

# 一种实时的道路空车位检测算法

梁明秀, 刘秋会, 王 林

贵州民族大学, 数据科学与信息工程学院, 贵州 贵阳  
Email: 2604911302@qq.com

收稿日期: 2020年11月29日; 录用日期: 2020年12月24日; 发布日期: 2020年12月31日

## 摘 要

道路空车位实时检测是解决城市停车难的一个关键环节, 本文提出了一种改进的faster RCNN深度学习道路空车位检测方法。首先, 利用K-means聚类算法对标注框进行聚类, 以获得适合的空车位形状特征; 然后, 调整区域建议框网络(Regional proposals network)框架, 以便网络提取更多的数据特征; 最后, 利用soft NMS算法提取可能包含目标的框。实验结果表明, 建议的方法对道路空车位的检测结果较好, 在采集的道路空车位检测数据集准确率达到95.3%, 比只用faster RCNN方法提高了2个百分点。

## 关键词

道路停车位, 空车位检测, Faster RCNN, 区域建议框网络

# A Real-Time Road Empty Parking Space Detection Algorithm

Mingxiu Liang, Qihui Liu, Lin Wang

College of Data Science and Information Engineering, Guizhou University for Nationalities, Guiyang Guizhou  
Email: 2604911302@qq.com

Received: Nov. 29<sup>th</sup>, 2020; accepted: Dec. 24<sup>th</sup>, 2020; published: Dec. 31<sup>st</sup>, 2020

## Abstract

The real-time detection of road empty parking spaces is a key link to solve the difficulty of urban parking. This paper proposes an improved faster RCNN deep learning road empty parking space detection method. First, use the K-means clustering algorithm to cluster the labeled boxes to obtain suitable vacant parking space shape features; then, adjust the regional proposal box network (RPN) framework so that the network can extract more data features; finally, use soft The NMS algorithm extracts boxes that may contain targets. The experimental results show that the proposed method has better detection results for road empty parking spaces. The accuracy of the collected road empty parking space detection data set reaches 95.3%, which is 2% higher than the faster RCNN method.

## Keywords

Road Parking Space, Empty Parking Space Detection, Faster RCNN, Regional Proposals Network

Copyright © 2020 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

随着汽车保有量的不断增加,为解决停车难问题,会将部分交通不太繁忙的城市道路旁和其它一些空旷区域划出车位以供停车。但由于没有这些车位是否空闲的信息,车主在寻找空车位时会花费许多时间。因此,如何快速准确地检测道路空车位,成为计算机视觉的一个研究热点。

道路可用空车位检测是智慧交通的一个重要组成部分,一个实时的道路可用空车位检测系统能帮助车主获取离他最近的可用空车位信息。减少车主没有目标的去寻找空车位而浪费时间和燃油的消耗。目前,现有的道路可用空车位检测方法主要有两类。第一类方法是利用地磁传感器、感应涡流车辆检测器、超声波车辆传感器和红外线等进行检测。例如, Lou 等人[1]通过地磁传感器和无线信号强度,设计了基于传感器的空车位检测系统; Srikanth 等人[2]通过无线传感器网络技术,设计了停车管理系统(SPARK)可以远程停车监控,自动导航和停车预约机制; Jo & Jung [3]利用超声波和红外线,设计了小尺度灵敏的感应器检测车辆,主要运用于室内; Zhang 等人[4]通过各向异性磁阻传感器(AMR)的停车占用检测新算法,设计了在路边停车位上部署传感器节点来检测停车位占用情况。第二类方法是利用计算机视觉技术进行检测。例如, Xiang 等人[5]通过结合 haar-like 级联分类器及 VGG16 网络进行服务区空车位检测。Acharya 等人[6]通过智能图像处理设计了利用图像处理的方法提取车位占有情况和车位位置管理空车位; Mane 等人[7]利用卷积神经网络对移动物体监测和跟踪能在不同照明和遮挡下检测物体; Papageorgiou, C.P. 等人[8]介绍目标检测的主要框架; 安旭骁等人[9]提出迷你卷积神经网络(MCNN)的概念通过减少网络参数来减少训练和识别时间,并在网络中加入局部响应归一化层以加强对明度的校正,以及使用小卷积核来获取更多图像细节; Saharan S 等人[10]提出了一种基于占用率的机器学习路边停车收费方案使用基于机器学习的方法来预测停车场的占用率推断到达车辆的占用率驱动价格。但由于城市道路两旁状况的复杂性,通过视频图像来检测空车位的方法还有很多有待研究的问题。

