

基于多尺度特征聚合和密集连接的人群计数网络

马跃康¹ 胡璐锦²

¹(中国矿业大学环境与测绘学院 江苏 徐州 221116)

²(北京建筑大学测绘与城市空间信息学院 北京 100044)

摘要 人群计数任务处理的图像受到遮挡、视角变化和透视效应、背景成像干扰等多方面的挑战。针对复杂场景中人群计数任务存在的尺度变化、图片噪声等问题,设计一种基于多尺度特征聚合和密集连接的人群计数网络模型。模型的一个重要组成部分是密集连接而成的多尺度特征聚合模块,它通过不同卷积核提取多尺度特征并聚合其跨尺度的信息进行更准确的估计。该网络模型在三个公开数据集 Shanghai Tech、UCF_QNRF、UCF_CC_50 上进行测试,实验结果表明,该模型相比目前先进算法 CSRNet 在平均绝对误差(MAE)、均方误差(MSE)均有不同程度的减少,模型精度更好。与其他模型相比,该模型更充分地利用多尺度特征信息,提高了人群计数任务的精度。

关键词 人群计数 特征融合 多尺度卷积 密集连接 高质量密度图

中图分类号 TP391

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.10.033

CROWD COUNTING NETWORK BASED ON MULTI-SCALE FEATURE AGGREGATION AND DENSE CONNECTION

Ma Yuekang¹ Hu Lujin²

¹(School of Environment and Spatial Informatics, China University of Mining and Technology, Xuzhou 221116, Jiangsu, China)

²(School of Geomatics and Urban Spatial Informatics, Beijing University of Civil Engineering and Architecture, Beijing 100044, China)

Abstract Crowd counting is challenged by many aspects, such as occlusion, perspective change and perspective effect, background imaging interference, etc. In this paper, we propose a multi-scale feature aggregation and dense connection network for crowd counting. A vital component of this network called multi-scale feature aggregation model (MFA) extracted multi-scale features through different convolution kernels and aggregated their cross-scale information for more accurate estimation. This model was tested on three public datasets Shanghai Tech A, Shanghai Tech B, UCF_QNRF and UCF_CC_50. The results show that the model has reduced the mean absolute error (MAE) and mean square error (MSE) to different degrees, and the model accuracy is better compared with CSRNet. In contrast with other models, the model makes full use of multi-scale feature information and improves the accuracy of the crowd counting.

Keywords Crowd counting Feature aggregation Multi-scale convolution Dense connection High-quality density map

0 引言

人群计数作为智能视频监控技术的任务之一,其任务是估计视频或者图像中包含人数多少和其大致密度分布。人群计数在视频监控、交通安全、人流预测等

任务^[1-2]中应用广泛,一直以来受到很多研究人员的关注。

随着深度学习的发展,卷积神经网络常常用于人群计数任务。人群计数同其他计算机视觉领域一样面临诸多挑战,其中主要来自数据方面的问题。人群计数处理场景多为一些图像、视频,由定点拍摄而成,这

样难免造成人群分布不均。此外,图像、视频拍摄角度造成的视角变化和透视效应,使得图像本身的信息变化复杂。还有其他因素诸如光照、成像噪声、背景影响等同样带来巨大挑战。早期的人群计数工作主要是基于检测或回归的方法,这些方法针对的场景有限,同时受限于算法的局限性,计数结果也存在较大误差,因此表现并不理想。目前,人群计数任务的深度学习算法发展已有几年,最早,Wang 等^[3]采用 Alexnet 网络,将最终的 4 096 个神经元的全连接层用单个神经元替换,用以输出人数。Zhang 等^[4]提出了一种根据人头标记生成密度图的方法,首次将预测任务转化为像素对像素的预测,采用多列不同卷积核卷积结构的网络,使得网络在更好地完成计数的同时还能输出密度图。Li 等^[5]证明了多列网络在提取不同尺度信息时的表现并不能适应图像的尺度变化,而且其计算量随着网络复杂度急剧增加,导致训练速度缓慢和梯度爆炸。Li 等^[5]提出单列卷积结构的 CSRNet,该网络采用了 VGG16 前 10 层作为特征提取器,拥有更深的层数,除了作为前端的前 10 层外,后端采用了多层空洞卷积的特征提取,最后输出对应密度图。但其算法缺乏对空间上下文信息的补充和低层信息的还原,在复杂场景中容易造成误判,不利于实际应用。

