第 59 卷 第 24 期/2022 年 12 月/激光与光电子学进展 研究论文

激光与光电子学进展 先进成像

轻量化改进网络的实时光纤端面缺陷检测模型

宋敏毓[1]，陈力荣[1*]，梁建安[1]，李晋鹏[1]，牛振振[1]，王震[1]，白丽丽[2]

[1]山西大学物理电子工程学院，山西 太原 030006；

[2]太原理工大学航空航天学院，山西 太原 030006

摘要 光纤是现代通信系统及量子保密通信网中不可或缺的传输介质。针对光纤端面缺陷对光传输系统造成传输质量下降甚至永久性损伤的问题，提出了一种改进YOLOv5算法的光纤端面检测模型YOLOv5_CS。该模型首先将轻量化网络ShuffleNetV2作为主干特征提取网络，利用深度卷积操作以及通道随机混合策略，缩减模型容量，丰富特征信息；随后引入卷积注意力机制(CBAM)，同时在空间维度和通道维度上进行特征增强，提升网络性能；最后缩减特征融合层的卷积核数量，实现进一步的模型压缩，并利用数据增广技术构建的光纤端面数据集，对所提方法的有效性进行对比验证。结果表明，与YOLOv5算法相比，所提模型的模型容量压缩了80%，检测速度提升了31.1 frame/s，均值平均精度(mAP)提高了1.7%，能够较为准确以及实时地检测光纤端面缺陷。此项工作面向便携式智能检测装置的研制，可为光纤端面缺陷检测及相关视觉传感产业提供技术支持。

关键词 机器视觉；光纤端面缺陷检测；目标检测；深度学习；轻量化网络

中图分类号 TP391 **文献标志码** A **DOI**：10.3788/LOP202259.2415006

Real-Time Optical Fiber End Surface Defects Detection Model Based on Lightweight Improved Network

Song Minyu[1], Chen Lirong[1*], Liang Jian'an[1], Li Jinpeng[1], Niu Zhenzhen[1], Wang Zhen[1], Bai Lili[2]

[1]*College of Physics and Electronic Engineering, Shanxi University, Taiyuan* 030006, *Shanxi, China*;

[2]*College of Aeronautics and Astronautics, Taiyuan University of Technology, Taiyuan* 030006, *Shanxi, China*

Abstract Optical fiber is an indispensable transmission medium in modern communication system and quantum secure communication network. In order to solve the problem that the optical fiber end surface defects cause transmission quality decline or even permanent damage to optical transmission system, a fiber end surface detection model YOLOv5_CS based on YOLOv5 algorithm is proposed. Firstly, ShuffleNetV2, a lightweight network, is used as the main feature extraction network. Deep convolution operation and channel random mixing strategy are used to reduce model capacity and enrich feature information. Secondly, the convolutional block attention module (CBAM) is introduced, and features are enhanced in both spatial and channel dimensions to improve network performance. Finally, the number of convolution kernels in the feature fusion layer is reduced to achieve further model compression. The validity of the proposed method is compared and verified by the optical fiber end data set constructed by data augmentation technology. The results show that compared with the YOLOv5 algorithm, the model capacity of the proposed model is reduced by 80%, the detection speed is increased by 31.1 frame/s, and the mean average precision (mAP) is increased by 1.7%, which can accurately and real-time detect optical fiber end surface defects. This work is aimed at the development of portable intelligent detection device, and can also provide technical support for optical fiber end surface defects detection and related visual sensing industry.

Key words machine vision; fiber end surface defects detection; target detection; deep learning; lightweight network

收稿日期：2021-09-30；**修回日期**：2021-10-25；**录用日期**：2021-11-01

基金项目：国家自然科学基金(61805133，62035015)、中央引导地方科技发展专项资金项目(YDZX20201400001547)、山西省自然科学青年基金(1901D211172)

通信作者：*clr@sxu.edu.cn；

1 引 言

光纤作为一种较理想的传输介质，在激光、通信、医疗等领域得到广泛应用，并推动了现代通信产业、物联网产业的快速发展。然而，光纤端面的微小缺陷或小灰尘，与激光相互作用，将导致光纤严重缺陷的产生[1]，从而导致传输系统连接损耗变大、通信性能下降；甚至会对光纤本身以及光学系统造成影响以及永久性损伤，严重缺陷光纤还会损坏光学系统中的其他光学元件，发生安全事故[2]。因此，光纤端面缺陷及时准确的检测，不仅能够避免问题光纤使用时的潜在风险，还可以借助智能缺陷检测系统，对光纤端面进行针对性修复，避免造成不可恢复或更严重的经济损失。

传统的光纤端面检测方法有人工检测方法和光干涉法。人工检测方法需要调整显微镜焦距从而将光纤端面清晰的图像采集出来，然后再确定每一区域缺陷[3]。此方法检测结果主观性很强，误差较大，且难以检测到较浅的缺陷，易出现漏检情况[4]。光干涉法能够测量出光纤端面表面形貌且此方法精度可观，但其需要搭建光路并调试出复杂的干涉条纹才能进行相关检测。此项技术步骤繁琐且不能较为精确地识别缺陷[5]，同时其造价昂贵不适用于便携式装置。

随着机器学习的发展，人眼难以直接量化的特征可以通过机器学习便捷量化。基于机器学习的光纤端面检测方法大体有以下几种：Mei 等[6]提出使用最小-最大排序过滤的差异（D02MR）模型检测光纤端面的凹坑缺陷，使用线性增强检查器（LEI）模型检测光纤端面的划痕缺陷；赵伟杰等[7]提出使用基于自动检测的视觉生成器（VBAI）的视觉自动检测开发环境并结合图像处理技术来检测光纤端面；朱莉等[8]提出同心椭圆约束方法检测光纤纤芯轮廓用来划分光纤检测区域，并采用自适应阈值分割算法检测缺陷；刘为等[9]提出基于灰度图像阈值分割以及椭圆边界点选取与拟合的方法，并通过存在缺陷的光纤端面来求取其几何参数；周程等[10]提出使用 Java 平台结合 OpenCV 开源算法库，通过改进相关图像处理算法检测光纤端面缺陷。以上方法均对光纤端面的缺陷检测达到了一定效果，然而上述方法只能检测单一的缺陷，且检测方法较为复杂，适应性较差以及自动化程度低，检测速度较慢，实时性较差。

本文基于 YOLOv5 算法设计了光纤端面缺陷检测模型 YOLOv5_CS，此模型采用 ShuffleNetV2 网络，满足了模型的轻量化设计；通过引入卷积注意力机制，增强模型特征提取能力，提高了模型检测精度；并缩减特征融合层的卷积核数量，提高了模型检测速度。该模型容量小、检测速度快，能够同时识别多种缺陷，易于部署于工业环境，并为光纤端面缺陷检测的自动化提供了技术支持。

