

基于汇聚 CNN 和注意力增强网络的遮挡人脸检测方法

项丽萍¹, 杨红菊²

(1. 晋城职业技术学院信息工程系, 晋城 048000; 2. 山西大学计算机与信息技术学院, 太原 030006)

摘要: 针对现实场景中遮挡人脸检测精度低的问题, 提出了一种基于汇聚 CNN 和注意力增强网络的遮挡人脸检测方法。首先, 在主网络的多层原始特征图上, 通过有监督学习的方法增强原始特征图中人脸可见部分的响应值。然后, 将多个增强特征图组合成附加增强网络与主网络汇聚设置, 以加快对多尺度遮挡人脸的检测速度。最后, 将有监督信息分散到各个尺寸的特征图上进行监督学习, 为不同尺寸的特征图设置了基于锚框尺寸的损失函数。在 WIDER FACE 和 MAFA 数据集上的实验结果表明, 该方法的检测精度高于当前主流人脸检测方法。

关键词: 遮挡人脸检测; 卷积神经网络; 注意力增强网络; 有监督学习; 多尺度

中图分类号: TP391 **文献标志码:** A

Occlusion Face Detection Based on Convergent CNN and Attention Enhancement Network

XIANG Liping¹, YANG Hongju²

(1. Department of Information Engineering, Jincheng Institute of Technology, Jincheng 048000, China; 2. School of Computer and Information Technology, Shanxi University, Taiyuan 030006, China)

Abstract: Aiming at the problem of low detection accuracy of occluded faces in real scenes, an occluded face detection method based on convergent convolutional neural network (CNN) and attention enhancement network was proposed. First, on the multi-layer original feature map of the main network, the response value of the visible part of the face in the original feature map is enhanced by supervised learning. Then, multiple enhanced feature maps are combined into an additional enhanced network and set in converge with the main network to accelerate the detection of multi-scale occlusion faces. Finally, supervised information is distributed to feature maps of various sizes for supervised learning, and loss functions based on anchor frame sizes are set for feature maps of different sizes. Experimental results on WIDER FACE and MAFA datasets show that the detection accuracy of the proposed method is higher than the current mainstream face detection methods.

Key words: occlusion face detection; convolutional neural network (CNN); attention enhancement network; supervised learning; multiscale

引 言

人脸检测作为人脸信息处理的一项关键性技术,被广泛应用到人脸识别^[1]、人脸对齐^[2]、人机交互^[3]和人脸超分辨率重建^[4]等研究领域,其检测性能直接影响后续操作的准确性,具有重要的研究价值。作为人脸检测的经典方法,文献[5]提出了基于Haar特征和AdaBoost级联弱分类器的人脸检测方法,实现了较好的人脸检测效果。文献[6]提出了一种基于联合分层可变形组件模型(Deformable part model, DPM)的人脸检测方法,检测精度较高。文献[7]提出了一种基于树与共享池的混合人脸检测方法,将每个人脸标记点建模为共享池的一部分,并通过全局混合来还原由视角引起的拓扑变化。受限于人工设计特征的表现能力和分类器的预测性能,上述方法已被基于卷积神经网络(Convolutional neural networks, CNN)^[8-10]的方法取代。

目前基于CNN的人脸检测方法可根据是否建议候选区域分为2类:一类采用两阶段检测方法,首先生成高质量的区域建议图,然后在区域建议图上利用矩形框回归精确定位人脸边界框位置^[11-12]。另一类采用单阶段人脸检测方法^[13],去除区域建议部分,直接在多尺度特征图上进行人脸/非人脸分类和人脸边界框位置回归。文献[14]提出了一种利用人脸周边信息进行辅助的人脸检测方法,在小尺度人脸检测中取得了较好效果。文献[15]通过规模补偿锚匹配策略提高了小尺度人脸的召回率,通过最大化背景标签降低了小尺度人脸的误报率。文献[16]提出了一种基于环境辅助的单阶段人脸检测方法,通过引入环境敏感预测模块,提高了预测网络的人脸分类能力和检测精度。