卷积神经网络中各层提取的特征图由于其卷积核的不同(感受野大小不同),提取的特征也不相同。Guo 等^[6]在解决尺度变化问题时使用不同卷积率的扩张卷积来自适应地学习不同尺度人头的变化,同时引入可形变卷积对位置信息做更好的估计。不同等级的特征图也具有不一样的信息,特征图大小越小,所具有的语义信息就越多,反之,它的空间信息越丰富。Zhu 等^[7]提出的多尺度多级特征聚合网络(Multi-scale and Multi-level Feature Aggregation, MFANet)中不同卷积核提取的特征通过聚合和通道注意力机制获得了丰富的信息。在 Wang 等^[8]提出的 SCNet 中,使用了多个不同空洞率的卷积操作形成的卷积块,同时也穿插了一个空间金字塔模块,这些多尺度的操作让网络在单列的情况下能保持较好的上下文信息,使网络的性能更好。文献[9-11]的网络结构本身会产生不同大小、感受野的特征图,为实现更好的结果,通常在具有相同特点的特征图之间做特征融合。

人群计数任务中除尺度变化引起的精度挑战外,损失函数作为评价模型预测值和真实值的一致程度的标准,也是网络设计中不可缺少的一部分。目前,绝大多数算法都采用欧氏距离损失(euclidean distance loss)来作为模型损失函数,例如 MCNN^[4]、

CrowdNet^[12]、Switch-CNN^[13]、CSRNet 等。欧氏距离损失简单,计数表现较好。其他诸如 SANet 采用结构相似性指标(Structural Similarity Index, SSIM)^[3]来克服欧氏距离损失的不足。本文将采用密集连接网络^[14](Dense Scale Network, DSNet)提出的多尺度密度水平一致性损失(multi-scale density level consistency loss),此损失函数能够关注图像整体和局部的密度水平,使得真值图和预测图之间的整体和局部的密度水平尽可能一致。

针对上述问题,本文根据 CSRNet 的前后端结构设计一个多尺度特征聚合的密集连接网络,采用了多尺度卷积的方法来获取不同尺度的信息,对目标不同尺度进行学习。与大多数算法直接拼接特征图的方法不同,我们采用特征聚合的方式来融合跨尺度的信息,以此来增强其特征图的表达能力。借鉴密集连接^[15]的思想,多尺度模块采用密集连接结构,能够更好地复用浅层信息,以使网络包含更多的信息。该网络模型在 Shanghai Tech、UCF_QNRF、UCF_CC_50 数据集上进行了测试,相比于 CSRNet,人群计数效果有显著提升。

综上所述,本文有以下三个主要贡献:

- 1) 提出集成多尺度聚合模块的网络模型,可有效生成多尺度、跨尺度信息。
- 2) 提出多尺度特征融合的密集连接网络用于人群计数。通过密集连接结构对多尺度聚合模块进行特征信息的复用来提高网络模型性能。
- 3) 在三大公开数据集上验证了网络模型的有效性,并通过消融实验证明了各模块的作用。

1 多尺度特征聚合和密集连接的人群计数算法

在人群计数任务中,我们通常生成一个对应的人群密度图以估计人数,为此,我们需要建立一个端到端的模型,以任意分辨率大小的图像为输入,原图大小相等的密度图为输出,对输出的密度图矩阵求和计算出图像中人数。

1.1 模型结构

本文模型的任务是学习一个函数映射 F :

$$D_i^{\text{est}}(X_i) = F(X_i, \omega) \quad 1 < i \leq N \quad (1)$$

式中: X_i 表示输入的图像; $D_i^{\text{est}}(X_i)$ 表示对应的预测密度图; ω 表示网络的参数; N 表示样本数量。根据 $D_i^{\text{est}}(X_i)$ 对其积分可以计算出人群数量。本文设计一个多尺度特征聚合和密集连接的模型,该模型能够进行端到端的训练和预测,其结构如图 1 所示。