本文针对 He, K.等[11]提出的 faster RCNN 道路空车位检测算法存在范围广,外部环境复杂等问题,提出了改进的 faster RCNN 道路停车位检测算法。利用 k-means 聚类算法对道路空车位数据特征进行聚类,然后,对候选框网络框架实行调整,提取更多的信息,再通过 soft 非极大抑制算法调整筛选候选框机制来实现对空车位的检测。改进的算法比只用 faster RCNN 算法在检测准确率上提升了两个百分点。

## 2. Faster RCNN 网络模型框架

Faster RCNN 算法流程主要有以下:

- a) 将图像输入网络得到相应的特征图;
- b) 使用区域建议框网络生成候选框,将区域建议框网络生成的候选框投影到特征图上获得相应的特征矩阵;
- c) 将每个特征矩阵通过 ROI pooling 层缩放到  $7 \times 7$  大小的特征图,接着将特征图展平通过一系列连接层得到预测特征图。

Faster RCNN 使用一组基础的 Convolution + Relu + pooling 层提取图像的特征图。该特征图被共享用于后续区域建议框网络层和全连接层。区域建议框网络用于生成区域建议框。该层通过 soft max 判断 anchors 属于正样本或者负样本，再利用边界框回归参数修正 anchors 获得精确的候选框。ROI Pooling 该层收集输入的特征图和候选框，综合这些信息后提取候选框特征图，送入后续全连接层判定目标类别。Classification 利用候选框特征图计算候选框的类别，同时通过边界框回归参数获得检测框最终的精确位置，在将最终的检测框映射回原图。

利用标注软件对数据进行标定作为网络的输入数据；特征提取骨干网络主要是提取数据特征利用 resnet50 网络加特征金字塔网络 feature pyramid networks [12]提取更多数据特征，区域建议框网络生成建议框，对生成的建议框进行过滤和选取；感兴趣区域池化将特征矩阵缩放到  $7 \times 7$  大小接着将特征图展平通过一系列连接层得到预测特征图。Faster RCNN 网络模型框架图如图 1 所示。

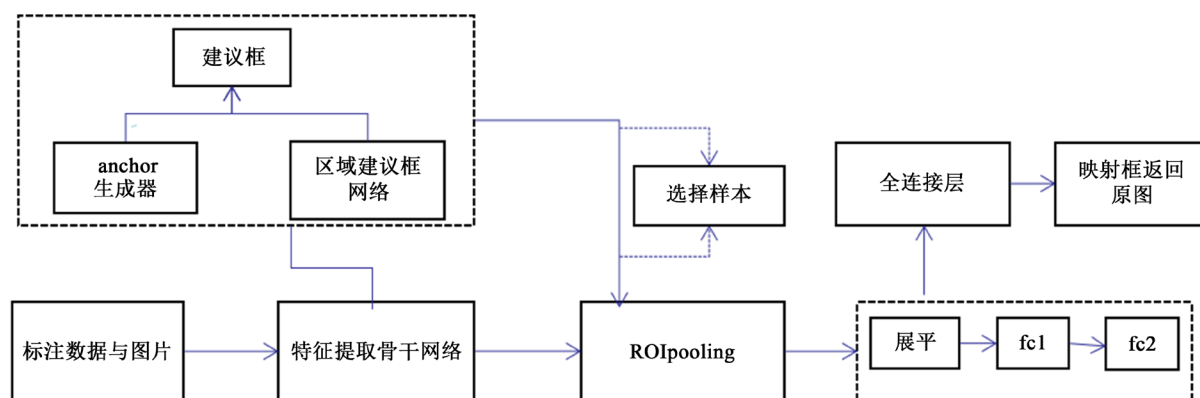


Figure 1. Flow chart of faster RCNN algorithm framework

图 1. Faster RCNN 算法框架流程图

### 3. 道路停车位检测

在基于 faster RCNN 深度学习算法的基础上，利用 K-means 聚类算法对 anchor 维度聚类获取适应道路空车位数据集 anchor 长宽比，通过不同数据集的数据特征生成的 anchor 能自适应调整，生成一系列目标框之后，再用 soft 非极大抑制方法筛选出目标框。

