

doi: 10.7690/bgzdh.2021.06.012

基于卷积神经网络的人脸检测综述

刘晓军¹, 类成玉², 张晓玲¹, 刘珂宇³(1. 中国石油大学胜利学院机械与控制工程学院, 山东 东营 257061; 2. 山东大学控制科学与工程学院, 济南 250061;
3. 广西科技大学国际教育学院, 广西 柳州 545006)

摘要: 为更好地了解和研究基于卷积神经网络(convolutional neural networks, CNN)的人脸检测, 从低图像质量人脸检测和人脸检测系统的性能优化2方面, 分析人脸检测所面临的困难并给出其解决方案, 总结2015年以来基于卷积神经网络的人脸检测技术的发展进程和方向, 对人脸检测任务中的遮挡、尺度、小面部集群、速度、精度以及多任务RPN(multi-task region proposal network)人脸检测等方面进行总结陈述, 对未来基于卷积神经网络人脸检测的发展趋势进行预测。

关键词: 计算机视觉; 人脸检测; 深度学习; 卷积神经网络

中图分类号: TP242 **文献标志码:** A

Face Detection Survey Based on Convolutional Neural Network

Liu Xiaojun¹, Lei Chengyu², Zhang Xiaoling¹, Liu Keyu³(1. School of Mechanical & Control Engineering, Shengli College, China University of Petroleum, Dongying 257061, China;
2. School of Control Science & Engineering, Shandong University, Ji'nan 250061, China;
3. College of International Education, Guangxi University of Science & Technology, Liuzhou 545006, China)

Abstract: In order to better understand and research the face detection based on convolutional neural network(CNN), this paper analyzed the main difficulties faced by face detection and its solution in low image quality face detection and the performance optimization of face detection system. This paper summarizes the development process and direction of face detection technology based on convolutional neural network since 2015. It covers occlusion, scale, small face cluster, speed, precision, and multi-task region proposal network face detection in face detection tasks. A summary statement is made to predict the future development of face detection based on convolutional neural networks.

Keywords: computer vision; face detection; deep learning; convolutional neural network

0 引言

人脸检测是计算机视觉领域的一个重要分支, 是分析人脸信息的第一步, 涉及身份认证、人机交互、安防监控以及社交等方面。随着人脸检测的广泛应用, 无约束条件下的人脸检测受到重视并作为独立课题进行研究。如何在非约束环境下提高召回率和降低检测时间是人脸检测面临的主要任务。

近年来, 随着研究的深入, 基于卷积神经网络(CNN)的人脸检测表现得越来越优异。基于卷积神经网络的人脸检测最早可以追溯到1994年^[1], 随着卷积神经网络的深入研究, 基于卷积神经网络的人脸检测取得了很好的检测结果。级联卷积神经网络^[2]结构通过由粗到细的策略, 在早期淘汰大量的非人脸区域; 多任务卷积神经网络(multi-task convolutional neural networks, MTCNN)^[3]训练了一个多任务框架用于人脸检测和人脸对齐; UnitBox^[4]、Grid Loss^[5]等方法采用新的损失函数用

于提升性能。人脸检测可以看作是目标检测的单一任务, 一些目标检测框架只需稍作改进便可用于人脸检测, 例如R-CNN^[6-8]、SSD^[9]、YOLO^[10]和Focal Loss^[11]。基于CNN的人脸检测器取得了比传统方法更好的性能, 也为以后的方法提供了新的基准。

卷积神经网络表现优异, 在人脸检测领域, 基于卷积神经网络的方法独占鳌头, CVPR、ECCV、ICCV等国际顶尖计算机视觉会议每年都有大量基于卷积神经网络的人脸检测相关的论文发表。笔者对基于卷积神经网络的人脸检测技术的发展进程和方向进行综合分析。

1 低图像质量人脸检测

口罩、墨镜和发型等都是实际存在且无法避免的人脸遮挡, 因此, 一个成熟的人脸检测系统必须具备解决面部遮挡的能力, 遮挡人脸检测面临的主要问题是遮挡区域特征缺失和遮挡面部数据集匮

收稿日期: 2021-02-15; 修回日期: 2021-03-28

基金项目: 山东省本科高校教学改革研究项目(C2016M076)

