

DOI:10.19651/j.cnki.emt.2106510

基于改进 YOLOv3 的头盔佩戴检测算法*

薛瑞晨 郝媛媛 张 振 黄训华 陆华丽 赵 华

(南京师范大学 计算机与电子信息学院(人工智能学院) 南京 210023)

摘要: 在城市交通中,时常出现电动车骑行者引发的安全事故。佩戴安全头盔可以有效地避免或降低安全事故带来的损害,因此目前多个城市已经颁布了佩戴安全头盔的相关法规。针对现有的安全头盔佩戴检测准确率低的问题,提出了一种基于改进 YOLOv3 的安全头盔佩戴检测算法。该改进算法采取了通道和空间注意力模块的加权特征融合,并结合密集连接网络以提高特征提取的效果,并且引入了空间金字塔池化结构以增强特征。以收集的电动车头盔佩戴检测数据集测试和比较了改进后的性能,结果表明,所提出的改进算法平均检测精度达到 93.29%,远高于原 YOLOv3 算法。实验表明,改进后的网络模型能显著提升电动自行车头盔佩戴情况的检测精度。

关键词: 计算机视觉;头盔佩戴检测;深度学习;改进 YOLOv3

中图分类号: TP391.4 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Helmet wearing detection algorithm based on improved YOLOv3

Xue Ruichen Hao Yuanyuan Zhang Zhen Huang Xunhua Lu Huali Zhao Hua

(School of Computer and Electronic Information/School of Artificial Intelligence, Nanjing Normal University, Nanjing 210023, China)

Abstract: In urban traffic, safety accidents caused by electric bike riders often occur. Wearing a safety helmet can effectively avoid or reduce the damage caused by a safety accident. Therefore, many cities have promulgated relevant regulations on wearing a safety helmet. Aiming at the existing problem of low detection accuracy of helmet wearing, this paper proposes an algorithm for detecting the safety helmet wearing based on improved YOLOv3. The improved algorithm adopts the weighted feature fusion of channel and spatial attention modules, and combines densely connected networks to improve the effect of feature extraction, and adds a spatial pyramid pooling structure to enhance features. The improved algorithm is tested and compared with original YOLOv3 at the self-built electric bike helmet wearing detection data set. The obtained results show that the mean average precision of the improved algorithm proposed reaches 93.29%, which is much higher than the original YOLOv3 algorithm. Experiments confirm that the proposed model can effectively enhance detection accuracy of electric bike helmet wearing detection.

Keywords: computer vision; helmet wearing detection; deep learning; improved YOLOv3 algorithm

0 引 言

电动自行车以其便捷、环保等特性受到广泛欢迎,但电动自行车骑行者作为交通中的弱势道路使用者,在事故中更容易受伤或者死亡。在世界卫生组织发布的《2018 年全球道路安全现状报告》中显示,2017 年全世界约有 135 万人死于道路交通事故,道路交通伤害成为全球人口死亡的重要原因之一。我国的道路交通安全状况也十分严峻,《中国统计年鉴-2020》显示,2019 年我国共发生了 134 617 起交通事故,其中,电动自行车等非机动车交通事故死亡人数占到死亡人数的 6.98%^[1]。

安全头盔能够对骑车人头部提供有效地保护,避免和降低骑车人严重的头部损伤。因此,越来越多的城市颁布了相关法规,规定电动自行车骑行者必须佩戴安全头盔,在许多道路安排了人员检测安全头盔佩戴情况,并对未佩戴安全头盔的电动车驾驶员采取罚款等警告措施。但是,通过人工的方法对电动车头盔的佩戴情况进行监测耗时耗力、覆盖面小,难以达到理想的监察效果。因此在公路交通环境下对骑车人和安全头盔的准确定位和实时监测对提高非机动车道的道路安全,保障道路交通顺畅起到了至关重要的作用。