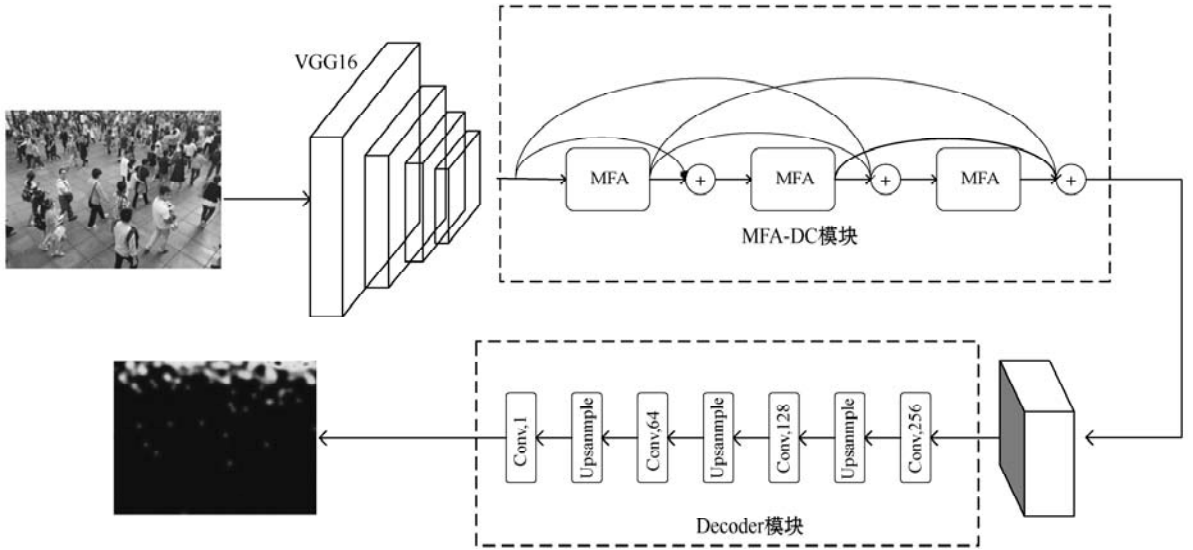


图 1 多尺度特征聚合和密集连接的人群计数模型结构

本文模型主要由三部分组成:front-end 模块、多尺度特征提取(MFA-DC)模块和 Decoder 模块。front-end 模块作为模型的 backbone 的一部分,我们选择 VGG 网络的前 13 层作为模型的 front-end,并使用其预训练模型,因为 VGG16 的预训练模型有着非常好的特征提取能力。多尺度特征提取模块对 front-end 模块提取的特征做进一步的提取和融合,以达到更好的特征提取能力。最后,因为图像通过一系列的编码特征后生成的是 1/8 原图大小的特征图,为了使输出密度图和输入图像大小相同,Decoder 模块使用一系列的上采样和卷积操作来还原分辨率,生成高质量的人群图像密度映射。Decoder 模块主要由 3 个上采样层和 3 个卷积层组合而成,进一步地从跨层次特征中提取信息,最后生成得到预测密度图。

1.2 多尺度特征聚合模块

针对人群计数任务中头部尺度多样性问题,本文设计多尺度特征聚合模块来提取多尺度信息,模型结构如图 2 所示。模块接收 front-end 模块或者前一层输出的特征图,分别进行空洞率为 1、2、3、6 的空洞卷积,得到特征图 $X_{i,1}$,为了降低参数量,每个卷积模块生成的特征数量是输入的 1/4。多尺度特征聚合操作将不同空洞率的特征图进行融合,并进行特征通道数的调整,即:

$$X_{i,j} = C(\text{concat}(X_{1,j}, X_{2,j}, \dots, X_{i,j})) \quad (2)$$

式中: C 代表卷积操作(调整特征通道数); concat 代表特征通道拼接。如图 2 所示, $X_{2,j}$ 的特征图有空洞率为 1、2 的上下文信息, $X_{3,j}$ 的特征图有空洞率为 1、2、3 的上下文信息,以此类推,最后, $X_{1,j} - X_{4,j}$ 进行特征图拼接得到与输入相同大小和通道数的特征图。这样在不