2 算法原理

2.1 方法介绍

光纤端面缺陷主要分为 3 种类别，分别为凹坑、划痕、麻点。如图 1 所示，虚线矩形框内为划痕缺陷，圆形框内为麻点缺陷，实线矩形框内为凹坑缺陷。由于光纤端面上可能存在多种缺陷，因此光纤端面缺陷检测要求能同时检测到端面的不同缺陷，并标记其类型及其所在位置，检测模型需兼顾自动化与精度、准确性与实时性。由于现有模型只能检测单一缺陷，适应性、实时性以及准确性较差，且对于较小以及较浅缺陷的检测能力较差。因此需要进一步提高网络的特征提取能力，提高模型检测精度。同时，由于实际应用中设备性能的限制，需要降低模型复杂度，以便于模型嵌入到广泛适用性平台上。为此，本文基于 YOLOv5 网络设计了一种新的卷积神经网络模型 YOLOv5_CS，采用 ShufflenetV2 网络作为新的特征提取网络，并引入卷积注意力机制以及缩减卷积核数量来提升检测精度与检测速度，达到同时标记光纤端面缺陷类型与位置的检测要求。

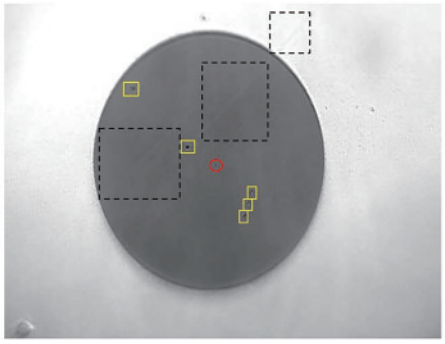

图 1 光纤端面缺陷图

Fig. 1 Diagram of fiber end surface defects

2.2 目标检测算法介绍

深度学习中的目标检测算法，具有自动提取特征、可并行化和检测精度高等优点，广泛应用于高精度测量领域。目标检测算法主要分为两步，首先找出图像中所有感兴趣的目标（物体），其次确定目标的类别与位置。

目标检测算法主要分为两类：单阶段算法（One stage）和双阶段算法（Two stage）。Two stage 算法需通过区域生成以及卷积神经网络（CNN）进行样本分类。Two stage 算法主要有基于区域的 CNN（R-CNN）[11-13]系列算法。One stage 算法则直接通过网络提取特征来预测物体的分类与位置。One stage 算法主要有你只看一次（YOLO）算法[14-17]，单激发多盒探测器（SSD）算法[18-20]。Two stage 算法检测性能更好但实时性较差，One stage 算法实时性较好但检测性能相比 Two stage 算法较差。结合实际需求，本文采用 One stage 算法中的 YOLO 算法来实现检测。

YOLO 算法是一种实时目标检测算法，速度快且

结构简单，该算法已更新到v5版本YOLOv5。本文选择YOLOv5算法中的4.0版本作为光纤端面缺陷分类的模型，并在自制光纤端面数据集上训练网络，通过训练完成的YOLOv5网络来实现光纤端面缺陷的自动分类与检测。

2.3 YOLOv5网络模型介绍

YOLOv5算法的速度最快可达到140 frame/s，其权重只有上一代YOLO算法即YOLOv4算法的1/9，检测准确度相比YOLOv4更高。YOLOv5算法有4个网络，其中YOLOv5s是这4个网络中深度最小，也是训练速度最快的一个网络。因此本文基于YOLOv5系列中的YOLOv5s网络开展光纤端面检测。YOLOv5s算法网络结构如图2所示。各个部分的结构如图3所示。