在计算机视觉和人工智能领域,以卷积神经网络为代

收稿日期:2021-04-25

* 基金项目:江苏省科技厅面上项目(BK20201370)资助

表的深度学习算法在目标检测、识别、跟踪等方面相比于传统机器学习算法表现出了更优良的性能^[2-3]。日前,基于深度学习的目标检测算法主要分为两类:1)两阶段(Two-stage)算法如 RCNN^[4]、Fast R-CNN^[5]、Faster R-CNN^[6]、R-FCN^[7]、Mask R-CNN^[8]等;2)单阶段(One-stage)算法如 SSD^[9]、YOLO^[10]等。两阶段算法和单阶段算法的主要区别在于是否需要生成候选框。两步检测器需要进行候选区域生成的操作,因此准确率较高,但是存在速度瓶颈;单阶段算法直接在特征图上进行区域划分然后进行检测,在注重检测精度的同时还大大加快了检测速度。其中,2018年提出的 YOLOv3 算法在单阶段算法中表现最为优异。

针对本文的应用场景,在检测电动车驾驶人头盔佩戴情况时,不但需要较高的检测精度,也需要保证一定的检测速度。根据上述对目标检测算法的分析,单阶段算法在具有较高检测精度的同时,时间效率更高。因此针对本文实时性的要求,采用了单阶段检测中表现最为优秀的 YOLOv3 网络进行改进,以实现电动车驾驶人头盔佩戴情况的智能检测^[11]。为解决电动头盔样式多样带来传统 YOLOv3 网络的检测精度不高的问题,本文提出的改进网络引入了注意力模块和加权密集连接以改善特征提取,并加入了空间金字塔池化以增强局部特征,以上改进策略大大提高了电动自行车头盔佩戴情况检测的准确性。

1 YOLOv3 算法原理

YOLOv3 是从 YOLOv1 和 YOLOv2 衍生出的目前最先进的检测网络之一。YOLO 系列算法将分类和定位转化为回归问题,直接检测物体边界框的位置和类别概率^[12]。YOLOv3 的网络结构如图 1 所示,它结合了残差网络(ResNet)、特征金字塔(feature pyramid networks, FPN)和多尺度融合思想等优秀的方法,具备较好的识别速度和检测精度。

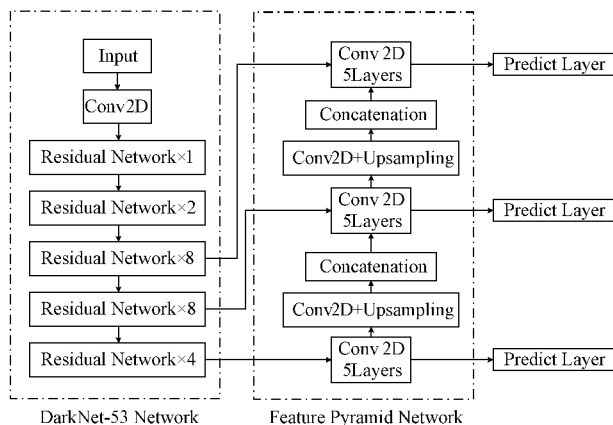


图 1 YOLOv3 原理

YOLO 系列网络都采用了 Anchor(锚点)机制进行目标位置的回归,输入图像经过骨干网络后得到特征图,特征图中的每个像素点即为锚点,以每个锚点为中心点,人为设

置不同的尺度(scale)和长宽比(aspect ratio),即可得到基于锚点的多个先验框(Anchor box),用以框定图像中的目标,这就是所谓的 Anchor 机制。采用 Anchor 机制的目的是学习一个从先验框到标签(ground true box, gt box)的转换的函数,使得网络对目标检测更加准确。YOLOv3 在每个尺度上使用 3 种尺度的先验框进行目标检测。

YOLOv3 的特征提取部分采用了 DarkNet-53, DarkNet-53 很好地将残差网络的思想融入,使用连续的 3×3 和 1×1 卷积层跳跃连接,利用残差层学习输入和输出之间的残差表示,而不是直接尝试学习输入和输出之间的映射关系,减少了信息的流失。

为了使得网络能够对不同尺度目标具有同样的检测效果,YOLOv3 采用了多尺度检测,从 DarkNet-53 中提取了 3 个不同的特征层进行预测,其大小为 $(52, 52, 256)$ 、 $(26, 26, 512)$ 和 $(13, 13, 1024)$ 。大小为 $(13, 13, 1024)$ 的特征层直接用于检测,而另外两个特征层则经过和下层的上采样操作后的下层特征进行融合后进行检测。