同空洞率的特征图之间做融合和卷积操作,有助于提取更为丰富的多尺度信息,同时这种类残差结构也增加了网络的非线性,提高模型整体的鲁棒性。




图 2 多尺度特征聚合模块

由于使用了空洞卷积,它可以捕获具有不同感受域的高级特征,另外,模块中的融合和卷积有助于增强特征的代表能力和尺度的多样性。更简单地说,这样的结构更加适应尺度变化大的数据。

1.3 密集连接结构

虽然多尺度特征聚合模块具有提取多尺度信息的能力,但是模块与模块之间的特征并没有得到充分的利用。因此,我们增加一个密集连接结构来改进特征提取能力,以此增强其特征的上下文信息表达能力,此外,密集连接结构可以有效加速模型收敛。密集连接模块如图 1 中 MFA-DC 模块所示。

每一个多尺度特征聚合模块都会接收前面所有多尺度特征模块的输出,其数学函数表达为:

$$X_{i+1} = H(X_1, X_2, \dots, X_i) \quad (3)$$

式中: X_i 代表各个模块的输出; H 代表一个组合操作,包括特征拼接、多尺度特征聚合模块所有的操作等。这样,每一层的输出都包含了前面所有层的信息,从而实现了特征传递。与没有密集残差连接结构相比,它的尺度多样性、上下文信息更加丰富,进一步提取了多尺度信息。

1.4 损失函数

大多数人群计数算法的损失函数都采用了均方误差作为损失函数,本文也采用了此损失函数。均方误差的损失函数定义如下:

$$L_e = \frac{1}{N} \sum_{i=1}^N \|G(x_i; \theta) - D_i^{GT}\|_2^2 \quad (4)$$

式中: N 是一个批次内的图像个数; $G(x_i; \theta)$ 是使用参数 θ 对训练图像 x_i 估计的密度图; D_i^{GT} 是密度图对应的真值。均方误差损失函数会计算像素误差,对于误差较大的点更加敏感,但是相应地,如果数据集中存在较大的离群点(即偏离一般数据较大的点),损失函数会给予更高的权重,牺牲对其他正常点的预测,从而影响模型性能。

根据文献[15],模型的损失函数除了使用均方误差损失外,还引入了多尺度密度水平一致性损失。多尺度密度水平一致性损失的定义如下:

$$L_c = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^S \frac{1}{k_j^2} \|P_{ave}(G(x_i; \theta), k_j) - P_{ave}(D_i^{GT}, k_j)\|_1 \quad (5)$$

式中: S 代表了多尺度的等级; P_{ave} 是平均池化操作; k_j 是指平均池化的输出大小。多尺度损失考虑了预测密度图和真值图之间的全局和局部的密度等级差异,尺度将预测密度图划分为不同的子区域,以表示不同位置的人群密度水平。在本文中,使用 $k_j = (1, 2, 4)$ 进行多尺度损失预测。

最后,两个损失函数组成联合损失函数:

$$L = L_e + \lambda L_c \quad (6)$$

式中: λ 代表了多尺度损失在联合损失函数计算时的权重。根据本文的实验结果,对各数据集的权重取值如表 1 所示。

表 1 各数据集的权重 λ 取值

数据集	λ
Shanghai tech A	10
Shanghai tech B	1
UCF_QNRF	1
UCF_CC_50	1

2 实验及分析

本文在 Shanghai Tech、UCF_QNRF、UCF_CC_50 三大数据集上进行模型对比实验及分析。所有的实验采用的环境为 Ubuntu 16.04,深度学习框架是 PyTorch 1.7.0,

硬件配置为 i9-10980XE 处理器,显卡为 RTX6000 (24 GB 显存)。

2.1 训练细节

(1) 训练参数设置。我们的模型采用 VGG-16 预训练模型来加速训练过程,其他层采用 0 均值、0.01 标准差的高斯分布来进行初始化。训练过程中使用 Adam 优化器。模型训练过程 Shanghai Tech A 和 UCF_CC_50 两个训练集的批大小为 4,Shanghai Tech B 和 UCF_QNRF 的批大小为 1。