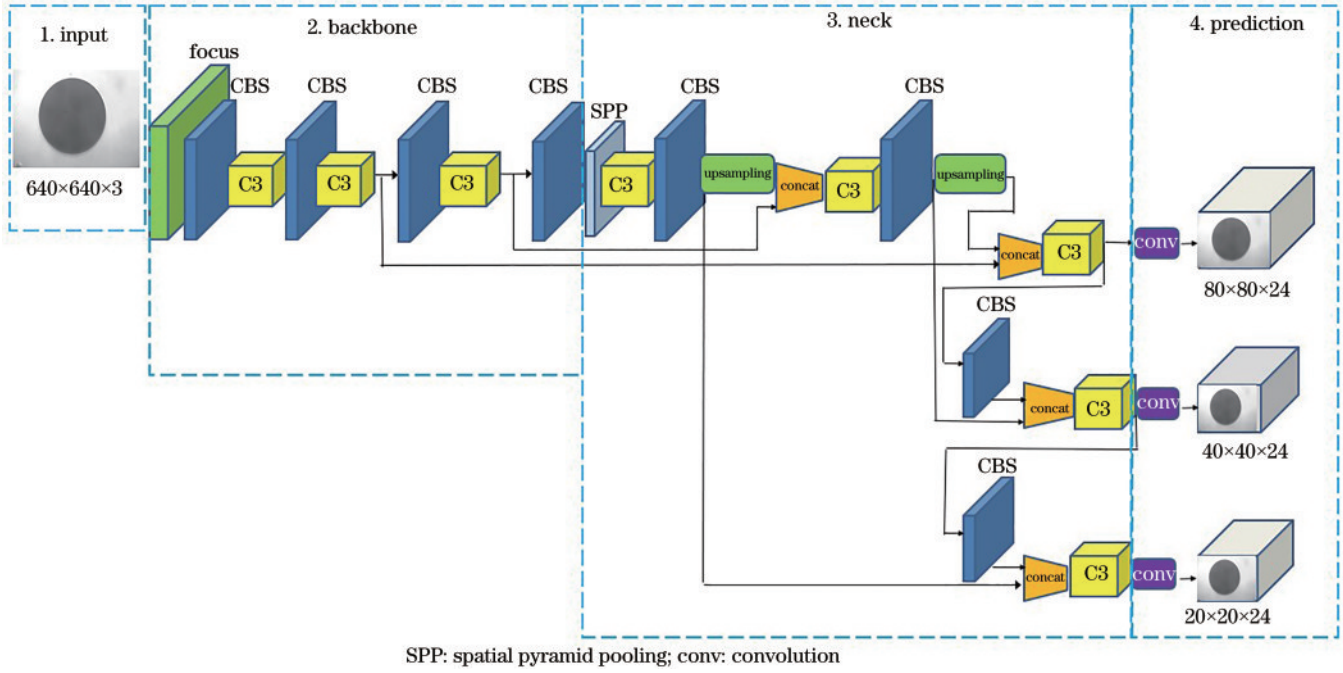

图2 YOLOv5s总体结构图

Fig. 2 General structure of YOLOv5s

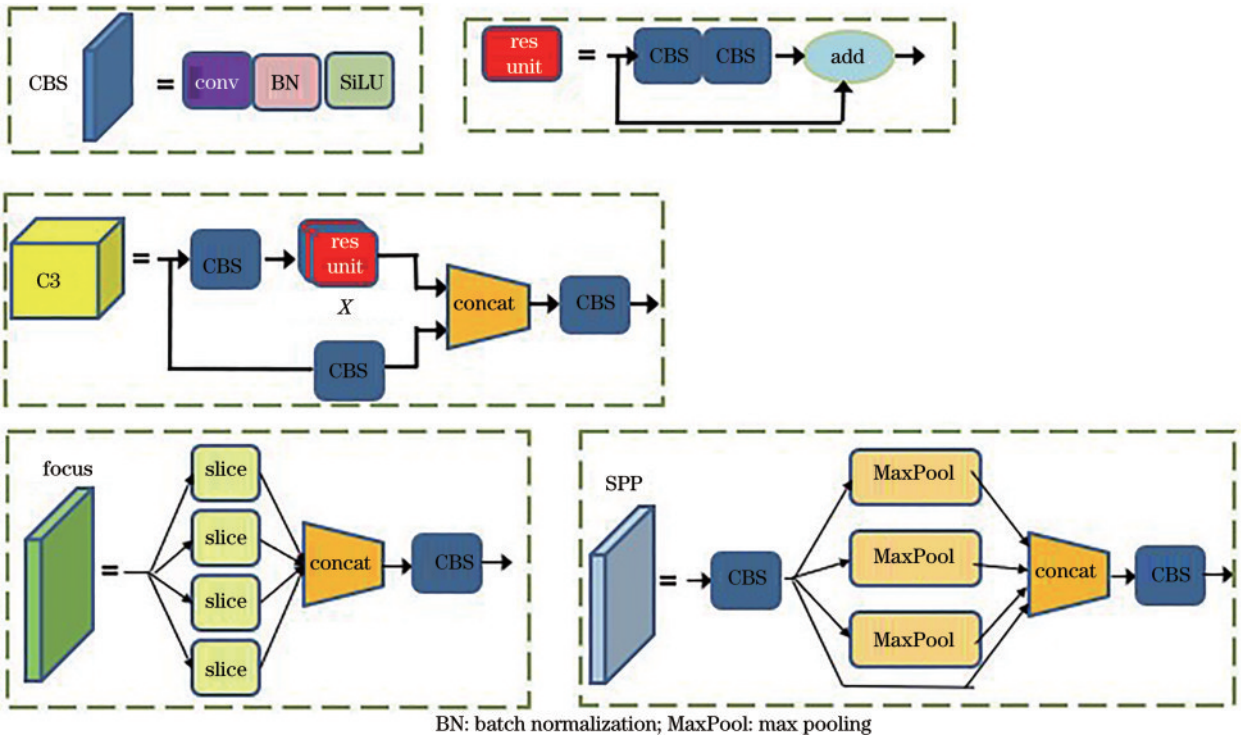

图3 YOLOv5s子结构图

Fig. 3 Diagram of YOLOv5s substructure

由YOLOv5算法网络结构图可知，YOLOv5的网络结构分为input、主干网络（backbone）、特征融合层（neck）、prediction 4个部分。input将输入图像的大小统一成640 pixel×640 pixel×3 pixel，并采用Mosaic数据增强提高小目标检测精度；backbone由focus结构、CBS结构以及C3结构组成；neck部分，采用特征金字塔网络（FPN）+路径聚合网络（PAN）结构。与YOLOv4算法不同的是，在YOLOv4算法的neck结构中，采用的是普通卷积（conv）操作，而在YOLOv5算法的neck结构中，则采用借鉴了C3结构，由图3所示，C3结构包含3个标准卷积层和X个残差组件（res unit）模块。并且分为两条支路：上支路通过一个标准卷积层降低通道数量，再经过多个res unit模块；下支路只通过一个标准卷积层降低通道数量。C3结构先将基础层的特征映射划分为两部分，然后通过跨阶段层次结构将两部分合并，与标准卷积操作相比，能够加强CNN的学习能力，在减少计算量的同时可以保证准确率，并加强了网络特征融合的能力。在网络输出端YOLOv5则采用了GIOU_Loss损失函数。

YOLOv5s将经过input端的图片划分为$S\times S$个网络，然后通过卷积、归一化、激活等操作，将特征提取到80 pixel×80 pixel、40 pixel×40 pixel、20 pixel×20 pixel 3个不同尺寸的特征图来预测3种不同的目标。检测层共有$3\times(1+4+B)$个通道，负责预测3种不同的目标。其中3为锚框个数，1为锚框置信度，4为坐标偏移量(t_x, t_y, t_h, t_w)，B为目标类别数量。

$$C=P(O)\times I, \tag{1}$$

式中：C为锚框置信度；$P(O)$为目标落在该网格中的概率，如落在网格，则取1，否则取0；I为真实框与预测框的交并比（IOU），即两个框的交集面积与并集面积的比值。

锚框的类别置信度计算公式为

$$S=P(C_i|O)\times C, \tag{2}$$

式中：$P(C_i|O)$表示若目标落在某个网格内，则该网格需判定此目标属于第i类的概率；S表示此概率与置信度相乘得到的锚框类别置信度。S能够预测锚框的类别，也能够预测锚框的准确度。

通过计算每个锚框与该类别置信度最高锚框的IOU，若大于设定阈值则舍弃该锚框，然后在其余框中选取一个最大的框，再删除大于阈值的框，如此反复计算即得到该目标的最终锚框，此过程被称为非极大值抑制（NMS）。

最后通过梯度下降反复计算锚框与真实框的损失函数，得到损失函数为最小值情况下每个锚框的类别得分和坐标偏移量，预测框需用锚框的坐标偏移量去微调先验框得到，使得预测框不断接近真实框。损失计算有3种形式，分别为边界框损失、置信度损失和类别损失。置信度损失和类别损失采用的是二进制交叉熵损失函数（BCELoss），边界框损失则采用的是GIOU_Loss函数。

$$L_{\mathrm{B}}=\begin{cases}-\log P' & y=1\\ -\log(1-P)' & y=0\end{cases}, \tag{3}$$

式中：L_{B}为BCELoss函数；P'为样本预测值。其中y等于1时表示为该类别，y等于0时则表示不属于该类别。

$$L_{\mathrm{G}}=1-\left(I-\frac{|D-B\cup B^{\mathrm{g}}|}{|D|}\right), \tag{4}$$

式中：L_{G}为GIOU_Loss损失函数；D为真实框与预测框所包围的最小矩形面积；B为预测框；B^{g}为真实框。

2.4 轻量型网络ShuffleNetV2

CNN在目标检测、图像分类与分割等领域获得广泛应用。但随着对CNN的性能要求越来越高，其模型深度加深，模型参数量增多以及模型复杂度提高，使得CNN只能在高性能的设备上运行，难以部署到性能较差的设备平台上。SqueezeNet、ShuffleNet、MobileNet等轻量型网络的出现使得这种设想成为可能。轻量型网络通过设计高效的网络计算方式，从而减少网络的参数量，并保持网络性能不变。

本文所使用的轻量化网络为ShuffleNetV2。ShuffleNetV2网络不再使用分组卷积操作，相反使用输入输出通道数目相同的1×1普通卷积，以此提高模型的检测速度。ShuffleNetV2同时采用随机通道分离[21]的新类型操作，该操作将模型的输入通道随机分为两部分：一部分保留自身映射并直接向下传递；另一部分则直接向后计算，此处使用的一部分为原输入通道的一半。向后计算部分由两个输入输出通道相同的卷积层以及输入输出通道数相同的深度卷积共同组成。在模块底部，通过将两分支的输出通道级联，避免了元素级相加的操作。然后对输出的特征图进行随机混合，相互传递各通道之间的信息，该操作能够有效提升模型的泛化性。模型结构如图4所示。

针对池化操作存在的缺点，ShuffleNetV2设计了一个下采样模块。该模块取消了随机通道分离操作，将所有的特征分别送入两个支路，再进行处理，然后将其拼接，此操作使得最终输出的通道数目翻倍。此处理的目的是为了在下采样过程中增加整体输出通道数目。具体结构如图5所示。

