

基于混合注意力网络的安全工器具检测

凌永标^{1,2}, 毛峰^{1,2}, 杨岚岚^{2*}, 邱兴卫¹, 张志锐¹, 张杰¹

(1. 国网黄山供电公司, 安徽 黄山 245000;

2. 安徽大学 计算机科学与技术学院, 安徽 合肥 230601)

摘要:在电网施工和安全检查过程中, 电力工作人员的安全问题至关重要。施工现场的安全工器具是否有破损直接关系到电力工作人员的安全, 因此提出一种基于混合注意力网络的安全工器具神经网络自动检测方法, 用于施工现场的安全工器具检测问题。所提出的混合注意力网络以经典的 Faster R-CNN 为主干网络, 混合注意力模块包含全局通道注意力和局部空间注意力两个子模块。其中全局通道注意力关注的是通道的重要性, 而局部空间注意力关注的是空间位置信息, 主要是帮助网络定位目标。还引入了多种混叠的数据增强方法, 以及采用了基于多尺度特征金字塔的多层预测方法。此外, 为了验证该方法的有效性, 还从电网施工现场采集了一批真实图片, 整理并标注对应的安全工器具, 构建了一个安全工器具数据集。经实验对比, 该方法对于安全工器具的自动检测有较好的效果。

关键词:目标检测; 安全工器具; 注意力网络; 数据增强; 特征金字塔

中图分类号: TP389.1

文献标识码: A

文章编号: 1673-629X(2022)06-0209-06

doi: 10.3969/j.issn.1673-629X.2022.06.035

Safety Tools Detection Based on Hybrid Attention Network

LING Yong-biao^{1,2}, MAO Feng^{1,2}, YANG Lan-lan^{2*}, QIU Xing-wei¹,

ZHANG Zhi-rui¹, ZHANG Jie¹

(1. Huangshan Power Supply Company of State Grid, Huangshan 245000, China;

2. School of Computer Science and Technology, Anhui University, Hefei 230601, China)

Abstract: In the process of power grid construction and safety inspection, electric power staff safety is crucial. Construction site safety instruments to see if there is any breakage directly relates to the safety of staff in the electric power. Therefore, we propose an automatic detection method of safety tools based on hybrid attention network, which is used for safety tools detection in construction site. The proposed hybrid attention network takes the classical Faster R-CNN as the main stem network, and the hybrid attention module consists of two sub-modules: global channel attention and local spatial attention. Global channel attention is concerned with the importance of the channel, while local spatial attention is concerned with spatial location information, mainly to help the network locate the target. We also introduce a variety of aliasing data enhancement method and use the multilayer prediction method based on multi-scale feature pyramids. In addition, in order to validate the effectiveness of the proposed method, we also collect a batch of real images from the grid construction site, obtain the corresponding safety instruments and construct a set of security and instrument data. According to comparison, the proposed method is effective for the automatic detection of safety and instrument.

Key words: object detection; safety tools; attention network; data enhancement; feature pyramid.

0 引言

随着经济不断发展, 人们对电力的需求越来越大, 输电部署和电网安全检查任务艰巨。由于受到输电系统的内外环境影响, 电力系统故障时有发生。电网部署和安全检查需要电力工作人员花更多的时间在施工现场, 这无疑增大了电力工作人员的危险。目前, 越来越多的行业都引入了人工智能技术来做一些重复或者

危险的事^[1]。电网部署和安全检测中引入人工智能更是未来的趋势。

安全工器具是指在触电、灼伤、坠落、摔跌等事故中, 保障电力工作人员人身安全的各种专用的安全工器具。常用的有个体防护装备、绝缘安全工器具、登高工器具、警示标识等四大类。它的好坏直接影响到电力工作人员的人身安全, 所以必须重视对安全工器具

收稿日期: 2021-03-14

修回日期: 2021-07-20

基金项目: 国家自然科学基金资助项目(61976004); 国网安徽省电力有限公司科技项目(5212S01900RN)