作者简介: 刘晓军(1969—), 男, 山东人, 硕士, 高级实验师, 从事传感器技术、供配电技术研究。E-mail: 1274932468@qq.com。

乏。小面部检测和尺度不变的检测在一定程度上具有重合。建立图像金字塔和将 CNN 模型拟合到多尺度的方法会增大 CNN 的计算量, 减缓 CNN 的速度, M.NAJIBI 等^[12]提出的无头单阶段(single stage headless, SSH) 检测器通过独特的设计避免了图像金字塔的建立是一种解决尺度变化的新思路。小面部检测具有更大的挑战, 利用人脸的相关信息建立新的模型是扩展小面部检测可用特征的新思路和有效方法^[13]。

1.1 遮挡人脸

在进行人脸检测时无法避免遮挡。遮挡的任意性会导致被遮挡的人脸具有各种各样的变化特征, 给 CNN 带来巨大的计算量, 同时需要大量的训练数据。由于人脸遮挡区域特征的缺失和遮挡面部数据集的匮乏^[14], 使得遮挡变成了人脸检测任务的一大挑战。目前针对遮挡问题的人脸检测也多是从面临的问题出发, 其中采用人脸面部特征分块^[5]和创建数据集^[14]的方式, 取得了良好的效果。

Opitz 等^[5]定义了一种新的损失函数 Grid Loss:

$$l(\theta) = \max(0, 1 - y \cdot \omega^T x + b) + \lambda \cdot \sum_{i=1}^N \max(0, m - y \cdot \omega_i^T f_i + b_i). \quad (1)$$

其中: ω 和 b 是连接参数; λ 是对单个部分检测器与整体检测器进行加权, 在该实验中设置为 1。该方法优于常规 CNNs, 适用于实时应用。Ge SH M 等^[14]建立了遮挡人脸数据库 MAFA, 并提出 CNN 网络 LLE-CNNs 用于遮挡人脸检测, LLE-CNNs 引入嵌入模块实现对被遮挡的人脸特征恢复, 抑制噪声; 验证模块利用被修复的人脸特征进行人脸区域验证, 微调人脸位置和尺度。

除上述方法, Tang X 等^[13]通过学习人脸相关特征辅助检测, 对部分遮挡的人脸具有一定的鲁棒性; S.S.FARFADE 等^[15]提出的基于 AlexNet 网络的深度卷积神经网络模型(deep convolutional neural networks, DCNN)也可很好地检测部分遮挡的人脸。王成济等^[16]通过加权降低得分的方法降低了遮挡造成相邻人脸漏检的概率。

1.2 尺度变化

在一些视频监控等实际应用中, 都需要检测不同尺度的人脸, 因此在各种人脸检测的系统设计时, 都需要考虑尺度不变性, 很难使用单一网络进行不同尺度的人脸检测, 因为从 300 像素值大小的人脸

上提取到的特征和在 3 像素值大小的人脸上提取的特征是具有极大差异^[17]。为了鲁棒姿态、表情以及背景遮挡, 需要更多的卷积层来学习具有代表性的特征, 但是用于检测小脸的空间信息却会因过多的池化和卷积操作而丢失^[18]。解决尺度不变性多采用 2 种方法: 1) 使用图像金字塔进行多尺度测试, 但是会带来大量的计算负担; 2) 将 CNN 模型拟合到多尺度, 但是会使模型增大、计算量增加。高额的计算代价并不适合实际应用系统, 因此, 设计计算量小的算法就变得尤为关键。

Hao Z 等^[19]提出了有尺度意识的人脸检测(scale-aware face detection, SAFD)来处理尺度问题。Yang SH^[18]等针对不同尺度的人脸采用不同的网络结构, 将这些离散网络整合成一个网络, 使用端对端的方式优化学习。该算法通过模型压缩, 可以提高检测速度。周安众等^[20]则是在卷积神经网络的不同层提取不同尺度的特征形式建立多尺度人脸检测模型; 得益于物品检测算法的发展, 基于物品检测算法尺度不变的人脸检测器也实现了良好的尺度不变性, 但不同的算法其处理方式不尽相同, 基于 Faster R-CNN^[8,21]和 R-FCN^[22]算法的人脸检测器通过在较高层的 ROI pooling maps 上提取特征并训练检测器; 基于 SSD^[19]物品检测框架的人脸检测算法则是在不同的卷积层中利用多尺度的特征映射训练尺度不变的人脸检测器。