(2) 数据增强。数据增强有助于扩充数据集,提高训练模型的鲁棒性。在训练过程中,我们使用了几个数据增强的方法:在图像的四个角裁剪 1/4 原图大小的 4 幅图片和随机裁剪 1/4 原图大小的 5 幅图片,接着,我们对这些图片做随机的水平翻转。我们还对这些图片做了参数为 [0.5, 1.5] 的 gamma 变换得到最终的训练数据集。

2.2 评价指标

目前大多数人群计数算法模型均采用平均绝对误差 (Mean Absolute Error, MAE) 和均方误差 (Mean Squared Error, MSE) 作为评价指标,为统一对比本文方法也采用相同的评价指标。其定义如下:

$$M_{AE} = \frac{1}{N} \sum_{i=1}^N |C_i - C_i^{GT}| \quad (7)$$

$$M_{SE} = \sqrt{\frac{1}{N} \sum_{i=1}^N |C_i - C_i^{GT}|^2} \quad (8)$$

式中: N 代表测试集的图像数量; C_i 和 C_i^{GT} 分别表示第 i 幅测试图像的预测值和标注真值。MAE 表示估计的准确性,而 MSE 反映估计的鲁棒性。

2.3 Shanghai tech 数据集

从互联网上随机下载而来,图像之间背景、相似度等差异较大,包含有 482 幅图片,它的人数、密度都比 Part B 高,这 482 幅中 300 幅作为训练集,182 幅作为测试集,其平均分辨率为 589×868 。Part B 是在上海的街道上拍摄所得,图像之间相似度比较好、背景相似,其中一共包含 400 幅训练集和 316 幅测试集,其平均分辨率为 768×1024 。

为了验证本文模型,我们将在 Shanghai tech 数据集进行实验并与其他先进的方法进行比较。其结果如下。表 2 结果表明,本文模型在 PartB 数据集比 PartA 数据集表现要好,在 PartB 数据集上 MAE 比先进的算法提高了 13.8%;在人群密度稀疏场景中的表现比密集场景好。

表 2 各方法在 Shanghai tech 数据集上的性能

方法	Shanghai part A (MAE/MSE)	Shanghai part B (MAE/MSE)
MCNN ^[4]	110.2/173.2	26.4/41.3
Switch-CNN ^[13]	90.4/135.0	21.6/33.4
SCNet ^[8]	71.9/107.9	9.3/14.4
CSRNet ^[5]	68.2/115.0	10.6/16.0
SCLNet ^[16]	67.9/102.9	9.1/14.2
AWRFN ^[17]	66.7/109.1	11.5/19.5
MBTTBF ^[18]	60.2/94.1	8.0/15.5
本文方法	68.2/112.0	7.1/11.3

2.4 UCF_QNRF 数据集

UCF_QNRF 数据集是一个非常具有挑战性的数据集,它场景多样,视角、背景、成像条件变化多样,它共包含 1 535 幅图像,其中 1 201 幅图像作为训练集,其余作为测试集,平均人数为 815 个。本文方法的实验结果及性能对比。

表 3 各方法在 UCF_QNRF 数据集上的性能

方法	UCF_QNRF (MAE/MSE)
Switch-CNN ^[13]	228/445
CSRNet ^[5]	120.3/208.5
SCLNet ^[16]	109.6/182.5
MBTTBF ^[18]	97.5/165.2
本文方法	96.58/169.4

2.5 UCF_CC_50 数据集

UCF_CC_50^[19] 是一个密度极大的数据集,总共由 50 幅不同分辨率大小图片组成,其平均人数达 1 280 之多,但由于其图像数量有限,本文按照五倍交叉验证的方法对本文模型进行验证:将数据集随机分为 5 份,以其中 4 份作为训练集,另外一份作为测试集,分别做五次实验,最终结果取五次实验的误差指标的平均值。本文方法的实验结果及性能对比如表 4 所示。

表 4 各方法在 UCF_CC_50 数据集上的性能

方法	UCF_CC_50 (MAE/MSE)
MCNN ^[4]	377.6/509.1
Switch-CNN ^[13]	318.1/439.2
SCNet ^[8]	280.5/332.8
CSRNet ^[5]	266.1/397.5
SCLNet ^[16]	258.9/326.2
AWRFN ^[17]	257.3/337.2
MBTTBF ^[18]	233.1/300.9
本文方法	259.1/350.9