虽然以上特性给 YOLOv3 带来了优异的性能,但它仍然存在如下缺点:1)骨干网络特征提取能力低,不能充分利用浅层特征,制约了目标检测精度的提高;2)多尺度预测网络虽然充分利用了感受野,一定程度上解决了神经网络缺少尺度不变性的问题,但还存在着浅层特征提取不充分的问题。特别是在电动车头盔佩戴检测的问题中,由于头盔样式的多样性,在不改变输入图片尺寸的前提下,对局部特征的利用显得尤为重要。针对以上问题,本文提出了一种基于改进 YOLOv3 的电动车头盔佩戴检测网络,在提出的改进网络中引入了注意力模块,并采取加权密集连接以改善特征提取,同时采取空间金字塔池化以增强局部特征。

2 改进后的 YOLOv3 算法

2.1 特征提取网络

1) 注意力模块

准确地提取到目标的关键信息是目标检测的关键。2018年, Woo 等^[13]提出一种全新卷积模块:注意力机制模块(convolutional block attention module, CBAM),从空间维度和通道维度进行双重特征权重标定来提升网络准确率。本文受到注意力机制的启发,将结合了空间注意力机制和通道注意力机制的 CBAM 模块加入到特征提取网络中,以准确提取目标的关键信息。

CBAM 模块包含两个子模块:通道注意力模块(channel attention module, CAM)和空间注意力模块(spatial attention module, SAM)。在通道注意力模块中,通道注意力针对每个通道,在通道维度上学习到不同的权重。在目标检测中通道注意力可看作根据上下文语义选取相关特征的过程,当要预测目标时,此目标对应的特征图就会被分配更大的权重。通道注意力机制的结构如图 2 所示。首先通过全局平均池化(global average pooling)和全

局最大池化(global max pooling)将全局信息压缩为一维向量,然后利用全连接层降低网络维度,再经过 ReLU 激活函数,通过一个全连接层,最后经过 Sigmoid 生成归一化的权重,生成通道注意力矩阵。经过特征加权操作后,为特征图增加了通道注意力机制,继续向下传播到空间注意力模块中。

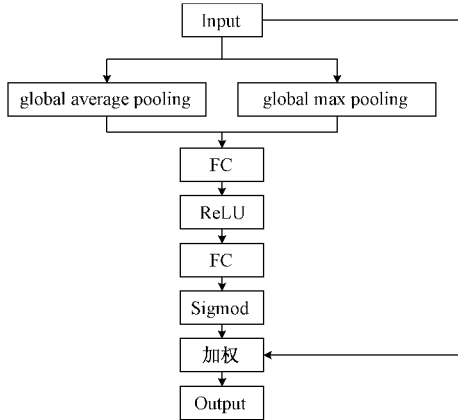


图2 通道注意力模块

图3为空间注意力机制的结构,首先,还是使用全局平均池化和全局最大池化对输入特征图进行压缩操作,只不过这里的压缩变成了通道维度上的压缩,最后得到了两个二维的特征图,再将它们按通道维度拼接在一起,得到一个通道数为2的特征图。然后通过卷积将特征图的通道数降为1,通过 Sigmoid 函数得到归一化的权重,生成空间注意力矩阵,经过特征加权操作后,将空间注意力矩阵与特征图做乘法,为特征图增加了空间注意力机制,继续向下传播。将通道注意力模块和空间注意力模块级联,就得到了一个完整的 CBAM 模块。

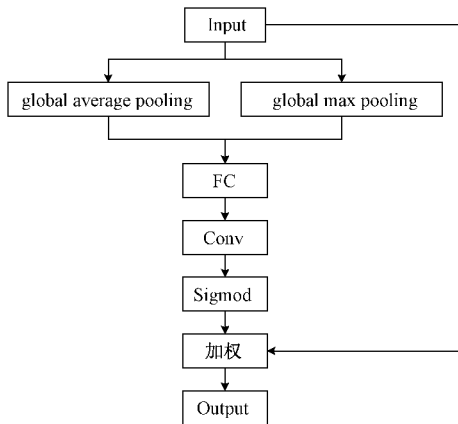


图3 空间注意力模块

2) 密集连接模块

YOLOv3 中的残差结构 ResBlock 中,第 l 层的输入与第 $l-1$ 层的输入和输出的关系可以表示为式(1),其中的 $H(x)$ 代表非线性变换。残差结构定义了输入输出之间的连接关系,将前后相邻的特征层连接起来,第 l 层的输入来