#### 3.1. 区域建议框网络(Regional proposals network)候选框调整

区域候选框网络在预测特征层上设置锚点，铺设三种不同尺度，三种长宽比为 1:1、1:2、2:1，总共生成 9 种不同尺度的 anchor，但对于道路空车位场景下不适用于采用到的公开数据集长宽比。本文采用聚类算法 k-means 对数据原始框长宽比进行聚类，以获得适应本文数据集的 anchor 尺寸。由于远近场景中车辆尺寸的差异较大，本文采用 5 种不同尺寸。在 Faster RCNN 方法中，anchor 都是手动设定的，YOLOv2 [13]使用 k-means 聚类算法对训练集中的边界框做了聚类分析，聚类出建议框的长宽比。如果采用标准的 k-means 聚类，在 box 的尺寸比较大的时候其误差也更大，而我们希望的是误差和 box 的尺寸没有太大关系。所以通过 IOU 定义了如下的距离函数，使得误差和 box 的大小无关：

$$d(\text{box}, \text{centroid}) = 1 - \text{IOU}(\text{box}, \text{centroid}) \quad (1)$$

计算一个 ground truth 边界框和 k 个先验框(Anchor)的交并比(IOU)值。参数 box: 元组或者数据，代表 ground truth 的长宽。参数 clusters: 形如(k, 2)的 numpy 数组，其中 k 是聚类 anchor 框的个数返回: ground truth 和每个 anchor 框的交并比。利用 k-means 聚类算法对原始框的维度进行聚类，以获得适合自己数据

集空车位长宽比, 获得聚类结果 0.5、0.6、0.8。聚类结果效果如表 1 所示。

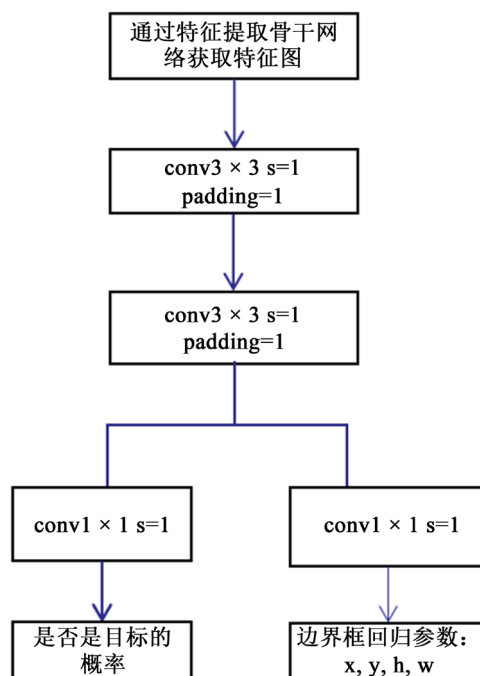
**Table 1.** k-means clustering results

**表 1.** k-means 聚类结果

宽	高	宽高比
0.56	0.064	0.109333
0.59	0.604	0.738738
0.82	0.2	0.3582681

### 3.2. 区域建议框网络(Regional proposals network)框架调整

RPN 主要在原始图像生成候选框, 卷积之后的特征图和原始图像之间有一个映射关系, 在特征图上面找到响应候选框, 代表在原始图像上找到候选框。区域建议框网络是全卷积(full Convolution)网络, 其采用基础网络输出的卷积特征图作为输入。首先, 采用 512 个通道,  $3 \times 3$  kernel 的卷积层, 然后是两个并行的  $1 \times 1$  kernel 的卷积层, 该卷积层的通道数量取决于每个点(每个 anchor)所对应的标准候选框 K 的数量, 在这两个并行的  $1 \times 1$  卷积中, 左侧的是进行分类的, 这里的分类只是分有和无两类, 即候选框中有目标还是没有目标, 至于目标到底是什么先不管, 由于每一个 anchor 对应 k 个候选框, 每一个候选框有两个取值(即有和无, 用概率大小表示)所以每一个 anchor 对应的输出应该为一个  $2K$  维度的向量, 故而左侧的分类卷积使用  $2K$  个通道, 两个通道生成两个值分别是目标和是背景的概率。同样的道理, 右侧是获取边框位置信息的卷积网络, 由于每一个 anchor 对应 k 个候选框, 每一个候选框有 4 个位置取值(x, y, w, h)所以每一个 anchor 对应的输出应该为一个  $4K$  维度的向量, 故而右侧的卷积使用  $4K$  个通道。本文在区域建议网络中添加一层核为  $3 \times 3$ , 步长为 1, padding 为 1 的卷积层, 有助于提取更多的细节特征, 提高准确进度。微调的 RPN 流程图如图 2 所示。