2.5 卷积注意力机制

注意力机制作为机器学习中的数据处理方法，广泛应用在图像处理、图像及语音识别等不同类型的机器学习任务中。在目标检测算法中，通过引入注意力机制，使得模型关注重要特征，进而提高模型的检测精度。注意力机制主要分为通道注意力机制、空间注意力机制以及混合注意力机制3种。而本文所引用的卷积注意力机制（CBAM）则属于混合注意力机制。

如图6所示，CBAM由通道注意力机制和空间注

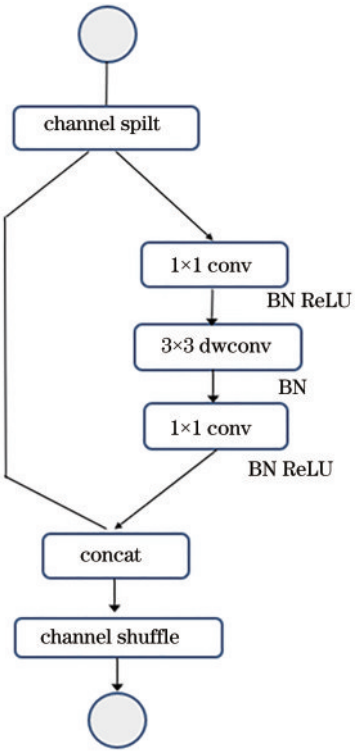

图 4 ShuffleNetV2的基本单元

Fig. 4 Basic unit of shuffleNetV2

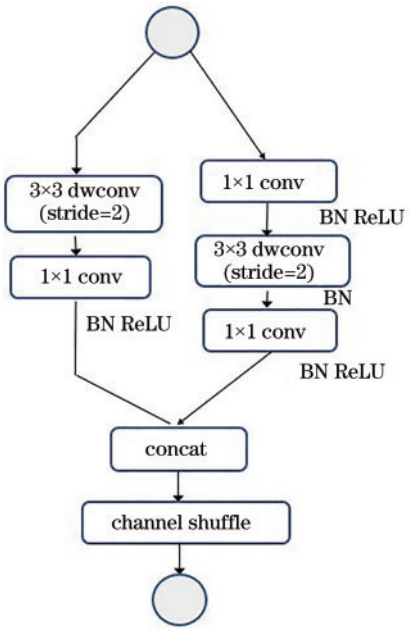

图 5 空间下采样的ShuffleNetV2单元

Fig. 5 ShuffleNetV2 unit down sampled in space

意力机制组成，并先后集成了这两种机制。其中通道注意力模块将注意力集中在通道上，判断哪些通道具有目标主要特征；空间注意力模块将注意力集中在空间位置上，判断哪些位置上包含目标主要信息[22]。CBAM的处理过程如下所示：

$$F' = M_c(F) * F, \tag{5}$$

$$F'' = M_s(F') * F', \tag{6}$$

式中，$*$表示对应元素逐个相乘。输入特征图F先送入通道注意力机制生成通道注意力权重的特征图M_c，并与原始特征图对应元素相乘得到新的特征图F'。新的特征图送入空间注意力机制生成空间注意力权重的特征图M_s，并与自身相乘得到最终输出特征图F''。

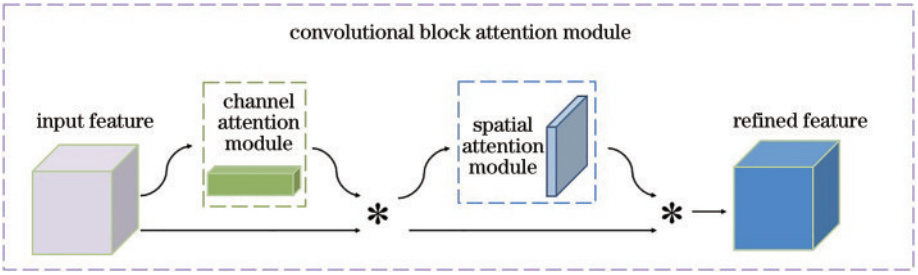

图 6 CBAM结构图

Fig. 6 Structure diagram of convolutional block attention module (CBAM)

通道注意力模块如图 7 所示，其输入特征图为 $F \in R^{C \times H \times W}$，为了更好地计算每个特征通道的重要程

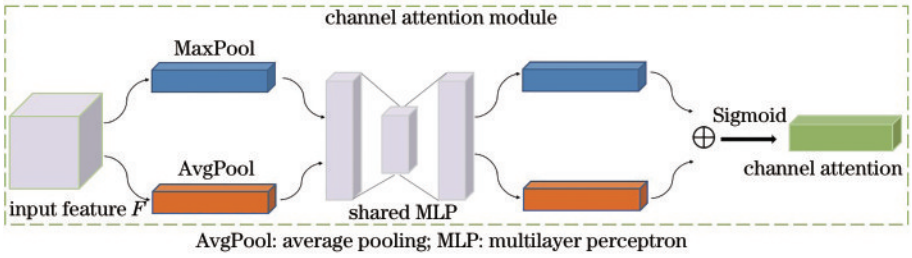

图 7 通道注意力模块结构图

Fig. 7 Structure diagram of channel attention module

度，需要将输入的特征图送入平均池化层（average pooling）和最大池化层（max pooling）进行压缩得到 $F^{C}_{avg}\in R^{C\times1\times1}$ 和 $F^{c}_{max}\in R^{C\times1\times1}$，再分别将得到的通道特征输入多层感知机（MLP）进行卷积运算，再将卷积运算后的输出逐元素相加，以及使用Sigmoid激活函数，从而得到通道注意力权重的特征图 $M_c(F)\in R^{C\times1\times1}$，该特征图的计算公式为

$$M_c(F)=\sigma\{\mathrm{MLP}[\mathrm{AvgPool}(F)]+\mathrm{MLP}[\mathrm{MaxPool}(F)]\}=\sigma\{W_1[W_0(F^{c}_{avg})]+W_1(W_0(F^{c}_{max}))\},\tag{7}$$

式中：σ 为Sigmoid激活函数；W_0 和 W_1 为MLP的权重。

空间注意力模块如图8所示，输入为经过 M_c 加权后的新特征图 F'，通过平均池化层和最大池化层后得到 $F^{8}_{avg}\in R^{1\times H\times W}$ 和 $F^{8}_{max}\in R^{1\times H\times W}$，再将两个空间特征拼接在一起，形成通道数为2的新的空间特征图；然后通过卷积层进行卷积（conv），以及使用Sigmoid激活函数，从而得到空间注意力权重的特征图 $M_s(F)\in R^{H\times W}$。该特征图的计算公式为

$$M_s(F)=\sigma\{f^{7\times7}\{[\mathrm{AvgPool}(F);\ \mathrm{MaxPool}(F)]\}\}=\sigma[f^{7\times7}(F^{s}_{avg};\ F^{s}_{max})],\tag{8}$$