1.3 小面部集群

人脸检测已经取得了突破性进展和显著成果, 但是针对小脸的检测依然是一个开放性的挑战。目前小脸检测主要面临以下困难: 1) 在尺度不变性的情况下对小脸的检测率依然较低; 2) 多人脸时的人脸重叠大大减少了小脸的可用特征; 3) 低分辨率和复杂的背景等。由于检测小面部的空间信息特征会因过多的池化和卷积操作而丢失, 通过对 anchor 的合理调整和人脸相关信息的有效利用, 可以提高小脸的检测结果。

Hu P Y 等^[17]针对不同的尺度训练分离的检测器并辅以相关信息提高小脸的检测结果。Zhang S F 等^[23]提出了一种基于单一神经网络的多尺度人脸实时检测方法, 通过尺度补偿锚匹配策略和最大化标签来提高小脸的召回率和减少假正率。Tang X 等^[13]提出的 PyramidBox 利用相关信息和 Data-anchor-sampling 策略加强小面部检测。

Deep-IR^[24]通过提取底层卷积层的特征训练小面部检测器解决高卷积层中背景与小面部混淆的问题, S³FD^[23]和 FaceBoxes^[25]通过改善匹配策略与 anchor 密度以检测小面部群, 而 Scaleface^[18]和 HR-ER^[17]则是分配特定尺度的卷积层训练小面部检测器。

2 人脸检测系统的性能优化

一个通用型的人脸检测系统并不能仅针对单一问题, 必须对所有可能出现的情况都具备一定的鲁棒性, 对单一问题的深入研究也是为了更好地解决这个问题。传统的 Boosting 方法和卷积神经网络在速度和精度上分别具有各自的优势, 将传统方法与卷积神经网络的有效结合是解决速度和精度的有效方法。多任务人脸检测可以利用不同人物间的协同作用辅助人脸检测, 但计算量是面临的难题。

2.1 速度优化

基于 CNN 的人脸检测可以轻松达到优于传统方法的准确率, 但是相较于传统的 Boosting 方法, 在速度方面劣势明显。时下的热门应用机器人、视频监控等系统的运算能力有限, 在实时运行时无法承受庞大的计算量, 因此若要 CNN 实用化, 必须要解决人脸检测系统的运行速度, 这也使得速度问题变成研究人员关注的热点问题。

结合传统方法是提高速度的有效方法^[26], 优势互补, 在保证相对准确率的同时提高人脸检测系统的实时性能。Li H X 等^[2]提出的 Cascade CNN 是 V-J 结构和卷积神经网络结合的代表, 该算法是当时基于 CNN 中运算速度最快, 且在一定程度上鲁棒光照和角度变化, 但是该框架的第一级是基于密集滑动窗口的方式进行窗口过滤, 在高分辨率且存在大量小人脸的图像上限制了算法的性能上限。Qin H W 等^[3]提出了基于 Cascaded CNN 进行改进的 JTCCNN。JTCCNN 使用 BP 算法进行联合训练, 后面的网络会包含前面的网络, 卷积层在不同的阶段共享, 级联的概念体现在网络内部。

研究者还对卷积神经网络的级联思想进行了调整和改进。I.KALINOVSKII 等^[27]提出了一种基于紧凑卷积神经网络级联的人脸检测方法。该算法舍弃了 CNN 中参数较多的全连接层。由于 CNN 的改造和简单的级联结构, 该网络的速度十分理想, 但是精度相对较低, 且只能用来检测正面脸部。Zhang K P 等^[28]将级联思想运用到 CNN 的不同网络层。该

算法将简单人脸检测任务和复杂人脸检测任务分别在 CNN 网络的前几层和后面的部分完成, 通过这种策略快速排除简单非人脸区域, 加快检测速度。

除了级联结构的使用, 科研人员通过对 CNN 的改造和独特设计也实现了速度的大幅提升。Zhang SH F 等^[25]提出了运行在 CPU 上的面部检测器 FaceBoxes, FaceBoxes 由快速消化卷积层 (rapidly digested convolutional layers, RDCL) 和多尺度卷积层 (multiple scale convolutional layers, MSCL) 构成。RDCL 使得 FaceBoxes 在 CPU 上实现实时的速度; 而 MSCL 在不同层上丰富感受野 (receptive field) 和离散化 (anchor), 以便处理不同尺度的面部。