作者简介: 凌永标(1967-), 男, 高级工程师, 硕士, 研究方向为智能计算。

的日常检查。然而,存在有少部分电力工作人员安全防范意识薄弱,对安全工器具的日常检查流于形式,给电网安全检查带来危险。电网安全检查的监管急需对检查全过程中安全工器具进行自动化检测和报警的解决方案,以保障电力工作人员的人身安全,防患于未然,提高电网运营的安全性。

该文重点关注绝缘手套、绝缘鞋、安全带、安全绳、挂钩这几类安全工器具在电网安全检查中是否正常或出现破损情况的自动化检测与识别任务。提出一种基于混合注意力网络的安全工器具检测方法。混合注意力网络以经典的 Faster R-CNN^[2]为主干网络,混合注意力模块包含全局通道注意力和局部空间注意力两个子模块,引入多种混叠的数据增强方法,采用了基于多尺度特征金字塔的多层预测方法。此外,为了验证所提方法的有效性,还从电网安全检查现场采集了一批真实图片,整理并标注对应的安全工器具,构建了一个安全工器具数据集。

1 相关工作

传统的目标检测算法主要依赖于手工设计的特征,对于多样性的变化没有很好的鲁棒性。而且由于采用滑动窗口的方式选取候选框,没有针对性,时间复杂度高,窗口冗余问题严重,难以取得满意的结果。最近几年,随着深度学习领域的快速发展,深度卷积神经网络越来越多地应用于计算机视觉领域,如检测、分割、跟踪等,并取得重大进展。基于深度卷积神经网络的目标检测算法在目标检测领域取得了最好的效果。深度学习技术引用到检测领域,主要使目标检测精度大幅提升,使得单一模型能够检测的目标类别数目增加。

基于神经网络的目标检测算法分为两阶段检测算法和单阶段检测算法两种。R-CNN^[3] (Region with CNN feature) 是卷积神经网络应用于目标检测问题的一个里程碑的飞跃,其使用 Selective Search^[4] 算法生成候选区域,然后将候选区域变换为统一大小,送进 CNN 提取特征,输出的特征向量由 SVM 分类器进行分类,R-CNN 的进阶版 Fast R-CNN^[5] 在 R-CNN 的基础上采纳了 SPP-Net^[6] 方法,对 R-CNN 作了改进,使得性能进一步提高。Fast R-CNN 与 R-CNN 对比,主要有两处不同:一是最后一个卷积层后加了一个 ROI pooling 层,二是损失函数使用了多任务损失函数 (multi-task loss),将边界框回归直接加入到 CNN 网络中训练。Faster R-CNN 采用 Region Proposal Network (RPN) 来替代 Selective-Search 提取候选区域,anchor 就是位置和大小固定的框,可以理解成事先设置好的固定的候选区域。

YOLO^[7] 不同于上述两阶段目标检测方法,它将物体检测当成一个回归问题。做法是基于一个单独的端到端网络,来完成从原始图像的输入到物体位置和类别的输出任务。SSD^[8] 也是单阶段目标检测方法,是 Faster RCNN 和 YOLO 的结合,同时采用了 Faster RCNN 中基于候选框的概念和 YOLO 中基于回归的处理方法,在一个端到端网络中直接回归出目标物体的类别和位置。FCOS 是一个基于全卷积的单阶段检测网络,类似于语义分割,针对每个像素进行预测。SSD、YOLOv3^[9]、Faster R-CNN 都依赖于预定义的候选框。而 CornerNet、CenterNet、FCOS^[10-12] 是不需要预定义候选框的,从而减少大量的计算以及内存占用。

结合数据增强和注意力机制等优点,该文提出一种基于混合注意力网络的安全工器具检测方法,主要是在 Faster R-CNN 网络结构上添加了混合注意力模块,引入了多种混叠的数据增强方法,采用了基于多尺度特征金字塔的多层预测方法,以解决数据集中小目标检测不准确的问题。