2.6 消融实验

为了验证本文提出的多尺度特征聚合结构、密集连接结构的有效性,在上述 Shanghai Part A 数据集上做了消融实验,实验结果如表 5 所示。

表 5 在 Shanghai tech Part A 数据集上的网络结构消融实验

方法	Shanghai part A (MAE/MSE)
CSRNet ^[5]	68.2/115.0
Baseline	71.51/117.44
Baseline + MFA	69.9/115.11
Baseline + MFA + DC	68.2/112.0

本文模型包括主干网络 Baseline、MFA-DC 特征提取模块。为了证明各模块的有效性,我们通过以 Baseline 为基础添加各个组件块(结构)来进行消融实验。

主干网络 Baseline 采用 VGG16 预训练模型作为 backbone,输出的特征图通过特征通道为 [256, 128, 64, 1] 的一系列卷积加上采样操作将特征图还原为原来大小,输出密度图。本文的 MFA 模块也具有较强的特征提取能力,在 Baseline + MFA 实验中仅采用一个 MFA 模块作为特征提取模块,以此验证模块的有效性。Baseline + MFA + DC 模型则为本文提出的网络,实验结果如表 5 所示。

上述实验结果表明,在 Baseline 上增加 MFA 模块使得 Part A 数据集的 MAE 下降 2.3%,MSE 下降 2.0%,验证了 MFA 模块提取多尺度特征的能力;在此基础上增加密集连接结构时进一步使 MAE 下降 2.4%,MSE 下降 2.7%,这表明多尺度特性通过密集连接结构得到进一步扩大,特征利用更有效。由此可见,多尺度特征聚合模块和密集连接结构具有较好的性能和鲁棒性。

3 结 语

本文提出一种基于多尺度特征聚合和密集连接的人群计数网络,旨在通过解决图像尺度变化的问题来提高人群计数任务的准确率。通过本文所提出的多尺度特征聚合模块和密集连接结构,模型对特征图的利用大大增强。本文通过在 Shanghai Tech、UCF_QNRF、UCF_CC_50 数据集上进行实验并证明了本文算法的有效性和鲁棒性。未来还可以考虑引入注意力机制来学习特征的相关性等,以进一步提高人群计数任务的准确率。

参 考 文 献

- [1] Fookes C, Denman S, Lakemond R. et al. Semi-supervised intelligent surveillance system for secure environments[C]//