M.NAJIBI 等^[12]设计了 SSH 人脸检测器。SSH 直接从分类网络中的早期卷积层的单个阶段中检测人脸, 速度的优化设计体现在 3 个方面: 1) 消除含有大量参数的全连接层; 2) 通过独特的设计替代图像金字塔实现多尺度的人脸检测同时大大提高了速度; 3) 在网络的单个正向通道的不同层中检测具有不同比例的人脸。

2.2 强鲁棒性人脸检测

显然, 只解决人脸检测任务中的单一问题在实际应用中是不够的, 只有完善的高鲁棒性的系统才具有普遍实用价值。

S.S.FARFADE 等^[15]提出基于 AlexNet 网络的深度卷积神经网络模型 (DCNN)。他们利用深度卷积神经网络的高容量进行分类和特征提取, 学习用于检测多角度人脸的单分类器, 去除 SVM 分类器和边界框回归模块最小化计算复杂度。该算法可以很好的检测多角度、部分遮挡和光照影响的人脸, 并通过缩放图像来检测不同尺度的人脸, 重构全连接层的思想使 DCNN 可以接受任意尺寸的图像输入。

Li Y ZH 等^[29]提出了一种基于 Faster R-CNN 卷积网络与 3D 模型结合起来的端对端的基于面部关键点的人脸检测框架。本文中框架对 Faster R-CNN 做了 2 点修改: 1) 在 PRN 中用 3D 平均人脸模型代替预定义的 anchor boxes; 2) 根据人脸结构信息用一个组态池化层代替 ROI 池化层。

Chen D 等^[30]提出了一种级联卷积神经网络来解决大范围姿态变化问题。STN (supervised transformer network) 第 1 阶段使用多任务 RPN 预测候选人脸区域并进行关键点标注; 第 2 阶段由 R-CNN 利用拼接特征对候选区域分类。STN 引入 supervised transformer 层对候选窗口进行矫正, 利

用 Non-top K 的抑制策略提高召回率的同时保证精度, 使用 ROI 卷积策略只对人脸区域计算以加速运算; 但该方法存在明显缺点, 无法在原始图像上实现实时性能。

Yang S 等^[31]提出的 Faceness-Net 网络是一个典型的由粗到精的工作流。该检测系统分为 2 个阶段: 1) 根据 attribute-aware 深度网络生成人脸部件映射图(partness map), 通过对这些组件的结合计算人脸的置信度, 然后对人脸进行重新排序; 2) 训练一个人脸分类和边界回归的 CNN, 进一步提高召回率。Faceness-Net 通过参数共享降低了 83% 的网络参数, 大大加快了网络运行速度, 而且在同一网络中实现了多任务。

Wang Y T 等^[22]提出全卷积网络的区域人脸检测器 Face R-FCN, 利用位置敏感平均池(position-sensitive average pooling)、多尺度训练和测试(multi-scale training and testing)以及在线硬示例挖掘策略(on-line hard example mining strategy)等新技术来提高检测精度。

刘英剑等^[32]将 Edge Boxes 算法和卷积神经网络结合, 加强了对遮挡、光照和旋转等因素的鲁棒性。吴素雯等^[33]利用选择性搜索策略筛选候选窗口, 结合 Gabor 核优化的卷积神经网络对非约束环境下的光照变化和多姿态问题具有较好的鲁棒性, 在 LFW(labeled faces in the wild) 人脸数据集上取得了较好效果。王成济等^[16]通过特征融合的方法加强了在姿态、光照和尺度等因素下的人脸检测精度。

2.3 多任务人脸检测

多任务人脸检测是指在完成人脸检测任务的同时进行人脸对齐、姿态估计以及性别识别等任务。多任务人脸检测可以利用各任务之间的内在联系和协同作用提高人脸检测的效果^[34]。虽然多任务人脸检测会在一定程度上增加运算的复杂度, 但是在某些需要多任务的特定应用很有借鉴意义。

Zhang K P 等^[35]提出了一个深度级联的多任务框架(MTCNN), 利用检测与对齐之间的固有属性来提升性能。MTCNN 由 PNet、RNet 和 ONet 3 部分构成。图中, MP 表示最大值池化, Conv 表示卷积, 卷积和池化的步长分别为 1 和 2。与 Cascade CNN 相比, 第 1 阶段的 PNet 网络为全卷积网络(FCN), 可以输入任意尺寸的图像, 同时使用卷积运算代替滑动窗口运算, 大大提高了效率。此外, MTCNN 还增加了人脸 5 个关键点的回归任务, 在