**Figure 2.** Flow chart of fine-tuning RPN

**图 2.** 微调 RPN 的流程图

### 3.3. soft-非极大值抑制

Faster RCNN 在区域候选框网络依照目标置信由大到小度排序(优先提取更可能包含目标的), 并利用非极大值抑制生成 boxes (即非极大值抑制后的 proposal boxes), 物体检测中应用非极大值抑制算法的主要目的是消除多余(交叉重复)的窗口, 找到最佳物体检测位置但非极大值抑制抑制置信度不是最大的框, 会造成误检或漏检, soft 非极大值抑制候选框得分不是最大值直接会减少得分而不是直接删除。

经典的非极大值抑制算法将 IOU 大于阈值的窗口的得分全部置为 0, 可表述如下:

$$s_i = \begin{cases} s_i, & \text{IOU}(m, b_i) < N_t \\ 0, & \text{IOU}(m, b_i) \geq N_t \end{cases} \quad (3)$$

非极大值抑制直接将删除所有 IoU 大于阈值的框, soft 非极大值抑制算法不粗鲁地删除 IOU 大于阈值的框, 而是降低其置信度, 可以明显看到 soft 非极大值抑制最重要是更新权重变量的值。采用线性加权时, 更新为  $1 - \text{IOU}$ , 高斯加权时引入 sigma 参数, 而原始非极大值抑制算法时, 直接取 0 或 1。

$$s_i = \begin{cases} s_i, & \text{IOU}(m, b_i) < N_t \\ s_i(1 - \text{IOU}(m, b_i)), & \text{IOU}(m, b_i) \geq N_t \end{cases} \quad (4)$$

$b_i$  为待处理框,  $s_i$  是  $b_i$  框更新得分,  $N_t$  是非极大值抑制的阈值,  $N_t$  阈值设置为 0.5,  $b_i$  和  $m$  的阈值越大,  $b_i$  得分越高  $s_i$  就下降的越厉害。

## 4. 实验结果与分析

本节主要验证提出的 faster RCNN 在道路停车位检测问题上的有效性。主要讨论道路停车位检测实验设置、实验结果, 所提算法性能分析的对比性。

### 4.1. 实验设置

本文的实验场景是道路空车位检测, 采集的室外场景有白天和晚上的数据总共采集 1168 张图片。不同光照下的道路停车位数据图像如图 3 所示。



Figure 3. Road parking space images under different illumination

图 3. 不同光照下的道路停车位图像

实验环境硬件, 在 windows 操作系统, Intel(R) CPU E5-2698 V4@2.20GHZ, RAM(256GB)处理器, 实验软件采用 python 编程语言, 主要的深度学习框架 Pytorch 进行模型的训练和预测。以上实验环境为基础设置了两组试验。

1) faster RCNN 的特征提取对检测效果有重要的影响, 特征提取骨干网络 Mobilenet、resnet50+FPN、resnet101+FPN 的对比实验, 主要验证选取的 resnet50+FPN 作为网络的特征提取骨干网络有较好的检测效果。

2) faster RCNN 与调整的 faster RCNN 的对比分析, 主要对 anchor 维度聚类, 调整 RPN 网络框架, 调整选取更可能包含物体的机制, 主要验证调整的 faster RCNN 在道路停车位检测的有效性。

为了保证所设置试验中不同算法实验结果的对比性, 本文采用以下定量指标进行评价平均准确率 (AP)、平均召回率 (AR)、均值平均准确率 (Map)。AP 指的 P-R (precision-Recall) 曲线下面积, Map 即各类 AP 的平均值。

$$\text{准确率} = TP / (TP + FP) \qquad \text{召回率} = TP / (TP + FN)$$

TP 是分类器认为是正样本而且确实是正样本的例子, FP 是分类器认为是正样本但实际上不是正样本的例子, Precision 就是“分类器认为是正类并且确实是正类的部分占有所有分类器认为是正类的比例”。FN 是分类器认为是负样本但实际上不是负样本的例子, Recall 是“分类器认为是正类并且确实是正类的部分占有所有确实是正类的比例”。基于这些实验设置, 以下给出对比实验。

