存在精度较低、误检、漏检等问题。

左图表示原 YOLOv5s 直接对数据集进行验证的结果，右图表示改进之后算法的检测效果，为了更直观对改进前后算法对比区分，其中原模型中标签 0 表示良性，1 表示恶性。改进后的模型标签 benign 表示良性，malignant 表示恶性。

从图 12(a)可以看出，左图精度为 0.79，右图为 0.83，表明改进后的算法准确率有一定提升。图 12(b)中左图原恶性黑色素瘤部分(大红色目标检测框部分)，被误检为良性黑色素瘤，右图能正确检测出所有的恶性黑色素瘤，说明改进后的算法能解决错检问题。图 12(c)中左图没有检测出黑色素瘤，右图能检测出恶性黑色素瘤，说明和皮肤高度相似、难以检测的黑色素瘤部分也能被检测出来。

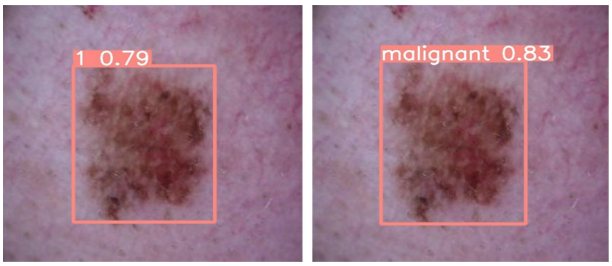

(a) 准确率验证结果

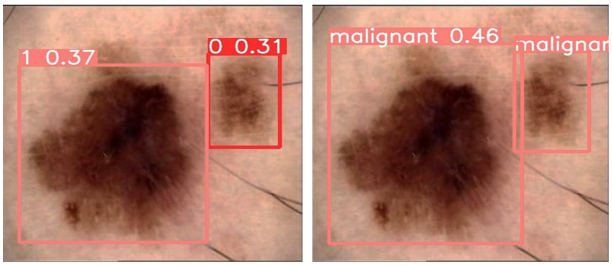

(b) 误检验证结果

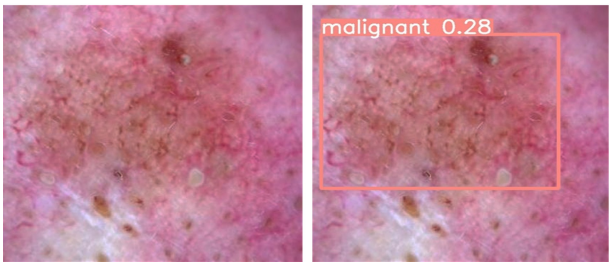

(c) 漏检验证结果

图 12 改进前后各验证结果对比

3 结论

本文提出一种重参数化大核卷积的光学黑色素瘤图像检测算法，在标注好的 ISIC 数据集上进行对比实验，验证了改进后算法的优越性。准确率、召回率、平均精度分别较原算法提高了 6.2%，6.7% 和 4.4%，总体参数量和计算量也在一定程度上有所下降。能够快速有效地检测出病变区域和分辨良性和恶性肿瘤，提高早期诊断准确率，减少漏诊和误诊。对轻量化网络 YOLOv5s 进行改进，便于在真实场景下移动设备部署，将算法实时地应用到资源不足的边缘设备中去，帮助医疗工作者快速诊断[21]。

由于本文中使用的标注数据集较少，使用的数

据增强方式也比较单一，接下来可以在数据增强方法上继续探索，扩充数据集从而使得数据集更具多样性，进一步提高模型的泛化能力。

参考文献：

[1] 秦岚群，邹征云. 恶性黑色素瘤化疗研究进展[J]. 实用肿瘤学杂志，2019，33(2)：167-172.
Qin Lanqun，Zou Zhengyun. Advances in chemotherapy for malignant melanoma[J]. J. of Practical Oncology，2019，33(2)：167-172.

[2] 王永芳，谭　谦. 皮肤恶性黑色素瘤诊断和外科治疗的研究进展[J]. 东南大学学报(医学版)，2021，40(5)：721-725.
Wang Yongfang，Tan Qian. Advances in the diagnosis and surgical treatment of cutaneous malignant melanoma[J]. J. of Southeast University (Medical Science Edition)，2021，40(5)：721-725.