虽然基于CNN的人脸检测方法已经取得了很大进展,但在现实场景中的多尺度遮挡人脸检测问题仍是难题。比如,身份证及驾照等证件验证、银行或海关监控、自动门禁系统、视频会议等应用场景中或多或少会存在人脸遮挡,这些都造成人脸检测精度的下降。现实场景中的遮挡人脸一般具有多种朝向、遮挡级别和遮挡类型,受遮挡的影响,人脸检测区域的特征存在较大缺失,这使得最先进的人脸检测方法^[17-18]也难以对其精确定位。

近年来,单阶段人脸检测方法以其高效的检测效率和直观的网络结构而备受关注,本文在单帧检测器(Single shot detector, SSD)人脸检测模型的基础上,针对复杂场景下的多尺度遮挡人脸检测问题,进行了3方面改进:(1)提出了一种注意力增强网络,通过参考人脸可见部分来辅助确认检测区域是否是人脸,即通过有监督学习的方法增强原始特征图中人脸可见部分的响应值;(2)在训练阶段,将有监督信息是分散到各个尺寸的特征图上进行监督学习,为不同尺寸的特征图设置了基于锚框尺寸的新损失函数;(3)在网络结构的设计上,为主网络和附加增强网络设置了并行的运行模式,提高了对遮挡人脸的检测速度。

1 SSD人脸检测模型

SSD算法作为一种One-stage检测算法,经单次检测即可直接得到预测目标类别和候选框位置,具有快速检测和高精度的特点。该算法的核心是在多尺度特征图上利用卷积核来预测一系列默认检测框的类别和位置。为了提高检测准确率,利用SSD算法在6个不同尺度的特征图上进行预测。

基于SSD算法的人脸检测模型如图1所示,其中,Conv1_1~Conv5_3是VGG16的前5个卷积层,Conv6和Conv7是经全连接层改造的2个卷积层,Conv8_2~Conv11_2是新增的4个卷积层。当该模型输入一幅包含单个人脸或者多个人脸的图像时,会先放缩到 300×300 大小再送入网络,最终输出一系列离散的人脸边界框及其得分。对全部的离散人脸边界框进行非极大值抑制(Non-maximum suppression, NMS),即可得到最终的人脸检测结果。

SSD人脸检测模型的损失函数包含了人脸/非人脸分类的log损失和人脸边界框回归的smooth L_1 损失




图1 基于SSD算法的人脸检测模型
Fig.1 Face detection model based on SSD algorithm

$$L_{SSD}(x, c, t, t^*) = \frac{1}{N} (L_{conf}(x, c) + \alpha L_{loc}(x, t_i, t_i^*)) \tag{1}$$

式中: N 为匹配人脸边界框的数量; x 为匹配人脸边界框的标签,是人脸时取1,不是取0; c 为所框选目标是否属于人脸的置信度; t_i 为预测人脸框; t_i^* 为真实标注框; α 为权重系数。

在模型训练时,通过计算默认检测框和真实标注框的交并比(Intersection over union, IoU)确定正负训练样本。通常选择IoU > 0.5的默认检测框为候选正样本集,选择IoU ≤ 0.5的默认检测框为候选负样本集。为了平衡正负样本数量,还要用训练时实际选取的检测框与候选负样本集匹配,剔除损失过小的检测框,因为它们易被识别为背景,且对整体网络训练提升不大。

2 基于汇聚CNN和注意力增强网络的遮挡人脸检测方法

2.1 总体框架

为了增强对遮挡人脸的检测效果,本文提出了一种基于汇聚CNN和注意力增强网络的遮挡人脸检测方法。在检测一个被遮挡的人脸时,首先需要确定该检测区域是否是人脸,这需要参考人脸周围的上下文信息,即通过合理的设置锚框尺寸去学习人脸特征。但是,受遮挡的影响,仅参考人脸周围的上下文信息也会产生一些误导,所以还需要参考人脸的可见部分来辅助确认该检测区域是否是人脸,即通过有监督学习的方法去增强对人脸可见区域的学习。本文方法对应的检测模型如图2所示,它由主网络、注意力增强网络和附加增强网络3部分组成。