式中，σ 为Sigmoid激活函数，$f^{7\times7}$ 表示7×7卷积核的卷积层。

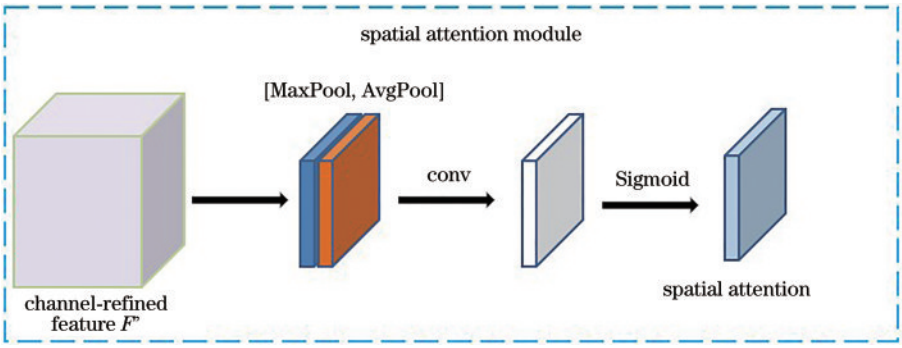

图8 空间注意力模块结构图

Fig. 8 Structure diagram of spatial attention module

2.6 改进后的网络结构YOLOv5_CS

为了提高网络的性能，对YOLOv5s网络作相应改进，改进后的网络结构如图9所示，并将改进后的网络结构命名为YOLOv5_CS，CS为CBAM与ShuffleNetV2结构首字母的缩写。YOLOv5_CS将YOLOv5s网络中的主干网络backbone由darknet53结构改为ShuffleNetV2结构，其中SN_1为ShuffleNetV2的基本单元，SN_2为空间下采样的ShuffleNetV2单

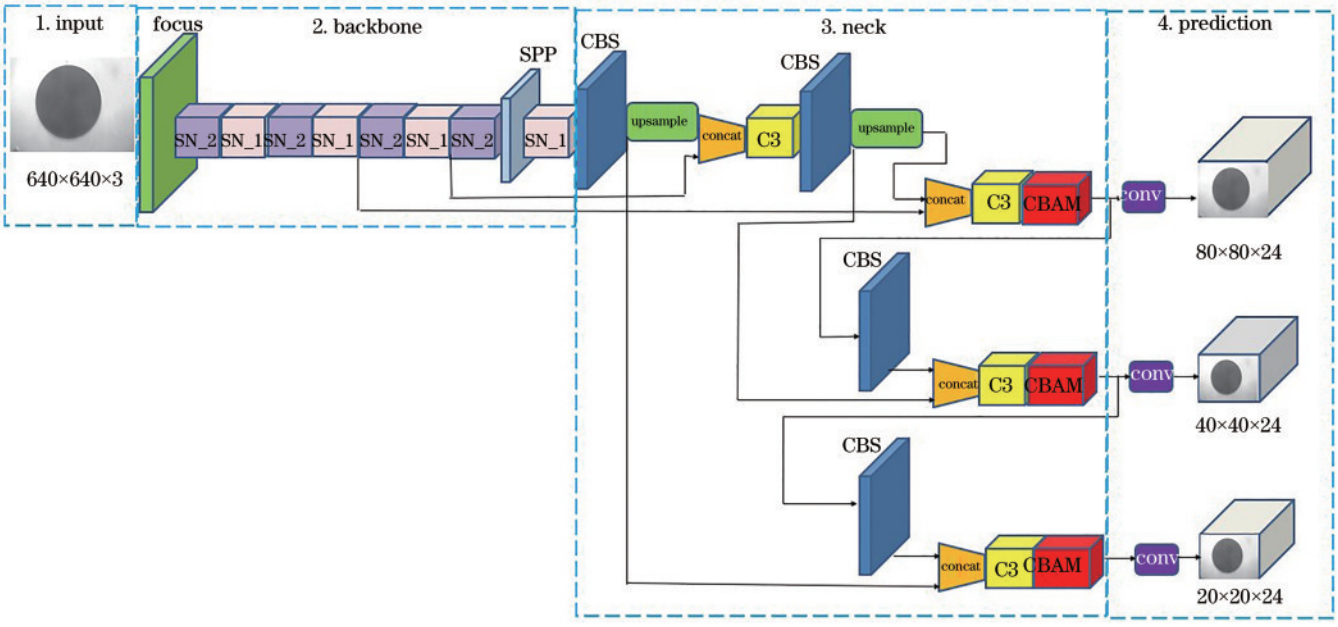

图9 YOLOv5_CS网络结构图

Fig. 9 Structure diagram of YOLOv5_CS

元，卷积核大小为1×1；其次在neck部分添加CBAM，用于提升模型检测精度；最后缩减特征融合层即neck部分的卷积核数量，进一步压缩模型容量。输入图像经缩放后大小统一为640 pixel×640 pixel，并经过主干网络的5次下采样，提取大小分别为80 pixel×80 pixel、40 pixel×40 pixel、20 pixel×20 pixel这3个尺度特征；其次在neck部分对获取的尺度特征进行FPN+PAN的特征融合[23]提取，提取后的特征图最终经过prediction部分的3次卷积得到3种尺度的预测结果，分别为80 pixel×80 pixel×24 pixel、40 pixel×40 pixel×24 pixel，20 pixel×20 pixel×24 pixel。

3 实验方案与结果

3.1 数据集介绍

本文设计了一套图像数据采集技术流程，解决了深度学习数据量要求大、工业数据收集成本高等问题。首先通过光纤端面检测仪采集500张光纤端面图片，为防止网络训练过拟合，采用上下旋转、左右翻转、裁剪等数据增广的方式将样本个数增加至5168张；其次按照8∶1∶1的比例将数据集划分为训练集、验证集、测试集，每张图像的分辨率为646 pixel×491 pixel；最后使用LabelImg软件对图片中的光纤端面缺陷进行标注，标注后的文件以txt作为后缀，文件名和图片名称一致。

3.2 实验设备及参数设置

本文通过搭建的Pytorch深度学习框架对自制光纤端面缺陷数据集进行训练和测试。训练过程中用到的硬件设备为Intel(R)Core(TM)i7-6500 CPU@2.50 GHz型号的电脑CPU，NVIDIA Tesla T4型号的GPU。软件环境为Windows10操作系统，Python3.6编程语言，Pytorch 1.7.1深度学习框架。

训练阶段的超参数设置：初始学习率为0.001，衰减系数为0.0005，动量为0.937，批次(batch size)为40，训练次数(epoch)为300次。

3.3 评价指标

在检验模型效果时，本文采用均值平均精度(mAP)，以及检测速度(frame/s，FPS)来作为主要评价指标。这些评价指标也是在目标检测任务中常用的指标。

在目标检测任务中，一般采用均值平均精度mAP来反映模型检测精度。其计算公式为

$$A_{\mathrm{mAP}}=\frac{1}{c}\sum_{i=1}^{c}\int_{0}^{1}PR\mathrm{d}R, \tag{9}$$

式中：c表示检测目标的类别数；P与R分别表示精确度以及召回率，其计算公式分别为

$$P=\frac{S_{\mathrm{TP}}}{S_{\mathrm{TP}}+S_{\mathrm{FP}}}, \tag{10}$$

$$R=\frac{TP}{S_{\mathrm{TP}}+S_{\mathrm{FN}}}, \tag{11}$$

式中：S_{TP}代表检测结果中正确目标的个数；S_{FP}代表检测结果错误目标个数；S_{FN}代表正确目标中漏检的个数。

除了检测准确度，目标检测任务的另一个重要评估指标是FPS，即模型每秒内能够处理的图片数量。

3.4 实验对比

为了验证本文所提模型的有效性，需进行消融实验[24]，因此本文构建了3种模型与所提模型进行对比。构建的3种模型分别命名为YOLOv5s_A、YOLOv5s_B、YOLOv5s_C。其中YOLOv5s_A是在原有YOLOv5s网络基础上增加CBAM；YOLOv5s_B是在原有YOLOv5s网络基础上将主干网络修改为ShuffleNetV2。YOLOv5s_C是在原有YOLOv5s网络基础上将主干网络修改为ShuffleNetV2，并增加CBAM。YOLOv5_CS是本文所提模型，此模型是在YOLOv5s_C模型基础上缩减neck部分的卷积核数量。