2 基于混合注意力网络的安全工器具检测

2.1 多种混叠的数据增强

通过大量的实验发现,许多效果较好的神经网络都有大量的参数,要想很好地训练这些参数,以使网络拟合,则需要大量的训练数据。因为 AI 技术非常强地依赖于高质量数据^[13]。但是在实际制作数据集时,无论是采集数据,还是对数据进行标注都需要大量的人力,物力,而且这非常耗时。因此该文采用数据增强技术来缓解数据量不足的问题。目前数据增强技术主要是通过通过对图片进行翻转,平移或者是旋转等操作,有时也会采用在数据上增加噪声的操作,以此可以在已有的少量数据上得到更多的训练数据,使得网络达到更好的效果^[14]。综上,为了提高网络的精度与泛化能力,该文采用数据增强技术来获得更多的训练数据。

数据增强主要分为:离线增强和在线增强。离线增强:顾名思义是在数据输入神经网络前对数据进行离线增强,通过离线增强的数据集在数据上会变成原数据集数目的 N 倍(是增强因子)。在线增强:这种数据增强的方法是在神经网络中对数据进行增强,主要做法是在得到 batch 数据后,对获得的这些 batch 数据进行 batch 块的旋转,平移或者翻转等操作。由于在线操作很受硬件条件限制,这种增强方法一般适合较大的数据集。目前,随着技术的不断发展,很多机器学习框架已经支持了这种在线数据增强方式,并且可以使用 GPU 来自动实现优化计算。因为以后的数据量较少,故该文采用的是多种混叠的离线数据增强的方式。多种混叠的数据增强示例如图 1 所示。



图 1 多种混叠的数据增强

(翻转、旋转、剪裁、mixup) 示例

数据翻转是数据增强中比较常用的一种方法,主要做法是将图片做类似于镜面的翻转,而不是将图片旋转 180 度,如图 1 第一列分别是原图的左右翻转。该文的增强因子是 2(即:指数量扩大 2 倍)。旋转就是顺时针或者逆时针的旋转,通常增强因子设为 2 ~ 4。如图 1 第二列第二行所示,增强因子也设为 2。裁剪这种数据增强方法的做法是先在原有图片上随机选择其中的一部分区域,然后将选择后的这部分区域裁剪,最后将裁剪得到的图片块 resize 成与原图片一样的大小,如图 1 第二列第一行所示。该方法的增强因子任意,文中裁剪的增强因子也是设为 2。mixup^[15]是一种最近新出来运用在计算机视觉上的数据增强方法,它的做法是将不同类别的图像进行混合,如图 1 第

三列所示。综上,该文在数据增强上主要采用了以上几种方法来扩充数据集。

2.2 基于 Faster R-CNN 的混合注意力网络

所提的混合注意力网络以经典的 Faster R-CNN 为主干网络。Faster R-CNN 主要包括四个模块,分别是:特征提取、RPN、RoI Pooling 和 RCNN。因为多阶段信息可以增强网络的能力,提高算法的精度^[16],在文献[17]通过引入多尺度的特征融合模块,设计了一个针对目标检测任务的轻量化特征提取网络 TinyNet,进而提高了轻量化特征提取网络对不同尺度目标的适应性。因此,为了解决数据集中部分目标较小的问题,该文加入了 FPN^[18](特征金字塔网络)。此外每一个通道的特征通常都表示某特定类别的目标,在文献^[19]基于语义的增强混合特征选择方法在文本分类时既提高了分类效率又能保证分类精度,在文献[20]利用注意力机制对信息进行增强融合语义信息与问题关键信息的多阶段注意力答案选取模型也极大地提升了算法的性能。基于以上启发,并且为了解决不同通道重要性不同的问题,该文提出了混合注意力机制。网络结构如图 2 所示。