校正阶段采用了真实坐标的偏移量。

R.RANJAN 等^[36]提出了基于 deep dense face detector 的 HyperFace 算法, 可同时用于人脸检测、地标定位、姿态估计和性别识别。HyperFace 使用分离 CNN 对 DCNN 的中间层进行融合, 随后应用多任务学习算法, 对融合特征进行操作。后处理时提出迭代区域选择和基于关键点的 NMS 算法有效的提升性能。此外还提出了 2 种可以显著提升性能的变体。HyperFace 利用多任务学习同时完成 4 项人脸检测任务, 但是计算机运算代价较大, 运行速度很慢。

3 人脸检测算法表现

笔者从人脸检测系统实际应用中亟待解决的问题入手, 针对低图像质量人脸检测和人脸检测系统的性能优化 2 方面, 对人脸检测任务中的遮挡、尺度、小面部集群、速度、精度以及多任务人脸检测等方面进行了综述。表 1 是部分人脸检测算法在 FDDB^[37]上的表现, 其中 CS 表示 continue score, DS 表示 discrete score, FP 表示 false positive; 表 2 是部分人脸检测算法在 WIDER FACE^[38]上的表现; 表 3 是部分人脸检测算法的速度表现。

表 1 人脸检测算法在 FDDB 上的表现

算法	CS	DS	FP
SA-RPN ^[19]	--	0.938	1 000
ScaleFace ^[18]	--	0.960	2 000
S ³ FD ^[23]	0.856	0.983	1 000
PyramidBox ^[13]	0.860	0.987	1 000
Cascade CNN ^[2]	--	0.857	1 000
CasCNN ^[3]	--	0.872	1 000
ICC-CNN ^[28]	--	0.971	2 000
DDFD ^[15]	--	0.840	1 000
Conv3D ^[29]	0.767	0.912	2 000
Faceness-Net-SR-RP ^[31]	0.744	0.928	2 000
Face R-FCN (model-B) ^[22]	0.760	0.994	2 000
MTCNN ^[35]	--	0.950	2 000
HyperFace ^[36]	--	0.901	1 000

表 2 人脸检测算法在 WIDER FACE 上的表现

算法	Easy	Middle	Hard
ScaleFace ^[18]	0.867	0.866	0.764
Tiny Faces ^[17]	0.919	0.908	0.823
S ³ FD ^[23]	0.937	0.924	0.852
PyramidBox ^[13]	0.956	0.946	0.887
Faceness-Net-SR-RP ^[31]	0.717	0.615	0.305
Face R-FCN ^[22]	0.943	0.931	0.876
MTCNN ^[35]	0.851	0.820	0.607

表 3 人脸检测算法的速度表现

算法	Speed/fps	备注
S ³ FD ^[23]	36	Titan X (Pascal) and cuDNN v5.1
Cascade CNN ^[2]	100	GPU for VGA-resolution images
CasCNN ^[3]	10	single CPU core on FDDB
C-CNN Cascade ^[27]	27	4K Ultra HD video stream
ICC-CNN ^[28]	40	GPU for VGA-resolution images
MTCNN ^[35]	99	Nvidia Titan Black 640 × 480 VGA images

4 结束语

笔者在系统分析 2015 年以来基于卷积神经网络的人脸检测相关文献后,总结了基于卷积神经网络人脸检测的研究现状和发展方向。自 V-J 结构提出以来,人脸检测得以迅速发展,近年来基于卷积神经网络的人脸检测更是取得了良好效果;但是人脸检测所面临的问题依然存在,随意变换的复杂背景、千奇百怪的人脸遮挡、变幻莫测光照条件、变化无方的姿态和表情、不同的分辨率以及 CNN 带来的运行速度问题,各种各样的内外因素使得人脸模式千变万化,目前依然没有对所有问题都具有高鲁棒性的系统存在。基于卷积神经网络的人脸检测在 FDDB^[37] 和 WIDER FACE^[38] 等高难度的数据集上已经趋近饱和,但是计算代价依然巨大。在今后的研究中,加快检测速度的同时鲁棒小面部和低图像质量的人脸检测会成为研究的重心,研究结果也会更加贴近实际应用。需在以下方面进行深入研究:

1) 优化网络结构。随着对卷积神经网络理论分析的推进,研究如何更好地减少和调整网络参数,如何在保持检测效果的情况下简化网络结构,以期达到加速收敛和运行的目的。另外,还可以通过研究中间层的特征提取和信息损失优化特征的提取及舍弃。