由表1、表2可知，YOLOv5s_A模型的mAP值相较于原YOLOv5s网络上升2.08个百分点，验证了CBAM的有效性，CBAM在空间和通道两个维度上都实施注意力机制，通过强调主要特征，抑制次要特征来对特征层进行权重再分配，从而使网络在反向传播时重点更新关键位置的权重，并能给网络性能带来实质性的提升，对于提升模型检测精度有一定作用。但单张推理时间增加了1 ms，且模型容量相较于原YOLOv5s网络提升了15.7%，模型参数量以及浮点运算量相较于原YOLOv5s网络均有所上升。YOLOv5s_B模型的mAP值相较于原YOLOv5s网络下降0.40个百分点，但单张推理时间减少了2.4 ms，且模型容量相较于原YOLOv5s网络下降了44.2%。模型参数量以及浮点运算量相较于原网络均有所下降。验证了将主干网络改为ShuffleNetV2的有效性，ShuffleNetV2作为主干特征提取网络，利用深度

表1 5种模型检测结果对比

Table 1 Comparison of detection results of five models

Method	ShuffleNetV2	CBAM	Delete convolution kernel	mAP /%	Infertime /ms
YOLOv5s				82.10	11.5
YOLOv5s_A		√		84.18	12.5
YOLOv5s_B	√			81.70	9.1
YOLOv5s_C	√	√		83.93	9.9
YOLOv5_CS	√	√	√	83.80	8.5

表2 5种模型复杂度对比

Table 2 Complexity comparison of five models

Method	Model of capacity /M	Number of model parameters /M	Floating point operations /G
YOLOv5s	14.0	7.1	16.3
YOLOv5s_A	16.2	8.3	17.4
YOLOv5s_B	7.8	3.9	8.5
YOLOv5s_C	7.9	4.0	8.6
YOLOv5_CS	2.8	1.3	3.8

卷积操作以及通道随机混合策略，缩减模型容量，丰富特征信息，提升了模型检测速度，以及降低了模型参数量，使得网络轻量化。YOLOv5s_C模型的mAP值相较于原YOLOv5s网络上升1.83个百分点，单张推理时间减少了1.6 ms，且模型容量相较于原YOLOv5s网络下降了43.5%。

本文所提模型YOLOv5_CS的mAP值相较于原YOLOv5s网络上升1.70个百分点，单张推理时间减少了3 ms，且模型容量相较于原YOLOv5s网络下降了80%。与YOLOv5s_C模型相比，其mAP值仅降低了0.13个百分点，但单张推理时间减少了1.4 ms，说明缩减特征融合层的卷积核没有降低模型学习能力，反而减少了模型参数冗余，提高了模型检测速度。

表3为5种模型在不同显卡上检测速度的对比，由表3可以得出，在Tesla T4显卡运行下，YOLOv5_CS的检测速度高于原YOLOv5s网络31.1 frame/s，在Tesla K80显卡运行下，YOLOv5_CS的检测速度高于原YOLOv5s网络14.0 frame/s。且YOLOv5_CS是5种网络中检测速度最快的，符合实时检测要求，在实际应用中，硬件的配置普遍较低，因此对于将模型移植在性能较差的设备上，YOLOv5_CS具有优越性。

表3 不同显卡的检测速度对比

Table 3 Comparison of detection speed of different graphics cards

unit: frame/s

Method	Tesla T4	Tesla K80
YOLOv5s	86.9	32.0
YOLOv5s_A	80.0	25.0
YOLOv5s_B	109.0	40.0
YOLOv5s_C	101.0	36.2
YOLOv5_CS	118.0	46.0

综合表1～3所述，本文所提模型，检测精度，检测速度以及模型容量都优于原YOLOv5s网络，且符合实时检测的需求。相比于文献[6]检测单张图片需620 ms，即1.612 frame/s，YOLOv5_CS的检测速度提升了约92.4%。

3.5 结果对比

图10为YOLOv5s网络与本文模型YOLOv5_CS

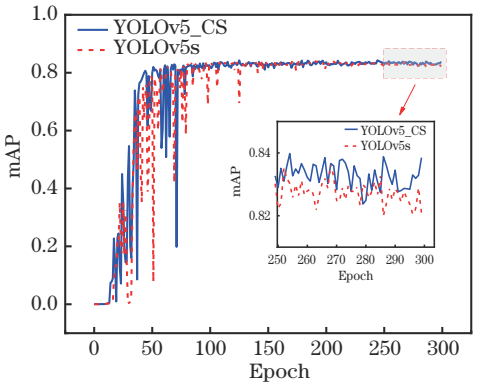

图10 训练期间mAP变化对比图

Fig. 10 Comparison of mAP changes during training

训练期间mAP变化对比图。横坐标为训练次数，纵坐标为mAP值。由图中得知，YOLOv5_CS的mAP值高于YOLOv5s。

在模型训练过程中，可通过绘制损失曲线来直观观察训练的过程，损失越小代表预测结果与实际结果误差越小，模型训练结果越好。图11为本文模型YOLOv5_CS与YOLOv5s模型在训练时的相应平均损失曲线，横坐标为训练次数，纵坐标为训练期间的损失值。从图中可以看出从训练到结束，YOLOv5_CS的平均损失始终低于YOLOv5s的平均损失。即YOLOv5_CS模型训练结果优于YOLOv5s。

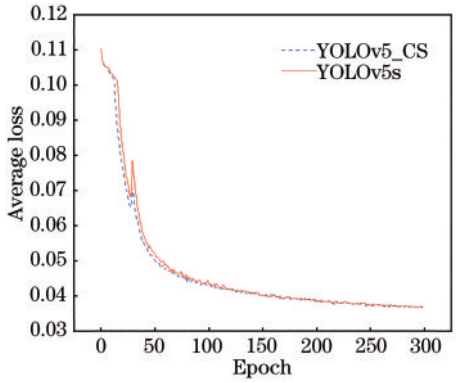

图11 训练损失函数对比图

Fig. 11 Contrast diagram of training loss function

表4为YOLOv5_CS模型与YOLOv5s网络对于具体缺陷检测结果的对比。由表4可知，YOLOv5_CS

表4 3类缺陷mAP对比

Table 4 Comparison of average precision of three types of defects

unit: %

Method	Dig	Pit	Scratch
YOLOv5s	75.1	79.5	91.6
YOLOv5_CS	77.7	81.4	92.5

模型对于3类缺陷的检测精度均有所提升，其中麻点缺陷、凹坑缺陷和划痕缺陷的mAP值分别提升了2.6个百分点、1.9个百分点和0.9个百分点。

图12为YOLOv5_CS模型总体以及3类缺陷*P-R*(Precision-Recall)曲线对比图。横坐标为召回率(Recall)，纵坐标为精确率(Precision)，*P-R*曲线围成的面积即为平均精度，从图中横纵坐标所围成的面积大小可知，划痕识别的mAP最高，凹坑次之，麻点最低。