主网络采用SSD算法在6个连续的卷积层上提取多尺度特征图,进而在多个特征图上分别进行人脸/非人脸分类和人脸边界框回归。由图2可知,输入图像的尺寸为384×384,经卷积层提取的6个多尺度特征图为f_1、f_2、f_3、f_4、f_5和f_6,对应尺寸为96×96、48×48、24×24、12×12、6×6和3×3。注意力增强网络通过引入分层的有监督学习,增强了原始特征图中人脸可见部分的响应值,得到原始特征图的增强特征图。附加增强网络的检测层是经过注意力增强网络处理后得到的,它由sf_1、sf_2、sf_3、sf_4和sf_5和sf_6这6个增强特征图组成,这些增强特征图与原始特征图的尺寸一致,但是对人脸可见部分的响应值更高。另外,附加增强网络与主网络采用了并行的设置方式,提高了对遮挡人脸的检测精度和速度。最终,并行检测的人脸边界框经Fast NMS处理后,输出最佳的人脸检测结果。

2.2 注意力增强网络

对于一幅遮挡人脸,仅参考人脸周围的上下文信息,很难判断该检测区域是否为人脸。因此,还需要学习出人脸可见部分,让人脸可见部分具有更高的响应值。因此,本文设置了一种注意力增强网络以提高原始特征图中人脸可见部分的辨识度,辅助进行人脸/非人脸检测,该网络的结构如图3所示。

由图3可知,该网络由4个卷积层级联而成,第1和第4个卷积层使用256个3×3大小的卷积核进

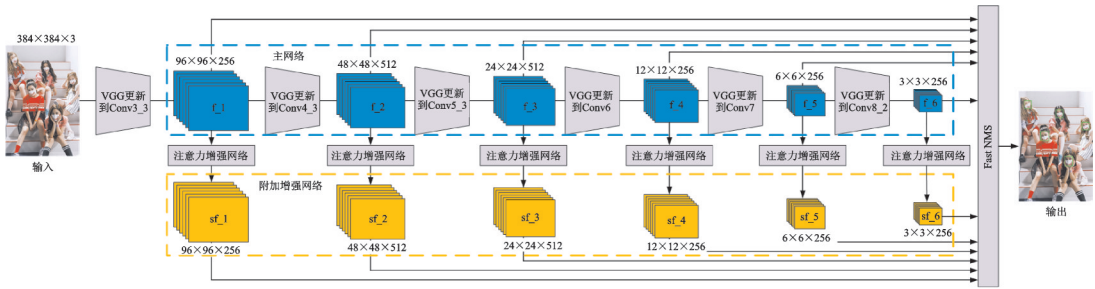


图2 基于汇聚CNN和注意力增强网络的遮挡人脸检测模型

Fig.2 Occlusion face detection model based on convergent CNN and attention enhancement network

行边缘补0的卷积,第2和第3个卷积层使用512个 3×3 大小的卷积核进行边缘补0的卷积。经过全连接层分类识别后,输出一个与原始特征图尺寸一致的得分图。在该得分图上,学习出的注意力增强区域置1,其他区域置0。对学习到的得分图进行e指数运算,将其取值范围由 $[0, 1]$ 转换为 $[1, e]$,然后点乘以原始特征图的各个通道,得到原始特征图的增强特征图。




图3 注意力增强网络

Fig.3 Attention enhancement network

为了提高对注意力增强区域的识别精度,引入有监督信息。通常,人脸检测数据集的真实标注仅有矩形框,因此,将人脸标注框内的区域全部置1,标注框外的区域全部置0。由于大部分的人脸标注不存在遮挡,当存在遮挡时,最终学习出的注意力增强区域会对未遮挡的人脸可见部分具有更高的响应值。文献[11]指出,浅层特征图适合检测小尺寸人脸,深层特征图适合检测大尺寸人脸,为了在不同尺寸的特征图上突出检测不同尺寸的人脸,本文根据特征图的尺寸比例,将监督信息分散到各个尺寸的特征图进行监督学习。简而言之,就是为大尺寸的浅层特征图增加小尺寸人脸监督信息,为小尺寸的深层特征图增加大尺寸人脸监督信息。