[3] Mohiyuddin A，Basharat A，Ghani U，et al. Breast tumor detection and classification in mammogram images using modified YOLOv5 network [J]. Computational and Mathematical Methods in Medicine，2022，2022：1359019.

[4] Krader C G. AI has potential to improve melanoma detection [J]. Dermatol. Times，2020，41(9)：1-36.

[5] Xu J，Ren H，Cai S，et al. An improved faster R-CNN algorithm for assisted detection of lung nodules[J]. Computers in Biology and Medicine，2023，153：106470.

[6] Ren S Q，He K M，Girshick R，et al. Faster RCNN：towards real-time object detection with region proposal networks[J]. IEEE Trans. on Pattern Analysis and Machine Intelligence，2017，39(6)：1137-1149.

[7] Liu W，Anguelov D，Erhan D，et al. SSD：single shot multi-box detector[C]// European Conf. on Computer Vision，2015：21-37.

[8] Redmon J，Divvala S，Girshick R，et al. You only look once：unified，real-time object detection[C]// Proc. of the 2016 IEEE Conf. on Computer Vision and Pattern Recognition，2016：779-788.

[9] Bisla D，Choromanska A，Berman R S，et al. Towards automated melanoma detection with deep learning：Data purification and augmentation[C]// Proc. of the IEEE/CVF Conf. on Computer Vision and Pattern Recognition Workshops，2019：2720-2728.

[10] Ali A R，Li J，O'Shea S J. Towards the automatic detection of skin lesion shape asymmetry，color variegation and diameter in dermoscopic images[J]. PloS One，2020，15(6)：e0234352.

[11] Gaonkar R，Singh K，Prashanth G R，et al. Lesion analysis towards melanoma detection using soft computing techniques [J]. Clinical Epidemiology and Global Health，2020，8(2)：501-508.

[12] Zunair H，Hamza A B. Melanoma detection using adversarial training and deep transfer learning[J]. Physics in Medicine & Biology，2020，65(13)：135005.

[13] Zhang L，Xu F，Li Y，et al. A lightweight convolutional neural network model with receptive field block for C-shaped root canal detection in mandibular second molars [J]. Scientific Reports，2022，12(1)：17373.

[14] Li H L，Li J，Wei H B，et al. Slim-neck by GSConv：A better design paradigm of detector architectures for autonomous vehicles[J/OL]. ArXiv，2022，2206：02424 [2023-6-28]. https://arxiv. org/vc/arxiv/papers/2206/2206.02424v1. pdf.

[15] Wang J，Chen K，Xu R，et al. Carafe：Content-aware reassembly of features[C]// Proc. of the IEEE/CVF Inter. Conf. on Computer Vision，2019：3007-3016.

[16] Dai T，Cai J，Zhang Y，et al. Second-order attention network for single image super-resolution[C]// Proc. of the IEEE/CVF Conf. on Computer Vision and Pattern Recognition，2019：11065-11074.

[17] Ding X，Zhang X，Han J，et al. Scaling up your kernels to 31×31：Revisiting large kernel design in cnns[C]// Proc. of the IEEE/CVF Conf. on Computer Vision and Pattern Recognition，2022：11963-11975.

[18] Szegedy C，Ioffe S，Vanhoucke V，et al. Inception-v4，inception-resnet and the impact of residual connections on learning[C]// Proc. of the Thirty-First AAAI Conf. on Artificial Intelligence，2017：4278-4284.

[19] Hu J，Shen L，Sun G. Squeeze-and-excitation networks [C]// Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition，2018：7132-7141.

[20] Codella N C，Gutman D，Dusza S，et al. Skin lesion analysis toward melanoma detection[C]// 2018 IEEE 15th Inter. Symp. on Biomedical Imaging，2018：264-269.

[21] Lecchi T，de Almeida G M，Vivacqua R P D. Algoritmo de deep learning baseado na rede neural YOLOv5 para classificação dermastoscópicae detecção de cancer (melanoma) [J]. Concilium，2022，22(7)：813-827.

作者简介：

苏　炅(1998—)，女，湖南省湘潭市人，硕士研究生，研究方向为图像处理、智能信息处理；

刘　强(1980—)，男，湖北省随州市人，讲师，研究方向包括网络技术应用、人工智能和机器视觉。