3.6 检测结果

YOLOv5s网络与本文模型分别对测试集部分光纤端面图片的检测结果，如图13所示。图13(a)、13(c)为YOLOv5s的检测结果，图13(b)、13(d)为本文模型的检测结果。对比图13(a)、13(b)可以发现，对于部分缺陷，YOLOv5s存在漏检情况，而本文模型可以检测到YOLOv5s的漏检目标。对比图13(c)、13(d)可以发现，YOLOv5s存在检测框错判情况，而本文模型无错判情况。

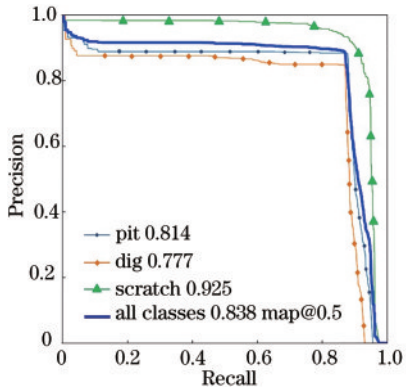

图12 *P-R*曲线图

Fig. 12 *P-R* graph

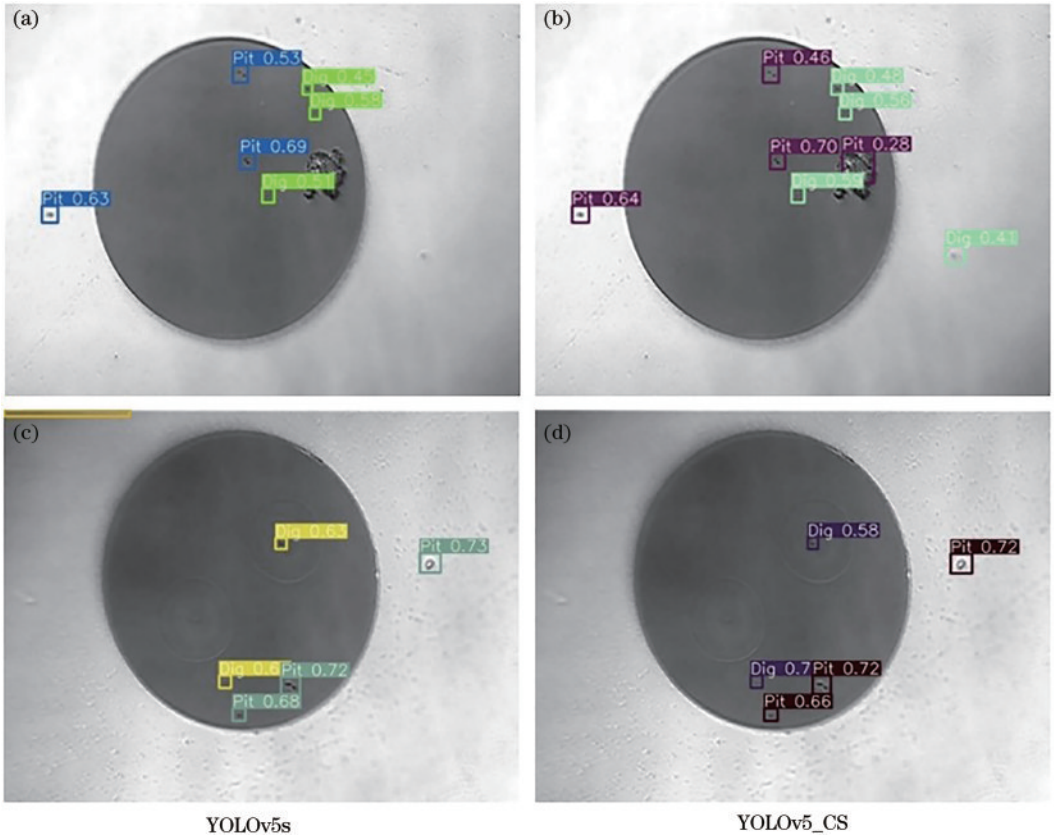

图13 YOLOv5_CS模型与YOLOv5s模型检测结果对比。(a)、(c) YOLOv5s的检测结果；(b)、(d) YOLOv5_CS的检测结果

Fig. 13 Detection results comparison of YOLOv5_CS model and YOLOv5s model. (a), (c) YOLOv5s detection results; (b), (d) YOLOv5_CS ditection results

图14(a)、14(c)为YOLOv5s的检测结果，图14(b)、14(d)为本文方法的检测结果。对比图14可以发现，本文模型检测结果的置信度评分均高于YOLOv5s检测结果的置信度评分。