2.3 分层损失函数

由2.2节可知,有监督信息是分散到各个尺寸的特征图上进行监督学习的,因此本文算法在训练时为不同尺寸的特征图设置了基于锚框尺寸 r_i^k 的损失函数。

对第 k 层特征图 f_k 和它的增强特征图 sf_k ,设置相同的损失函数

$$L_k(p_i^k, t_i^k, r_i^k) = \frac{1}{N_{\text{conf}}^k} \left(\sum_i L_{\text{conf}}^k(p_i^k, p_i^{k*}) \right) + \frac{\alpha}{N_{\text{loc}}^k} \left(\sum_i p_i^{k*} L_{\text{loc}}^k(t_i^k, t_i^{k*}, r_i^k) \right) \quad (2)$$

式中: N_{conf}^k 为正负样本锚框的数量, L_{conf}^k 为人脸/非人脸分类的softmax损失, p_i^k 为预测为人脸的概率, p_i^{k*} 为分配到第 k 层特征图上的正负样本标签, N_{loc}^k 为分配到第 k 层特征图上正样本锚框的数量, r_i^k 为第 k 层

特征图上的第*i*个锚框尺寸, L_{loc}^k 为使用锚框 r_i^k 时人脸预测框 t_i^k 和真实框 t_i^{k*} 之间的参数化 smooth L_1 损失, 当 $p_i^{k*} = 1$ 时, L_{loc}^k 被激活, α 是用来平衡 L_{conf}^k 和 L_{loc}^k 的权重系数。

将所有层特征图的损失函数加权求和, 得到融合损失函数 L_{all}

$$L_{all} = \sum_{k=1}^6 \beta_k L_k(p_i^k, t_i^k, r_i^k) \quad (3)$$

式中 β_k 为平衡各层损失函数的权重系数。

3 实 验

为验证所提出算法的精确性和稳健性, 选择 WIDER FACE^[19] 人脸检测基准数据集和 MAFA 遮挡人脸检测基准数据集^[20] 进行实验, 实验中选择分层可变形部件模型(Hierarchical deformable part model, HPM)^[6], 混合分辨率(Hybrid-resolution, HR)^[14], 单帧尺度不变人脸检测(Single shot scale-invariant face detection, SFD)^[15] 和 PyramidBox^[16] 算法作为对比算法。在训练时, 使用随机梯度下降(Stochastic gradient descent, SGD)优化, 最大迭代次数设置为 10^5 , 前 7.5×10^4 次迭代, 学习率为 10^{-3} , 后 2.5×10^4 次迭代, 学习率为 10^{-4} 。批大小设置为 32, 权重衰减设置为 e^{-5} , 动量设置为 0.9, 所有卷积层均使用 MSRA 方法初始化。与真实标注框相比, $IoU \geq 0.5$ 的默认检测框被分配到正样本集, $IoU < 0.4$ 的默认检测框被分配到负样本集。

3.1 WIDER FACE 数据集测试结果分析

WIDER FACE 人脸数据集共有 32 203 幅图像, 其中标记了 393 703 个具有遮挡、模糊、尺度变化、光照变化和姿态变化等因素的人脸图像。它包含了 61 种事件类别, 在每类事件中, 随机选择 40%、10%、50% 的数据作为训练、验证和测试子集。此外, 各个子集中的数据根据人脸检测的难易程度还被划分为简单、中等和困难 3 个级别。

本文算法与 HPM, HR, SFD 和 PyramidBox 算法在 WIDER FACE 的简单、中等和困难 3 个子测试数据集上的 MAP 对比结果如表 1 所示, 在 WIDER FACE 简单、中等和困难 3 个子测试数据集上的精度和召回率(Precision-recall, PR)曲线如图 4 所示。