2) 传统方法和卷积神经网络结合。传统的 Boosting 方法具有速度上的优势,而卷积神经网络可以达到很高的精度,通过传统方法和卷积神经网络的有机结合达到检测的高速度和高精度。

3) 辅助手段检测复杂人脸。通过辅助手段来解决人脸检测中高遮挡率、低分辨率以及复杂背景等高检测难度的问题是一个有效的方向,例如 benchmark、人脸对齐等方法的应用提高了人脸检测的效率和精度。

4) 优化训练样本选择算法。在某些应用下,训练样本的选择可以直接决定模型的好坏,在海量的样本中选择有效的训练样本(尤其是负样本更加复杂多变)是优化模型的重要环节,OHEM 策略的引入便起到了重要作用。

参考文献:

- [1] VAILLANT R, MONROCQ C, CUN Y L. Original approach for the localisation of objects in images[J]. Vision, Image and Signal Processing, IEE Proceedings, 1994, 141(4): 245–250.
- [2] LI H X, LIN Z, SHEN X H, et al. A convolutional neural network cascade for face detection[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2015. Boston, MA, USA: IEEE Computer Society, 2015: 5325–5334.
- [3] QIN H W, YAN J J, LI X, et al. Joint Training of Cascaded CNN for Face Detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2016. Las Vegas, NV, USA: IEEE Computer Society, 2016: 3456–3465.
- [4] YU J H, JIANG Y N, WANG Z Y, et al. UnitBox: An Advanced Object Detection Network[C]//Proceedings of the 2016 ACM Conference on Multimedia Conference, MM 2016. Amsterdam, The Netherlands: ACM, 2016: 516–520.
- [5] OPITZ M, WALTNER G, POIER G, et al. Grid Loss: Detecting Occluded Faces[C]//Computer Vision-ECCV 2016-14th European Conference. Amsterdam, The Netherlands: Springer, 2016: 386–402.
- [6] GIRSHICK R, DONAHUE J, DARRELL T, et al. Region-Based Convolutional Networks for Accurate Object Detection and Segmentation[J]. IEEE Trans Pattern Anal Mach Intell, 2016, 38(1): 142–158.
- [7] GIRSHICK R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision, ICCV 2015. Santiago, Chile: IEEE Computer Society, 2015: 1440–1448.
- [8] REN S M, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[C]//2015 International Conference on Neural Information Processing Systems, ICONIP 2015. Istanbul, Turkey: Springer, 2015: 91–99.
- [9] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single Shot MultiBox Detector[C]//Computer Vision-ECCV 2016-14th European Conference. Amsterdam, The Netherlands: Springer, 2016: 21–37.
- [10] 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, CVPR 2016. Las Vegas, NV, USA: IEEE Computer Society, 2016: 779–788.
- [11] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017(99): 2999–3007.
- [12] NAJIBI M, SAMANGOUEI P, CHELLAPPA R, et al. SSH: Single Stage Headless Face Detector[C]//2017 IEEE International Conference on Computer Vision, ICCV 2017. Venice, Italy: IEEE Computer Society, 2017: 4885–4894.
- [13] TANG X, DU D K, HE Z Q, et al. PyramidBox: A Context-assisted Single Shot Face Detector[C]//15th European Conference on Computer Vision. Munich, Germany: Springer, 2018: 812–828.
- [14] GE SH M, LI J, YE Q T, et al. Detecting Masked Faces in the Wild with LLE-CNNs[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017. Honolulu, HI, USA: IEEE Computer Society, 2017: 426–434.
- [15] FARFADE S S, SABERIAN M, LI L J. Multi-view Face