自前一层的输出和输入之和。

$$x_l = H(x_{l-1}) + x_{l-1} \quad (1)$$

但是 ResBlock 中的信息流是经过非线性变换后求和的,不能保证前一层的消息有效传播。2017 年 Huang 等^[14]提出了一个更有效的网络,即密集连接的卷积网络 DenseNet。密集连接网络中的密集连接模块 DenseBlock 中,第 l 层的输入来自于前面所有层的输入,可以表示为式(2),包含 5 个密集连接层的密集连接结构如图 4 所示。

$$x_l = H([x_0, x_1, x_2, x_3, \dots, x_{l-1}]) \quad (2)$$

为了实现特征的复用与融合,本文将原网络中所有的残差块替换为密集连接块,构建了一个密集连接的网络,使网络在预测之前能够接受密集连接块输出的多层特征卷积。




图4 密集连接模块

每个密集连接块之间有一个过渡层(Transition Layer),它的作用是减少通道数。在 3×3 的卷积之前加入 1×1 的卷积层来减少特征图的数量,提高计算效率的同时并不改变特征层的大小。

本文根据 YOLOv3 的输出大小重新设计了特征提取网络。特征提取网络由 5 个密集连接块组成,每个密集连接块包含 5 个密集连接的卷积层。GrowthRate 设置为 32,表示每个卷积层的输出有 32 个特征图,卷积层之间都密集连接。3 个密集连接块输出的特征图尺寸是: 52×52 、 26×26 和 13×13 。在每个密集连接块和过渡层之间再加入 CBAM 模块,构成本文所提出网络的特征提取网络基础结构 Dense-CBAM 模块。

2.2 特征增强网络

在常规的 YOLOv3 中骨干网络的深层特征图是按照如下方法提取的:深层特征图每次经过步长为 2 的上采样得到的特征图与前面尺度相同的特征图进行连接,得到 3 个包含丰富的上下层信息低层次特征图,它们的尺寸分别为 $(52, 52)$ 、 $(26, 26)$ 、 $(13, 13)$,并在这 3 个尺度上进行检测。然而,这样的多尺度检测更侧重于连接多尺度卷积层的全局特征,而忽略了多尺度局部区域特征在同一卷积层上的融合,对局部信息利用不够完全。而在电动车头盔佩戴检测的问题中,由于头盔样式的多样性,在不改变输入图片尺寸的前提下,局部特征的利用显得尤为重要。

2015 年,He 等^[15]提出空间金字塔池化(SPP)概念,其核心思想是使用固定分块的池化操作,对不同尺寸的输入实现相同大小的输出,具体操作是利用 3 个不同尺寸的池

化层进行最大池化,其池化核大小分别为 13×13 、 9×9 、 5×5 ,步长均为 1,最后将原特征图和 3 个经池化处理后得到的局部特征图进行堆叠,再进行 3 次卷积操作。空间金字塔池化结构的使用可以极大地增加最后一个特征层的感受野,分离出最显著的上下文特征,从而获得更加丰富的局部特征信息,其结构如图 5 所示。

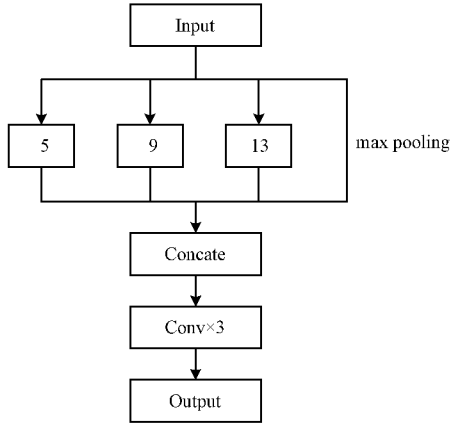


图 5 空间金字塔池化

本文将空间金字塔池化加入检测网络中。用于合并和连接多尺度局部区域特征,从而将全局和局部多尺度特征融合,获得更丰富的信息,以此提高电动车头盔佩戴检测的准确性。

由于空间金字塔池化并没有对输出特征图尺寸进行改变,因此本文考虑将空间金字塔池化引入到多尺度检测之前,将融合了更丰富局部特征信息的特征层送入多尺度检测网络中,再结合特征提取网络,构成了本文提出的基于改进 YOLOv3 的电动车头盔佩戴检测网络,如图 6 所示。