由表 1 可以看出, 本文算法在保持低时间消耗的同时, 提高了人脸检测精度。从图 4 的对比结果可以发现, 本文算法的 PR 曲线均高于其他 4 种对比算法。这说明本文算法的人脸检测性能优于所对比的 4 种主流人脸检测算法。考虑到困难子测试数据集中包含了大量的遮挡人脸, 而本文算法具有更高的检测精度, 这验证了本文算法对于遮挡人脸检测的有效性。

表 1 MAP 对比结果

Table 1 MAP comparison results

| 方法 | 简单 | 中等 | 困难 | 速度/(f·s ⁻¹) |
|----------------------------|-------|-------|-------|-------------------------|
| HPM ^[6] | 0.759 | 0.591 | 0.373 | 16 |
| HR ^[14] | 0.923 | 0.910 | 0.819 | 6 |
| SFD ^[15] | 0.928 | 0.913 | 0.840 | 36 |
| PyramidBox ^[16] | 0.956 | 0.946 | 0.887 | 27 |
| 本文算法 | 0.967 | 0.953 | 0.908 | 33 |

3.2 MAFA 数据集测试结果分析

MAFA 遮挡人脸数据集共有 30 811 幅图像, 其中标记了 35 806 个遮挡人脸。该数据集中的人脸具有多方向性和多遮挡级别, 并且每个人脸至少有一部分被遮罩遮挡。每个遮挡人脸具有 6 种属性, 分别是人脸位置、眼部位置、遮罩位置、人脸方向、遮挡级别和遮罩类型。MAFA 数据集的训练集包含了 25 876 幅图像, 共有 29 452 个遮挡人脸, 测试集包含了 4 935 幅图像, 共有 6 354 个遮挡人脸。

本文算法与 HPM, HR, SFD 和 PyramidBox 算法的平均精度(Average precision, AP)对比结果如表 2 所示, 本文算法与 HPM, HR, SFD 和 PyramidBox 算法在 MAFA 测试集的部分对比结果如图 5 所示。