- Detection Using Deep Convolutional Neural Networks[C]//Proceedings of the 5th ACM on International Conference on Multimedia Retrieval, 2015. Shanghai, China: ACM, 2015: 643–650.
- [16] 王成济, 罗志明, 钟准, 等. 一种多层特征融合的人脸检测方法[J]. 智能系统学报, 2018, 13(1): 138–146.
- [17] HU P Y, RAMANAN D. Finding Tiny Faces[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017. Honolulu, HI, USA: IEEE Computer Society, 2017: 1522–1530.
- [18] YANG S H, XIONG Y J, LOY C C, et al. Face Detection through Scale-Friendly Deep Convolutional Networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017, Honolulu, HI, USA. IEEE Computer Society 2017, CoRR abs/1706.02863.
- [19] HAO Z, LIU Y, QIN H, et al. Scale-Aware Face Detection[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017. Honolulu, HI, USA: IEEE Computer Society, 2017: 1913–1922.
- [20] 周安众, 罗可. 一种多尺度卷积神经网络的人脸检测模型[J]. 计算机工程与应用, 2018, 54(14): 168–174.
- [21] JIANG H, LEARNED-MILLER E. Face Detection with the Faster R-CNN[C]//IEEE International Conference on Automatic Face & Gesture Recognition. IEEE, 2017: 650–657.
- [22] WANG Y T, JI X, ZHOU Z, et al. Detecting Faces Using Region-based Fully Convolutional Networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA: IEEE Computer Society, CoRR abs/1709.05256.
- [23] ZHANG SH F, ZHU X Y, LEI Z, et al. S³FD: Single Shot Scale-Invariant Face Detector[C]//2017 IEEE International Conference on Computer Vision, ICCV 2017. Venice, Italy: IEEE Computer Society, 2017: 192–201.
- [24] SUN X D, WU P C, HOI S. Face Detection using Deep Learning: An Improved Faster RCNN Approach[J]. Neurocomputing, 2018, 299(1): 42–50.
- [25] ZHANG SH F, ZHU X Y, LEI Z, et al. FaceBoxes: A CPU Real-time Face Detector with High Accuracy[C]//2017 IEEE International Joint Conference on Biometrics, IJCB 2017. Denver, CO, USA: IEEE, 2017: 1–9.
- [26] 孙康, 李千目, 李德强. 基于级联卷积神经网络的人脸检测算法[J]. 南京理工大学学报, 2018, 42(1): 40–47.
- [27] KALINOVSKII I, SPITSYN V. Compact Convolutional Neural Network Cascade for Face Detection[J]. Computer Science, 2015, 2(2): 110–120.
- [28] ZHANG K P, ZHANG Z P, WANG H, et al. Detecting Faces Using Inside Cascaded Contextual CNN[C]//2017 IEEE International Conference on Computer Vision, ICCV 2017. Venice, Italy: IEEE Computer Society, 2017: 3190–3198.
- [29] LI Y Z, SUN B Y, WU T F, et al. Face Detection with End-to-End Integration of a ConvNet and a 3D Model[C]//Computer Vision–ECCV 2016. Amsterdam, The Netherlands: Springer International Publishing, 2016: 420–436.
- [30] CHEN D, HUA G, WEN F, et al. Supervised Transformer Network for Efficient Face Detection[C]// Computer Vision-ECCV 2016-14th European Conference. Amsterdam, The Netherlands: Springer, 2016: 122–138.
- [31] YANG S, LUO P, LOY C C, et al. Faceness-Net: Face Detection through Deep Facial Part Responses[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 40(8):1845–1859.
- [32] 刘英剑, 张起贵. 基于 Edge Boxes 和深度学习的非限制条件下人脸检测[J]. 现代电子技术, 2018, 41(13): 29–33.
- [33] 吴素雯, 战荫伟. 基于选择性搜索和卷积神经网络的人脸检测 [J]. 计算机应用研究, 2017, 34(9): 2854–2857.
- [34] CHEN D, REN S Q, WEI Y C, et al. Joint Cascade Face Detection and Alignment[C]//Computer Vision-ECCV 2014. Zurich, Switzerland: Springer International Publishing, 2014: 109–122.
- [35] ZHANG K P, ZHANG Z P, LI Z F, et al. Joint Face Detection and Alignment Using Multitask Cascaded Convolutional Networks[J]. IEEE Signal Processing Letters, 2016, 23(10): 1499–1503.
- [36] RANJAN R, PATEL V M, CHELLAPPA R. HyperFace: A Deep Multi-task Learning Framework for Face Detection, Landmark Localization, Pose Estimation, and Gender Recognition[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2016(99): 1.
- [37] JAIN V, LEARNED-MILLER E. FDDB: A Benchmark for Face Detection in Unconstrained Settings[R]. Technical Report UM-CS-2010-009, University of Massachusetts, Amherst: 2010.
- [38] YANG S, LUO P, LOY C C, et al. WIDER FACE: A Face Detection Benchmark[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2016. Las Vegas, NV, USA: IEEE Computer Society, 2016: 5525–5533.