综上所述，本文所提模型能够对光纤端面的3种缺陷自动分类以及标记缺陷所在位置，达到自动化检测要求，并与原YOLOv5网络相比检测结果更准确。

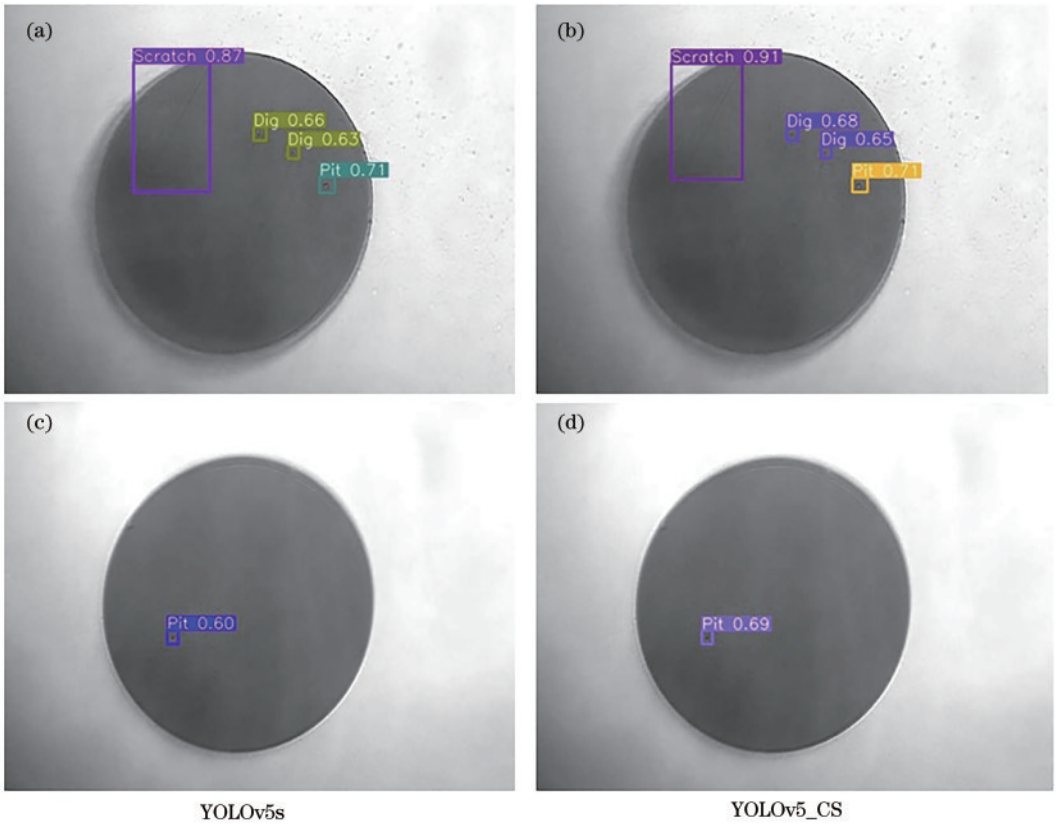

图 14 YOLOv5_CS模型与YOLOv5s检测结果对比。(a)、(c)YOLOv5s的检测结果;(b)、(d)YOLOv5_CS的检测结果

Fig. 14 Detection results comparison of YOLOv5_CS model and YOLOv5s model. (a), (c) YOLOv5s detection results; (b), (d) YOLOv5_CS detection results

4 结 论

针对光纤端面缺陷对光传输系统造成影响甚至永久性损伤的问题,提出了一种基于YOLOv5s网络的改进模型YOLOv5_CS用于检测光纤端面缺陷。该模型以YOLOv5s网络为基础,将ShuffleNetV2作为主干特征提取网络,并引入CBAM,以及缩减特征融合部分的卷积核数量,提高了模型检测速度,并提升了模型检测精度。

通过光纤端面检测仪和数据增广技术,得到数据量大、工业数据收集成本较低的自制数据集。在自制数据集上的实验结果表明,YOLOv5_CS模型的mAP为83.8%,模型容量为2.8 M,检测速度为118 frame/s。相较于目前已有的光纤端面缺陷检测算法,该模型检测时间提升了611 ms,且能同时识别多种缺陷。与原YOLOv5s模型相比,YOLOv5s_CS模型的mAP提升了1.7个百分点,对于麻点、凹坑以及划痕3类缺陷的mAP分别提升了2.6个百分点、1.9个百分点和0.9个百分点;且检测速度提高了31.1 frame/s,符合工业实时检测的要求;同时模型容量压缩了80%,有利于模型部署到低性能便携式智能设备平台上。

但此算法仍存在一定局限性,下一步将继续增加数据的多样性和复杂性,同时进一步改进网络结构,提高光纤端面缺陷的检测精度。随后,将开展智能检测器件的研制,为光纤端面缺陷检测及相关视觉传感产业提供技术支持。

参 考 文 献

[1] 周艳艳, 于凤霞, 刘淑梅, 等. 光纤端面的质量与光纤光学性能的关系[J]. 光学技术, 2005, 31(6): 806-808.
Zhou Y Y, Yu F X, Liu S M, et al. Discussion between the quality of optical fiber end face and optical property [J]. Optical Technique, 2005, 31(6): 806-808.

[2] 王洪祥, 沈璐, 李成福, 等. 光学元件激光诱导损伤分析及实验研究[J]. 中国激光, 2017, 44(3): 0302006.
Wang H X, Shen L, Li C F, et al. Analysis and experimental investigation of laser induced damage of optics[J]. Chinese Journal of Lasers, 2017, 44(3): 0302006.

[3] 牛文学, 梁艺军, 姜宇, 等. 光纤端面检测方法的实验研究[J]. 应用科技, 2002, 29(3): 19, 20-23.
Niu W X, Liang Y J, Jiang Y, et al. Experimental study of the method for inspecting optic fiber end[J]. Applied Science and Technology, 2002, 29(3): 19, 20-23.

[4] 谢勇明. 光纤连接器端面视觉检测技术研究[D]. 深圳: 深圳大学, 2016: 30-39.
Xie Y M. Research on optical fiber connector face inspection[D]. Shenzhen: Shenzhen University, 2016: 30-39.

[5] 裴扬. 一种基于光纤端面检测的激光干涉仪优化设计的研究[D]. 南昌: 南昌航空大学, 2014.

Pei Y. Study of optimization design based on laser interferometer for optical fiber end face[D]. Nanchang: Nanchang Hangkong University, 2014.

[6] Mei S, Wang Y D, Wen G J, et al. Automated inspection of defects in optical fiber connector end face using novel morphology approaches[J]. Sensors, 2018, 18(5): 1408.

[7] 赵伟杰, 高勇. 机器视觉在光纤端面缺陷检测中的应用[J]. 现代电子技术, 2011, 34(19): 136-139, 143.
Zhao W J, Gao Y. Application of machine vision in defects inspection of optical fiber end surface[J]. Modern Electronics Technique, 2011, 34(19): 136-139, 143.

[8] 朱莉, 徐胜勇. 基于OpenCV的光纤端面检测系统研究[J]. 光通信研究, 2015(1): 28-30, 38.
Zhu L, Xu S Y. Research on an OpenCV-based optical fiber end detection system[J]. Study on Optical Communications, 2015(1): 28-30, 38.

[9] 刘为, 唐春晖, 马秀梅, 等. 缺陷光纤端面几何参数的测量[J]. 光通信研究, 2013(6): 35-38.
Liu W, Tang C H, Ma X M, et al. Measurement of geometric parameters of defective fiber ends[J]. Study on Optical Communications, 2013(6): 35-38.

[10] 周程. 基于机器视觉的光纤端面缺陷自动检测系统[D]. 武汉: 华中科技大学, 2019: 120-145.
Zhou C. Automatic detection system of optical fiber end surface defects based on machine vision[D]. Wuhan: Huazhong University of Science and Technology, 2019: 120-145.

[11] 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.

[12] 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.

[13] 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.

[14] 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.

[15] 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.

[16] Redmon J, Farhadi A. YOLOv3: an incremental improvement[EB/OL]. (2018-04-08)[2021-04-05]. https://arxiv.org/abs/1804.02767.

[17] Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: optimal speed and accuracy of object detection[EB/OL]. (2020-04-23)[2021-04-05]. https://arxiv.org/abs/2004.10934.

[18] 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.

[19] Zhang S F, Wen L Y, Bian X, et al. Single-shot refinement neural network for object detection[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 4203-4212.

[20] Wang D F, Zhang B, Cao Y, et al. SFSSD: shallow feature fusion single shot multibox detector[M]//Leibe B, Matas J, Sebe N, et al. Communications, signal processing, and systems. Lecture notes in computer science. Cham: Springer, 2020, 9905: 21-37.

[21] Zhang X Y, Zhou X Y, Lin M X, et al. ShuffleNet: an extremely efficient convolutional neural network for mobile devices[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 6848-6856.

[22] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[EB/OL]. (2018-07-17)[2021-04-05]. https://arxiv.org/abs/1807.06521.

[23] Bai L L, Han Z N, Li Y F, et al. A hybrid de-noising algorithm for the gear transmission system based on CEEMDAN-PE-TFPF[J]. Entropy, 2018, 20(5): 361.

[24] Bai L L, Han Z N, Ren J J, et al. Research on feature selection for rotating machinery based on supervision kernel entropy component analysis with whale optimization algorithm[J]. Applied Soft Computing, 2020, 92: 106245.