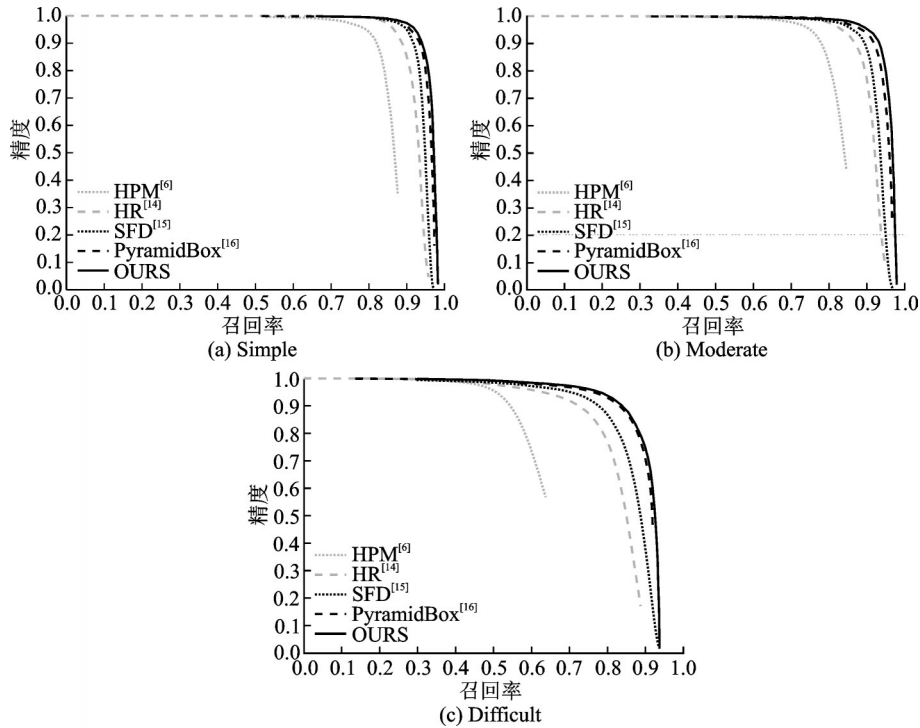


图4 精度和召回率曲线
Fig.4 Accuracy and recall curves

由表2可知,随着人脸偏转角度的增加,所有算法的平均精度会显著下降。并且随着遮挡程度的提高,各人脸检测方法的检测性能也会迅速下降。此外,遮罩越趋于复杂,人脸检测算法的检测精度越下降明显。而本文算法在12种属性下的平均精度均高于其他4种对比算法。整体的平均精度达到了80.2%,高出了PyramidBox算法约8.2%,这证明了本文算法对于遮挡人脸检测具有更高的检测精度。由图5可知,对于遮挡程度较高的人脸,4种对比算法甚至不能进行识别,而本文算法均可检测出遮挡人脸。这是因为4种对比算法均依赖于从遮挡区域内直接提取人脸的上下文信息,当人脸遮挡程度较大时,这些上下文信息的稳健性较差,导致对遮挡人脸的检测精度不高。而本文算法除了参考人脸周围的上下文信息,还参考了人脸可见部分来辅助确认该检测区域是否是人脸,即通过有监督学习的方法去增强对人脸可见区域的学习,提高了对遮挡人脸的检测精度。

表2 本文算法与HPM,HR,SFD和PyramidBox等方法的平均精度对比结果

Table 2 Comparison of the average precision of our algorithm with HPM, HR, SFD and PyramidBox

| | % | | | | |
|-------------|------|------|------|------------|------|
| 属性 | HPM | HR | SFD | PyramidBox | OURS |
| Left | 1.29 | 10.2 | 13.8 | 16.8 | 19.3 |
| Left-front | 26.6 | 33.4 | 38.2 | 45.2 | 62.6 |
| Front | 64.4 | 69.7 | 71.3 | 74.3 | 81.2 |
| Right-front | 18.9 | 23.8 | 27.6 | 30.6 | 57.6 |
| Right | 0.93 | 5.75 | 8.87 | 15.9 | 17.1 |
| Weak | 58.5 | 63.3 | 63.8 | 66.8 | 78.5 |
| Medium | 34.8 | 39.7 | 52.3 | 55.6 | 71.7 |
| Heavy | 5.31 | 10.1 | 12.4 | 15.2 | 25.3 |
| Simple | 54.7 | 59.3 | 58.4 | 60.1 | 76.3 |
| Complex | 46.1 | 51.7 | 55.7 | 58.2 | 73.9 |
| Body | 23.4 | 28.4 | 37.9 | 40.4 | 66.4 |
| Hybrid | 6.00 | 11.0 | 13.2 | 16.3 | 27.0 |
| All | 60.0 | 65.3 | 67.9 | 71.2 | 79.4 |



图5 本文方法与HPM,HR,SFD和PyramidBox方法在MAFA测试集的部分对比结果

Fig.5 Partial comparison of the proposed method with HPM, HR, SFD and PyramidBox in the MAFA test set

4 结束语

本文提出了一种基于汇聚CNN和注意力增强网络的遮挡人脸检测方法,该方法在主网络的多层原始特征图上,通过引入有监督学习增强了原始特征图中人脸可见部分的辨识度,并且将多个增强特征图组成附加增强网络,与主网络并行设置,以加快对多尺度遮挡人脸的检测速度。此外,在训练时还将有监督信息分散到多个尺寸的特征图上进行监督学习,为不同尺寸的特征图设置了基于锚框尺寸的损失函数,提高了对多尺度遮挡人脸的检测精度。在WIDER FACE和MAFA数据集上的实验结果表明,本文算法的检测精度优于当前主流人脸检测方法。

参考文献:

- [1] ZHU Xiangyu, LIU Hao, LEI Zhen, et al. Large-scale bisample learning on ID versus spot face recognition[J]. International Journal of Computer Vision, 2019, 127(6/7): 684-700.
- [2] SHI Baoguang, BAI Xiang, LIU Wenyu, et al. Face alignment with deep regression[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(1): 183-194.
- [3] VILLAMIZAR M, SANFELIU A, MORENO-NOGUER F. Online learning and detection of faces with low human supervision[J]. The Visual Computer, 2019, 35(3): 349-370.
- [4] JIANG Junjun, MA Jiayi, CHEN Chen, et al. Noise robust face image super-resolution through smooth sparse representation [J]. IEEE Transactions on Cybernetics, 2017, 47(11): 3991-4002.
- [5] VIOLA P, JONES M J. Robust real-time face detection[J]. International Journal of Computer Vision, 2004, 57(2): 137-154.
- [6] GHIASI G, FOWLKES C C. Occlusion coherence: Localizing occluded faces with a hierarchical deformable part model[C]// Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Columbus, USA: IEEE Computer Society, 2014: 1899-1906.
- [7] ZHU Xiangxin, RAMANAN D. Face detection, pose estimation, and landmark localization in the wild[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Providence, USA: IEEE Computer Society, 2012: 2879-2886.
- [8] LI Haoxiang, LIN Zhe, SHEN Xiaohui, et al. A convolutional neural network cascade for face detection[C]//Proceedings of

- IEEE Conference on Computer Vision and Pattern Recognition. Boston, USA: IEEE Computer Society, 2015: 5325-5334.
- [9] ZHANG Kaipeng, ZHANG Zhanpeng, LI Zhifeng, et al. Joint face detection and alignment using multitask cascaded convolutional networks[J]. *IEEE Signal Processing Letters*, 2016, 23(10): 1499-1503.
- [10] 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 and Machine Intelligence*, 2017, 41(1): 121-135.
- [11] REN Shaoqing, HE Kaiming, 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*, 2015, 39(6): 1137-1149.
- [12] JIANG Huaizu, LEARNED-MILLER E. Face detection with the faster R-CNN[C]//*Proceedings of International Conference on Automatic Face Gesture Recognition*. Washington, USA: IEEE Computer Society, 2016: 650-657.
- [13] LIU Wei, ANGUOLOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]//*Proceedings of the European Conference on Computer Vision*. Amsterdam, Netherlands: Springer, 2016: 21-37.
- [14] HU Peiyun, RAMANAN D. Finding tiny faces[C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, USA: IEEE Computer Society, 2017: 1522-1530.
- [15] ZHANG Shifeng, ZHU Xiangyu, LEI Zhen, et al. S³FD: Single shot scale-invariant face detector[C]//*Proceedings of the IEEE International Conference on Computer Vision*. Venice, Italy: IEEE Computer Society, 2017: 192-201.
- [16] TANG Xu, DU D K, HE Zeqiang, et al. Pyramidbox: A context-assisted single shot face detector[C]//*Proceedings of the European Conference on Computer Vision*. Munich, Germany: Springer, 2018: 797-813.
- [17] ZHU Chenchen, TAO, Ran, LU K, et al. Seeing small faces from robust anchor's perspective[C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. Salt Lake City, USA: IEEE Computer Society, 2018: 5127-5136.
- [18] ZHANG Shifeng, WEN Longyin, SHI Hailin, et al. Single-shot scale-aware network for real-time face detection[J]. *International Journal of Computer Vision*, 2019, 127(6/7): 537-559.
- [19] YANG Shuo, LUO Ping, CHEN C L, et al. WIDER FACE: A face detection benchmark[C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas, USA: IEEE Computer Society, 2016: 5525-5533.
- [20] GE Shiming, LI Jia, YE Qiting, et al. Detecting masked faces in the wild with LLE-CNNs[C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, USA: IEEE Computer Society, 2017: 2682-2690.

作者简介:



项丽萍(1975-),通信作者,女,副教授,研究方向:算法设计、大数据技术应用、云计算等, E-mail: xywuu38@163.com。



杨红菊(1975-),女,副教授,研究方向:机器学习、深度学习、计算机视觉等, E-mail:yhju@sxu.edu.cn。

(编辑:张彤)