### 4.2. 特征提取骨干网络对比分析

本节在特征提取骨干网络中利用 mobilenetv2、resnet50+feature pyramid networks、resnet101+feature pyramid networks 作对比实验, 检测结果中网络提取 resnet101+feature pyramid networks 比 mobilenetv2 效果较好, resnet50+feature pyramid networks 比 resnet101+feature pyramid networks 检测效果较好。则选取 resnet50+FPN 网络作为 faster RCNN 特征提取骨干网络。以下表格是 faster RCNN 特征提取网络对比检测结果。可见 resnet50+FPN 作为特征提取骨干网络检测效果较好。faster RCNN 特征提取网络对比检测结果如表 2 所示。

Table 2. Faster-RCNN feature extraction network comparison experiment

表 2. Faster-RCNN 特征提取网络对比实验

序号	网络	AP	MAP
1	mobilenet	92.3	72.4
2	resnet101+FPN	92.7	73.5
3	resnet50+FPN	93.3	79

### 4.3. 调整的 faster RCNN 算法的实验结果对比分析

为了考察调整的 faster RCNN 与 faster RCNN 算法的有效性, 本节将分别从是否调整 anchor 维度聚类, 是否调整区域建议框网络, 是否调整提取更可能包含目标选择机制三个方面作对比。实验效果图如图 4 所示。



Figure 4. Test results in different environments and lighting

图 4. 不同环境和光照下检测结果图

分析调整的 faster RCNN 与 faster RCNN 算法的有效性, 分别从是否调整 anchor 维度聚类, 是否调整区域建议框网络, 是否调整提取更可能包含目标选择机制三个方面作对比, Faster-RCNN 对比试验评价指标检测效果如表 3 所示。

**Table 3.** Faster-RCNN comparative test evaluation index detection effect

**表 3.** Faster-RCNN 对比试验评价指标检测效果

序号	backbone	anchor	nms	rpn	识别对象	$AP_{iou=0.5}$	$map_{iou=0.5:0.95}$	$AR_{iou=0.5:0.95}^{\max Dets=100}$
1	resnet50+fpn	否	否	否	空车位	93.3	79	83.8
2	resnet50+fpn	是	否	否	空车位	93.4	79.5	84.5
3	resnet50+fpn	否	否	是	空车位	94.3	79.1	84.8
4	resnet50+fpn	是	是	否	空车位	94.2	79.8	84.8
5	resnet50+fpn	是	是	是	空车位	95.3	80.3	85.4

展开分析: backbone 指的是 faster RCNN 特征提取网络, anchor 指的是在特征图上的特征点映射到原图的锚框, 非极大值抑制(nms), 区域候选框网络(RPN),  $AP$  指  $iou = 0.5$  时候的平均精确度,  $AP$  值指的是精确度与召回率曲线下方围成的面积,  $map_{iou=0.5:0.95}$  指  $iou = 0.5$  到 0.95 的均值平均精确  $AR_{iou=0.5:0.95}^{\max Dets=100}$  指  $iou = 0.5$  到 0.95 和最多目标个数为 100 的平均召回率。以 resnet50+FPN 作为特征提取网络平均准确率 ( $AP$ )、均值平均准确率 ( $MAP$ )、平均召回率 ( $AR$ ) 值分别为 93.3、79、83.8。基于调整的 faster RCNN 算法利用 resnet50+FPN 网络特征提取, 主要工作包括利用 K-means 聚类算法对 anchor 维度聚类获取适应道路空车位数据集 anchor 长宽比, 调整区域建议框网络获取更多的数据特征, 利用 soft 非极大抑制算法提取更可能包含目标。试验结果表明, 调整的 faster RCNN 与 faster RCNN 相比在检测道路空车位有显著优势。

## 5. 小结

由于汽车保有量逐年增加, 现有的室内和室外的停车场已不能满足人民的需要, 由于地理位置的特殊, 在路边或者道路边划出一定的区域以供停车, 以此来解决停车难停车费时的问题。因此道路的空车位检测已成为越来越热门的技术问题。本文基于 faster RCNN 检测算法来检测空车位, 主要的工作有:

1) 本文利用自己采集的街道车位作为检测数据集, 根据数据集的差异性本文利用聚类算法对 anchor 的长宽比进行聚类, 以获得适合自己数据集空车位的一般尺寸和长宽比。

2) 本文对区域建议框网络框架进行微调, 增加一层核为  $3 \times 3$ , 步长为 1, padding 为 1 的卷积层, 促使网络提取更多的数据特征。