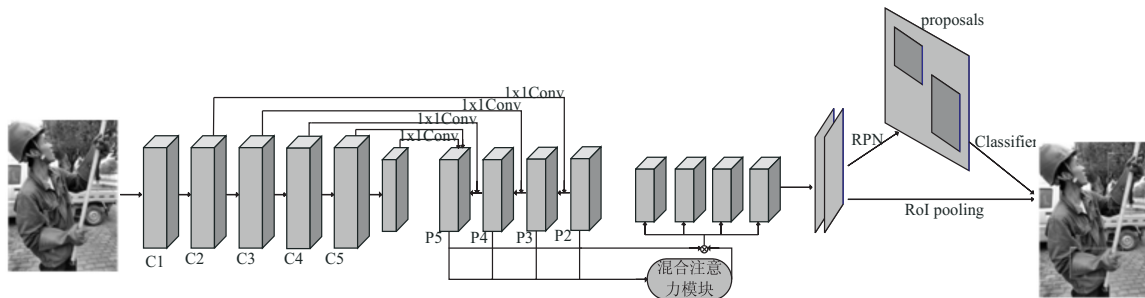


图 2 基于 Faster RCNN 的混合注意力网络结构

在以往的工作中使用 Faster R-CNN 进行目标检测,不论是在 RPN 还是在 Fast R-CNN 中,RoI 都作用在 Fc 的前一层,这样做在对大目标物体进行检测时效果是很好的,但是对于小目标物体的检测效果就不行了。主要原因是对于一个 RoI,映射到某个特征图的做法是将底层的坐标直接去除以步长,对于小目标物体,当进行多层卷积和池化后,映射过去后就很小甚至是没有了。所以为了解决数据集中部分目标较小而检测不好的问题,该文引入了特征金字塔网络,特征金字塔可以自然地利用卷积神经网络层级特征的金字塔形式,在生成所有的尺度上都含有强语义的信息特征。特征金字塔网络的结构采用自顶向下(the top-down pathway)结构和横向连接(lateral connections)的方式,以达到融合含有高分辨率的底层特征和含有丰富的语义信息的高层特征。这样做到了从单尺度的一张输入图片,快速地构建在所有尺度上都具有强的语义信息的特征金字塔网络,与此同时并没有产生明显的计算

代价。




图 3 基于多尺度特征金字塔的预测流程

采用自上而下的路径去融合低层特征图,这些低层特征图一般拥有较高的分辨率。特征金字塔具体做法如图 3 所示,首先图最左侧一列是通过卷积得到每一层的特征图,一般经过多层卷积得到的特征图分辨率会越来越低,但是会含有更多的语义信息,接着中间一列的作用是将左侧得到的最高层的特征图逐层做上采样操作,因为每一层的横向连接操作需要将要连接的两层特征的大小调整成相同的尺寸。这里使用横向

连接的作用是利用低层特征图的定位细节信息。如图 3 所示,首先将高层特征图做一个 2 倍上采样操作,然后将与其对应的前一层特征图做一个横向连接结合,结合方式就是做像素间的加法。重复迭代该过程,直至生成最精细的特征图。迭代开始阶段,在卷积 5 层后面加了一个 $1 * 1$ 的卷积核来产生最粗略的特征图。最后,用 $3 * 3$ 的卷积核去处理已经融合的特征图,以生成最后需要的特征图。为了后面的应用能够在所有层级共享分类层,这里固定了 $3 * 3$ 卷积后的输出通道为 d ,这里 d 设为 256。因此所有额外的卷积层具有 256 通道输出。这些层没有用非线性激活函数。卷积

2,3,4,5 层对应的融合特征层为 P2,3,4,5,对应的层空间尺寸均相同。

通常在神经网络中是同等地对待每一个卷积层,但是其实每一个通道的特征通常都表示某特定类别的目标。参考文献[21-23],该文设计了一种全新的混合注意力模块(通道空间注意力模块 CSA),分别包括全局通道注意力和局部空间注意力两个子模块。全局通道注意力是为了解决每个通道在卷积神经网络中贡献不同的问题,局部空间注意力是为了关注图片中的局部细节信息而加入的。

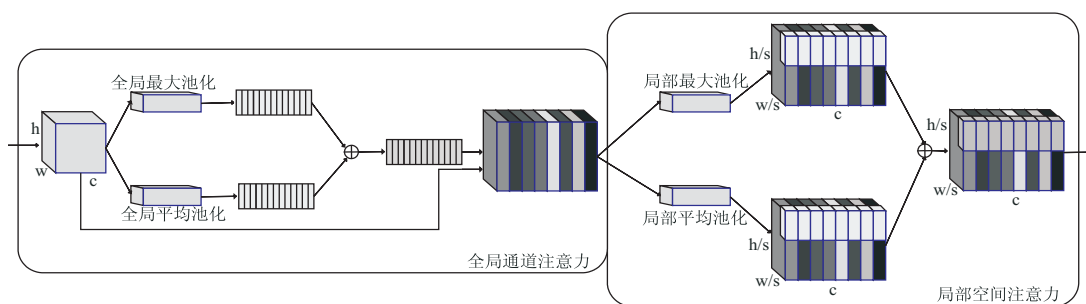


图 4 混合注意力模块(包含全局通道注意力和局部空间注意力两个子模块)