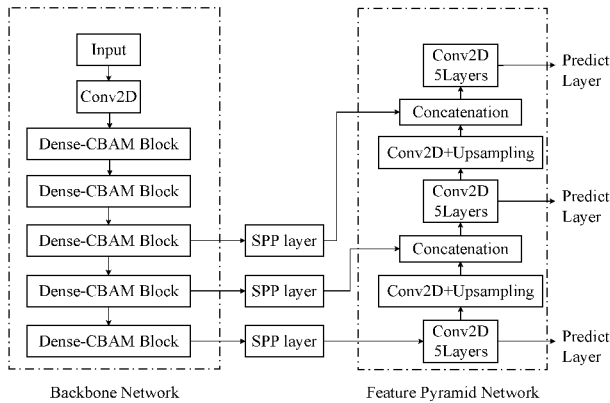


图 6 基于改进 YOLOv3 的电动车头盔佩戴检测网络

3 实验平台与结果分析

3.1 实验平台

本文的实验平台使用 Linux 系统,CPU 为 Intel(R) Xeon(R) Silver 4214 CPU@2.20 GHz,GPU 为 NVIDIA GTX2080Ti,11G 运行内存。模型采用 Kcras2.1.5 框架,

Tensorflow1.14.0 作为后端,编程语言采用 Python 3.6。网络模型训练的主要思路是使用已经在大规模数据集上训练好的模型进行微调,在新数据集上继续训练模型。训练好的网络结合摄像头构成电动自行车头盔佩戴检测系统,检测系统如图 7 所示。




图 7 电动自行车头盔佩戴检测系统

3.2 数据集

由于目前并没有公开的电动车头盔佩戴检测数据集,因此本文通过摄像头拍摄和网络爬取的方法进行了数据集的制作。之后,利用 Labelimg 软件进行手工标注,将目标分为 3 类:Motor、Helmet 和 People,分别指电动车、电动车头盔和未佩戴头盔的人脸。图 8 为数据集示例图片,图 9 为示例图片对应的 VOC 格式的 xml 文件。选取数据集中的 1 100 张图像作为训练集,300 张图像为测试集,经过 resize 后输入 416×416 大小的图片进入网络训练。



图 8 数据集图片示例

```

- <source>
  <database> Unknown</database>
</source>
- <size>
  <width>1024</width>
  <height>1024</height>
  <depth>3</depth>
</size>
<segmented>0</segmented>
- <object>
  <name>helmet</name>
  <pose>Unspecified</pose>
  <truncated>0</truncated>
  <difficult>0</difficult>
  <bndbox>
    <xmin>732</xmin>
    <ymin>404</ymin>
    <xmax>818</xmax>
    <ymax>506</ymax>
  </bndbox>
</object>
- <object>
  <name>head</name>
  <pose>Unspecified</pose>
  <truncated>0</truncated>
  <difficult>0</difficult>
  <bndbox>
    <xmin>168</xmin>
    <ymin>348</ymin>
    <xmax>218</xmax>
    <ymax>412</ymax>
  </bndbox>
</object>
- <object>
  <name>motor</name>
  <pose>Unspecified</pose>
  <truncated>0</truncated>
  <difficult>0</difficult>
  <bndbox>
    <xmin>116</xmin>
    <ymin>350</ymin>
    <xmax>272</xmax>
    <ymax>714</ymax>
  </bndbox>
</object>
- <object>
  <name>motor</name>
  <pose>Unspecified</pose>
  <truncated>0</truncated>