3) 在候选框的选取计算有目标的 anchor 并进行框回归生成建议框然后依目标置信由大到小度排序 (优先提取更可能包含目标的框的), 非极大抑制算法生成 boxes 时直接将重叠区域大的置为 0, 会造成漏检的情况, 本文利用 soft 非极大抑制算法提取更可能包含目标的框。调整的 faster RCNN 算法与 faster RCNN 算法对比分析实验中, 道路停车位的平均准确率达到 95.3%, 均值平均准确率达到 80.3%, 平均召回率达到 85.4%, 对比 faster RCNN 算法在平均准确率、均值平均准确率、平均召回率评价指标分别提升了 2%, 1.3%, 1.6%。本算法在自建数据集检测效果都较高, 但在小尺寸的停车位检测效果不是很明显, 接下来将小尺寸的停车位放入数据集并提升算法的检测精度。

## 参考文献

- [1] Lou, L., Zhang, J., Xiong, Y. and Jin, Y. (2019) An Improved Roadside Parking Space Occupancy Detection Method

- Based on Magnetic Sensors and Wireless Signal Strength. *Sensors*, **19**, 2348. <https://doi.org/10.3390/s19102348>
- [2] Srikanth, S.V., Pramod, P.J., Dileep, K.P., *et al.* (2009) Design and Implementation of a Prototype Smart Parking (SPARK) System Using Wireless Sensor Networks. *International Conference on Advanced Information Networking and Applications Workshops*, Bradford, 401-406. <https://doi.org/10.1109/WAINA.2009.53>
- [3] Jo, Y. and Jung, I. (2014) Analysis of Vehicle Detection with WSN-Based Ultrasonic Sensors. *Sensors*, **14**, 14050-14069. <https://doi.org/10.3390/s140814050>
- [4] Zhang, Z., Tao, M. and Yuan, H. (2014) A Parking Occupancy Detection Algorithm Based on AMR Sensor. *IEEE Sensors Journal*, **15**, 1261-1269. <https://doi.org/10.1109/JSEN.2014.2362122>
- [5] Xiang, X., Lv, N., Zhai, M. and El Saddik, A. (2017) Real-Time Parking Occupancy Detection for Gas Stations Based on Haar-Ada Boosting and CNN. *IEEE Sensors Journal*, **17**, 6360-6367. <https://doi.org/10.1109/JSEN.2017.2741722>
- [6] Acharya, D., Yan, W. and Khoshelham, K. (2018) Real-Time Image-Based Parking Occupancy Detection Using Deep Learning. *Proceedings of the 5th Annual Research@Locate Conference*, Adelaide, 9-11 April 2018, 33-40.
- [7] Mane, S. and Mangale, S. (2019) Moving Object Detection and Tracking Using Convolutional Neural Networks. 2018 *Second International Conference on Intelligent Computing and Control Systems (ICICCS)*, Madurai, 1809-1813. <https://doi.org/10.1109/ICCONS.2018.8662921>
- [8] Papageorgiou, C.P., Oren, M. and Poggio, T. (2002) A General Framework for Object Detection. *International Conference on Computer Vision*, Bombay, 6 August 2002, 555-562.
- [9] 安旭骁, 邓洪敏, 史兴宇. 基于迷你卷积神经网络的停车场空车位检测方法[J]. *计算机应用*, 2018, 38(4): 935-938.
- [10] Saharan, S., Kumar, N. and Bawa, S. (2020) An Efficient Smart Parking Pricing System for Smart City Environment: A Machine-Learning Based Approach. *Future Generation Computer Systems*, **106**, 622-640. <https://doi.org/10.1016/j.future.2020.01.031>
- [11] Ren, S., He, K., Girshick, R., *et al.* (2017) Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, **39**, 1137-1149. <https://doi.org/10.1109/TPAMI.2016.2577031>
- [12] Lin, T.Y., Dollár, P., Girshick, R., *et al.* (2016) Feature Pyramid Networks for Object Detection. 2017 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, 936-944. <https://doi.org/10.1109/CVPR.2017.106>
- [13] Redmon, J. and Farhadi, A. (2017) YOLO9000: Better, Faster, Stronger. *IEEE Conference on Computer Vision & Pattern Recognition*, Honolulu, HI, 6517-6525. <https://doi.org/10.1109/CVPR.2017.690>