- 2010 IEEE International Symposium on Industrial Electronics, 2010: 2815 – 2820.
- [2] Castro J, Delgado M, Medina J, et al. Intelligent surveillance system with integration of heterogeneous information for intrusion detection [J]. *Expert Systems with Applications*, 2011, 38(9) : 11182 – 11192.
- [3] Wang C, Zhang H, Yang L, et al. Deep people counting in extremely dense crowds [C] // 23rd ACM International Conference on Multimedia, 2015: 1299 – 1302.
- [4] Zhang Y, Zhou D, Chen S, et al. Single-image crowd counting via multi-column convolutional neural network [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition, 2016: 589 – 597.
- [5] Li Y, Zhang X, Chen D. CSRNet: Dilated convolutional neural networks for understanding the highly congested scenes [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 1091 – 1100.
- [6] Guo D, Li K, Zha Z, et al. DADNet: Dilated-attention-deformable convnet for crowd counting [C] // 27th ACM International Conference on Multimedia, 2019: 1823 – 1832.
- [7] Zhu F, Yan H, Chen X, et al. A multi-scale and multi-level feature aggregation network for crowd counting [J]. *Neurocomputing*, 2021, 423: 46 – 56.
- [8] Wang Z, Xiao Z, Xie K, et al. In defense of single-column networks for crowd counting [EB]. arXiv:1808.06133, 2018.
- [9] 杜培德, 严华. 基于多尺度空间注意力特征融合的人群计数网络 [J]. *计算机应用*, 2021, 41(2) : 537 – 543.
- [10] 王徐庆. 基于多尺度信息与注意力机制的人群密度估计算法研究 [D]. 合肥: 安徽大学, 2020.
- [11] 左健豪, 姜文刚. 自适应融合特征的人群计数网络 [J]. *计算机工程与应用*, 2021, 57(21) : 203 – 208.
- [12] Boominathan L, Kruthiventi S, Babu R. CrowdNet: A deep convolutional network for dense crowd counting [C] // 24th ACM International Conference on Multimedia, 2016: 640 – 644.
- [13] Sam D, Surya S, Babu R. Switching convolutional neural network for crowd counting [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4031 – 4039.
- [14] Dai F, Liu H, Ma Y, et al. Dense scale network for crowd counting [EB]. arXiv:1906.09707, 2019.
- [15] Huang G, Liu Z, Laurens V, et al. Densely connected convolutional networks [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2261 – 2269.
- [16] Wang S, Lu Y, Zhou T, et al. SCLNet: Spatial context learning network for congested crowd counting [J]. *Neurocomputing*, 2020, 404: 227 – 239.
- [17] Peng S, Wang L, Yin B, et al. Adaptive weighted crowd receptive field network for crowd counting [J]. *Pattern Analysis and Applications*, 2020, 24: 805 – 817.
- [18] Sindagi V, Patel V. Multi-level bottom-top and top-bottom feature fusion for crowd counting [C] // 2019 IEEE/CVF International Conference on Computer Vision, 2019: 1002 – 1012.
- [19] Idrees H, Saleemi I, Seibert C, et al. Multi-source multi-scale counting in extremely dense crowd images [C] // 2013 IEEE Conference on Computer Vision and Pattern Recognition, 2013: 2547 – 2554.
- ~~~~~
- (上接第 121 页)
- [14] Vazirani A, Odonoghue O, Brindley D, et al. Blockchain vehicles for efficient medical record management [J]. *NPJ Digital Medicine*, 2020, 3(1) : 1 – 5.
- [15] Ivan D. Moving toward a blockchain-based method for the secure storage of patient records [EB/OL]. [2021 – 03 – 21]. https://www.healthit.gov/sites/default/files/9-16-drew_ivan_20160804_blockchain_for_healthcare_final.pdf.
- [16] Bendiab K, Kolokotronis N, Shialeles S, et al. A novel blockchain-based trust model for cloud identity management [EB]. arXiv:1903.04767, 2019.
- [17] Li H Y, Zhu L H, Shen M, et al. Blockchain-based data preservation system for medical data [J]. *Journal of Medical Systems*, 2018, 42(8) : 1 – 13.
- [18] Ibraimi L, Tang Q, Hartel P H, et al. A type-and-identity-based proxy re-encryption scheme and its application in healthcare [C] // 5th VLDB Workshop on Secure Data Management, 2008: 185 – 198.
- [19] Fimiani G. Supporting privacy in a cloud-based health information system by means of fuzzy conditional identity-based proxy re-encryption (FCI-PRE) [C] // 2nd International Conference on Advanced Information Networking and Applications Workshops, 2018: 569 – 572.
- [20] Li X F, Mei Y R, Gong J, et al. A blockchain privacy protection scheme based on ring signature [J]. *IEEE Access*, 2020, 8: 76765 – 76772.
- [21] Zheng X C, Mukkamala R, Vatraru R, et al. Blockchain-based personal health data sharing system using cloud storage [C] // 20th International Conference on e-Health Networking, Applications and Services, 2018: 1 – 6.
- [22] Azaria A, Ekblaw A, Vieira T, et al. MedRec: Using blockchain for medical data access and permission management [C] // International Conference on Open & Big Data, 2016: 25 – 30.
- [23] 薛腾飞, 傅群超, 王枫, 等. 基于区块链的医疗数据共享模型研究 [J]. *自动化学报*, 2017, 43(9) : 1555 – 1562.
- [24] Huang H P, Zhu P, Xiao F, et al. A blockchain-based scheme for privacy-preserving and secure sharing of medical data [J]. *Computers & Security*, 2020, 99: 102010.
- [25] Bai S J, Yang G, Rong C M, et al. QHSE: An efficient privacy-preserving scheme for blockchain-based transactions [J]. *Future Generation Computer Systems*, 2020, 112: 930 – 944.