```

图 9 示例图片对应 xml 文件

3.3 Anchor 聚类

YOLOv3 使用 K-means 算法聚类 COCO 数据集得到 9 个先验框,并将其均分到 3 个尺度特征图,其中,尺度更大的特征图使用更小的先验框,以此来获得更多的目标边缘信息。YOLOv3 中计算得到的 9 组先验框尺寸分别为 (10,3)、(16,30)、(33,23)、(30,61)、(62,45)、(59,119)、(116,90)、(156,198)、(373,326),但是在实际电动车头盔佩戴检测任务中,YOLOv3 算法中计算得到的先验框维度并不适合电动车头盔佩戴检测场景,使用 YOLOv3 算法中原有的先验框维度很难得到精确的目标框信息。

因此,在电动车头盔佩戴检测场景下,使用 K-means 算法对自制的电动车头盔佩戴检测数据集进行聚类分析,得到 9 组先验框维度,分别为 (11,15)、(15,20)、(20,27)、(24,32)、(30,39)、(37,53)、(65,38)、(89,188)、(89,88),后将 Anchor 数据设置到配置文件中,进行电动车头盔佩戴检测实验。

3.4 实验结果

为验证本文算法对电动车头盔佩戴检测的准确性,构建了多种检测网络,就检测精度对算法性能进行对比。本文使用目标检测常用的模型评价指标:全类平均准确率(mean average precision,mAP)。

本文以 YOLOv3 为基础改进,在实际拍摄的 300 张图片上设计了 4 次实验,验证改进方法的有效性。A~C 实验均采用了 YOLOv3 的框架。区别在于 A 实验采用了 K-means 算法聚类先验框,B 实验在 A 实验的基础上更换骨干网络为 Dense-CBAM 结构,C 实验在 B 实验的基础上加入了空间金字塔池化进行特征增强,对比实验的结果如表 1 所示,表中“√”表示采用了对应的改进方法。

表 1 对比实验结果

算法	K-means	Densenet+CBAM	SPP	mAP/%
YOLOv3				86.23
A	√			90.38
B	√	√		91.95
C	√	√	√	93.29

表 1 中的数据可以看出,本文改进后的 YOLOv3 算法相对于原 YOLOv3 算法,平均精确度提升了 7.06%。

1)对比 YOLOv3 和 A 实验可以看到,A 实验的检测精度提高了 4.15%,主要是因为原 YOLOv3 的先验框尺寸与本文的应用场景并不匹配。而采用 K-means 算法聚类分析得到的先验框尺寸能更好地适应电动车头盔佩戴检测的场景。

2)对比 A 实验和 B 实验可以看到,B 实验的检测精度提高了 1.57%,主要是因为 YOLOv3 的特征提取网络采用

的残差结构使用前层输入和输出相加的方式输入到下层,丢失了一部分信息,而密集连接结构采用跨层连接的方式,考虑到了各层的语义信息,使得信息能够在所有层中流动;又加入了注意力机制模块,将通道注意力和空间注意力结合,实现了图像全局特征和局部特征的互补,进一步提升了特征提取的效果。

3)对比 B 实验和 C 实验可以看到,C 实验的检测精度提高了 1.34%,主要是因为 YOLOv3 采用的特征金字塔网络对图像局部特征的利用不够充分,而加入了空间金字塔池化后,增加了最后一个特征层的感受野,分离出最显著的上下文特征,从而获得更加丰富的局部特征信息,对于电动车头盔佩戴检测进行了针对性的提升。

从表 1 可以看出本文算法就电动车头盔佩戴检测的场景对 YOLOv3 算法的改进是切实有效的,检测精度相对于 YOLOv3 算法有较大提升,能够完成电动车头盔佩戴检测的任务。

图 10 所示为 YOLOv3 和改进后的 YOLOv3 算法检测结果。从图中可以看到,原 YOLOv3 算法在 Helmet 类的检测上效果一般,会出现漏检现象。而改进后的 YOLOv3 算法结合了图像的全局特征和局部特征,提升了特征提取的效果,降低了 Helmet 类的漏检,其他类别的检测置信度得分也得到了提高,有效提高了电动自行车头盔佩戴情况的检测效果。