如图 4 所示,该通道注意力首先对输入的特征进行一个全局平均池化操作和全局最大池化操作。假如输入的是一个 $h * w * c$ 的特征图,由两个全局池化(池化大小为 $h * w$)的操作可以得到两个 $1 * 1 * c$ 的特征图,然后将这两个特征图进行一个相加操作,相加后得到一个 $1 * 1 * c$ 的特征图,这个 $1 * 1 * c$ 的特征图与输入的特征图 $h * w * c$ 相乘便得到全局通道注意力之后的特征图。将全局通道注意力特征图作为输入,送入到局部空间注意力模块中,输入到局部空间注意力的特征经过一个局部最大池化和局部平均池化后分别得到两个特征图,特征图的大小是 $(h/s) * (w/s) * c$ (s 是池化的步长),然后将经过局部最大池化和局部平均池化得到的特征图进行一个相加操作。这样经过全局通道注意力和局部空间注意力之后便得到重要的通道,同时也关注到局部信息。

损失函数与 Faster R-CNN 是一样的,定义成以下式子:

$$L(\{p_i\}, \{t_i\}) = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, P_i) + \lambda \frac{1}{N_{reg}} \sum_i P_i L_{reg}(t_i, T_i) \quad (1)$$

$$L_{reg}(t_i, T_i) = L_1(t_i - T_i) \quad (2)$$

其中, i 是一个小批量中 anchor 的索引; p_i 是预测的该 anchor 是目标的概率; P_i 是真值标签,如果 anchor 是正样本,真值标签的值为 1,否则为 0; t_i 是预测的边界框的四个参数化坐标向量; T_i 是真值框的四个参数化坐标向量; L_{cls} 是分类损失,判断预测框是目标还是背

景; L_{reg} 是回归损失; L_1 是平滑损失。 $P_i L_{reg}$ 意味着只对正样本锚框进行回归,因为当是负样本锚框时 P_i 的值为 0。

3 实验

3.1 实验环境和数据集

实验是在 NVIDIA GeForce GTX TITAN XP GPU 平台上进行的,网络训练运行内存为 12 GB,代码基于 PyTorch 深度框架。

该文使用的数据来源于真实施工场景。从电力工作人员必备的安全防护工具的角度考虑,收集了绝缘手套、绝缘鞋、安全带、安全绳以及挂钩的相关图片数据,从而更好地进行施工现场安全性检测。共实地收集了 2 541 张图片,其中划分 80% 作为训练集,其余图片作为验证集。表 1 列举了制作的数据集的具体检测对象分布情况。注意到该数据集中的类别个数相差较大,是因为部分类别的场景分布较单一,比如绝缘手套破损和绝缘鞋,只出现在很少的场景下。

表 1 电网施工现场安全工器具数据集的类别分布

检测目标名称	图片数量(幅)
绝缘手套(正常/破损)	441/96
绝缘鞋(正常/破损)	64/23
安全带(正常/破损)	334/217
安全绳(正常/断股)	289/305
挂钩(正常/破损)	738/34

3.2 评价指标

目标检测的效果取决于预测框的位置和类别是否准确,主流的评级指标有:平均精度值(Average Precision, AP)和平均精度均值(mean Average Precision, mAP)^[24]。AP 是一种可以用来度量模型预测框类别和位置是否准确的指标,AP 通过计算每个类别预测框和真实框的 IoU 来判断预测框是否准确预测到了位置信息,同时引用精确度和召回率指标评价预测框的类别是否准确。mAP 是对多个验证集个体求平均 AP 值得到的。