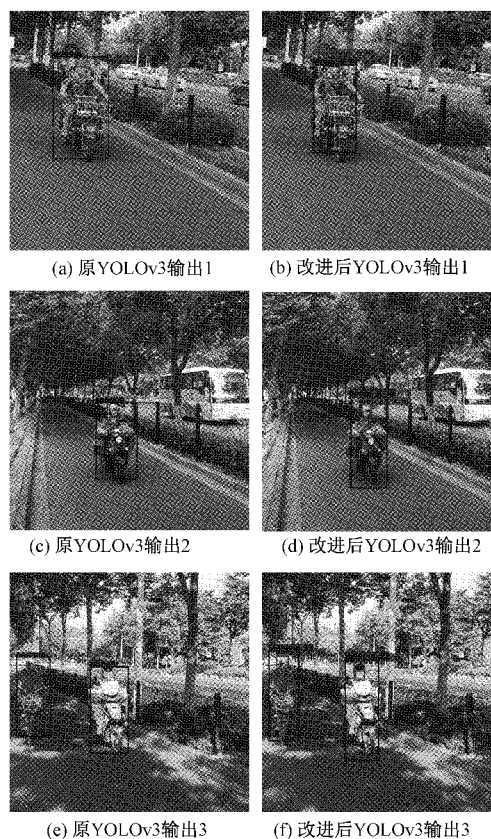


图 10 算法检测效果比较

4 结 论

本文基于YOLOv3算法进行改进,提出了一种基于加权密集连接和空间金字塔池化的电动车头盔佩戴检测网络。所提出的改进算法在骨干网络采用密集连接块并加入通道注意力模块和空间注意力模块进行特征提取;在特征提取网络和检测网络之间加入空间金字塔池化作为特征增强网络。对于实验数据集,本文通过拍摄和网络爬取相结合的方式制作了数据集,具有一定真实性。与原始的YOLOv3算法对比,本文提出的算法准确率达到93.29%,性能更为优异,有希望用于检测城市交通中电动自行车驾驶人佩戴头盔情况。

参考文献

- [1] 国家统计局. 中国统计年鉴[M]. 北京: 中国统计出版社, 2019.
- [2] 张培培, 王昭, 王菲. 基于深度学习的图像目标检测算法研究[J]. 国外电子测量技术, 2020, 39(8): 34-39.
- [3] 周晓彦, 王珂, 李凌燕. 基于深度学习的目标检测算法综述[J]. 电子测量技术, 2017, 40(11):89-93.
- [4] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [5] GIRSHICK R. Fast R-CNN[C]. IEEE International Conference on Computer Vision, 2015:1440-1448.
- [6] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[C]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
- [7] DAI J F, LI Y, HE K M, et al. R-FCN: Object detection via region-based fully convolutional networks[C]. Annual Conference on Neural Information Processing Systems, 2016:379-387.
- [8] HE K M, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN [C]. IEEE International Conference on Computer Vision, 2017:2980-2988.
- [9] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. European Conference on Computer Vision, 2016:21-37.
- [10] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [11] 李秀智, 李家豪, 张祥银, 等. 基于深度学习的机器人最优抓取姿态检测方法[J]. 仪器仪表学报, 2020, 41(5):108-117.
- [12] 曹红燕, 沈小林, 刘长明, 等. 改进的YOLOv3的红外目标检测算法[J]. 电子测量与仪器学报, 2020, 34(8):188-194.
- [13] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]. 15th European Conference on Computer Vision, 2018: 3-19.
- [14] HUANG G, LIU Z, MAATEN L D, et al. Densely connected convolutional networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2261-2269.
- [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.

作者简介

薛瑞晨,工学硕士在读,主要研究方向为智能硬件、深度学习等。

E-mail: 576565873@qq.com

郝媛媛,工学硕士在读,主要研究方向为光纤通信、深度学习等。

E-mail: 875715547@qq.com

张振,工学硕士在读,主要研究方向为光纤通信、深度学习等。

E-mail: 601399821@qq.com

黄训华,工学硕士在读,主要研究方向为光纤通信、深度学习等。

E-mail: 1326931078@qq.com

陆华丽,工学博士在读,主要研究方向为电子信息、激光传感等。

E-mail: luhuali@njnu.edu.cn

赵华(通信作者),硕士生导师,主要研究方向为信号处理、光纤光栅、深度学习及智能仪器等。

E-mail: zhaohua@njnu.edu.cn