3.3 模型训练细节

文中方法是两阶段的检测方法。深度学习方法中,数据是其基石,模型的训练离不开大量的数据。因此,为了提高模型的泛化能力和鲁棒性,采用了多种混合的数据增强方法,对研究所收集到的数据进行增强,从而使得神经网络具有更好的泛化效果。表 2 列举了不同的数据增强方式所带来的模型增益。其中 AP_{0.5} 表示在训练和测试中使用的阈值,即当预测结果中的检测框与数据标注的真值框的交并比大于 0.5 时,认为其检测到了目标的平均精度。由于网络中使用了全连接层,在训练时还为图片输入设定了固定值,为 600 * 600 像素。实验中,学习率设置为 0.001。

通过实验证明,选取经典的 ResNet101 作为骨干网络。同时,为了加快模型训练速度,使用官方提供的 ImageNet 数据集上的预训练模型进行参数初始化,而不是令参数随机初始化。

表 2 不同数据增强方法的性能对比

数据变换	AP _{0.5} /%	AP _{0.6} /%	AP _{0.7} /%
原始数据	58.6	55.0	52.6
原始+翻转	59.3	56.2	53.3
原始+旋转	59.2	56.3	54.2
原始+裁剪	59.5	56.5	54.6
多种混合的数据增强	60.7	58.2	56.7

3.4 各模块有效性验证的对比实验

文中方法是在 Faster R-CNN 基础上进行的改进和优化。在原本网络中增加了两个模块,进一步提升了原有网络的性能。为了证明所设计的模块的有效性,进行了相关消融实验,并将实验的配置细节和评估结果放在表 3 中。

表 3 各模块的有效性验证结果

Faster R-CNN	FPN	CSA	mAP/%
√			55.1
√	√		58.2
√		√	58.5
√	√	√	60.7

特征金字塔 FPN 是针对小目标检测不好的问题,增加了特征金字塔模块来提升小目标检测的能力。混合注意力 CSA 是针对不同通道在网络中所作的贡献不同,所以引入注意力机制来解决此问题。相对于 baseline,网络性能都能得到一定的提升,当两个模块都添加到网络中时,网络性能提升得最大。

3.5 与现有检测方法的对比实验

首先将提出的方法与其他经典的目标检测方法在电网施工现场安全工器具数据集上进行对比实验。在 Faster R-CNN^[2]、SSD^[9]、RFBNet^[25]和 YOLOv3^[10]这 4 种经典且有效的方法上的实验结果展示在表 4 中。

表 4 文中方法与现有方法在电网安全工器具数据集上的对比实验

方法	mAP/%
YOLOv3 ^[10]	52.0
SSD ^[9]	52.6
RFBNet ^[25]	51.6
Faster R-CNN ^[2]	55.9
文中方法	60.7

可以发现,文中方法在电网施工现场安全工器具数据集上的性能表现都是略优于其他方法的,较其他算法分别提高了 8.7%、8.1%、9.1%和 4.8%。图 5 直观地展示出文中方法在电网施工现场安全工器具数据集上的实验结果。其中左上角的图片是检测到挂钩与安全绳断股,右上角图片是检测到绝缘手套,第二行图中检测到安全带破损与挂钩情况。




图 5 文中方法在电网安全工器具数据集上的检测结果示例

4 结束语

电网施工及安全检测对于电力工作人员的安全性保护至关重要,因此对安全工器具的正确佩戴和安全工器具是否破损的检测工作是非常必要的。该文提出

一种基于混合注意力网络的安全工器具检测方法。混合注意力网络以经典的 Faster R-CNN 为主干网络。为了侧重比较重要的通道引入了混合注意力模块,包含全局通道注意力和局部空间注意力两个子模块。为了解决部分目标较小的问题引入了特征金字塔模块,采用了基于多尺度特征金字塔的多层预测方法。由于安全工器具的数据集数量较少,引入了多种混叠的数据增强方法,以此提高了检测的准确性。然而,该算法也存在一些不足,对于检测目前还不能满足实时的要求,后面欲通过通道剪枝来去除不重要的通道,从而提高算法的运算速度。

参考文献:

- [1] 冯 筠,邢嘉琪,赵艾琦,等. 人工智能在基础教育教学应用综述[J]. 计算机技术与发展,2021,31(2):1-7.
- [2] 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, 2017, 39(6): 1137-1149.
- [3] GIRSHICK R B, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Proceedings of the IEEE conference on computer vision and pattern recognition(CVPR). Columbus, OH, USA: IEEE, 2014: 580-587.
- [4] UIJLINGS J R R, VAN DE SANDE K E A, GEVERS T, et al. Selective search for object recognition [J]. International Journal of Computer Vision, 2013, 104(2): 154-171.
- [5] GIRSHICK R. Fast R-CNN[C]//Proceedings of the IEEE international conference on computer vision (ICCV). Santiago, Chile: IEEE, 2015: 1440-1448.
- [6] HE K, ZHANG X, REN S, 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.
- [7] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//Proceedings of the IEEE conference on computer vision and pattern recognition(CVPR). Las Vegas, NV, USA: IEEE, 2016: 779-788.
- [8] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector [C]//European conference on computer vision (ECCV). Amsterdam, The Netherlands: Springer, 2016.
- [9] REDMON J, FARHADI A. Yolov3: an incremental improvement[J]. arXiv:1804.02767, 2018.
- [10] LAW H, DENG J. Cornernet: detecting objects as paired keypoints [C]//Proceedings of the European Conference on Computer Vision (ECCV). Munich, Germany: Springer, 2018: 734-750.
- [11] DUAN K, BAI S, XIE L, et al. CenterNet: keypoint triplets for object detection [C]//CVF international conference on computer vision (ICCV). Seoul, Korea (South): IEEE, 2019: 6568-6577.
- [12] TIAN Zhi, SHEN Chunhua, CHEN Hao, et al. FCOS: fully convolutional one-stage object detection [C]//CVF international conference on computer vision (ICCV). Seoul, Korea (South): IEEE, 2019: 9626-9635.
- [13] 李国良,周焯赫. 面向 AI 的数据管理技术综述[J]. 软件学报, 2021, 32(1): 21-40.
- [14] ARULKUMARAN K, DEISENROTH M P, BRUNDAGE M, et al. A brief survey of deep reinforcement learning[J]. IEEE Signal Processing Magazine, 2017, 34(6): 26-38.
- [15] ZHANG H, CISSE M, DAUPHIN Y N, et al. Mixup: beyond empirical risk minimization[J]. arXiv:1710.09412, 2017.
- [16] 张冰冰,葛疏雨,王旗龙,等. 基于多阶信息融合的行为识别方法研究[J]. 自动化学报, 2021, 47(3): 609-619.
- [17] 余 进,史燕中,王春华,等. 一种轻量化目标检测算法研究[J]. 计算机技术与发展, 2020, 30(11): 42-47.
- [18] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]//Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR). Honolulu, Hawaii: IEEE, 2017: 2117-2125.
- [19] 高洁云,赵逢禹,刘 亚. 基于语义增强的改进混合特征选择的文本分类[J]. 计算机技术与发展, 2021, 31(1): 24-29.
- [20] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]//Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR). Salt Lake: IEEE, 2018: 7132-7141.
- [21] LV Miaomiao, CHEN Sibao, LUO Bin. LSAM: local spatial attention module [M]//3rd Chinese conference on pattern recognition and computer vision (PRCV). Nanjing: [s. n.], 2020: 407-418.
- [22] WOO S, PARK J, LEE J Y, et al. Cbam: convolutional block attention module [C]//Proceedings of the European conference on computer vision (ECCV). Munich, Germany: Springer, 2018: 3-19.
- [23] 陈 鹏,李勇志,余肖生. 基于特征选择模型的钓鱼网站快速识别方法[J]. 计算机技术与发展, 2021, 31(4): 40-45.
- [24] PADILLA R, PASSOS W L, DIAS T, et al. A comparative analysis of object detection metrics with a companion open-source toolkit [J]. Electronics, 2021, 10(3): 279-306.
- [25] LIU Songtao, HUANG Di, WANG Yunhong. Receptive field block net for accurate and fast object detection [C]//Proceedings of the European conference on computer vision (ECCV). Munich, Germany: Springer, 2018: 404-419.