

# 基于多层 BP 神经网络和无参数微调的人群计数方法

徐 洋<sup>1,2</sup> 陈 燧<sup>2</sup> 黄 磊<sup>2</sup> 谢晓尧<sup>1,2</sup>

(贵州师范大学贵州省信息与计算科学重点实验室 贵阳 550001)<sup>1</sup>

(贵州师范大学贵阳市公安局信息安全联合研究中心 贵阳 550001)<sup>2</sup>

**摘 要** 针对大部分现有的人群计数方法被应用到新的场景时性能下降的问题,在多层 BP 神经网络框架下,提出一种具有无参数微调的人群计数方法。首先,从训练图像中裁切图像块,将获得的相似尺度的行人作为人群 BP 神经网络模型的输入;然后,BP 神经网络模型通过学习预测密度图,得到了一个具有代表性的人群块;最后,为了处理新场景,对训练好的 BP 神经网络模型进行目标场景微调,可追求有相同属性的样本,包括候选块检索和局部块检索。实验数据集包括 PETS2009 数据集、UCSD 数据集和 UCF\_CC\_50 数据集。这些场景的实验结果验证了提出方法的有效性。相比于全局回归计数法和密度估计计数法,提出的方法在平均绝对误差和均方误差方面均有较大优势,消除了场景间区别和前景分割的影响。

**关键词** 人群计数,BP 神经网络,无参数微调,密度图,平均绝对误差

**中图分类号** TP301.6 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2018.10.043

## Crowd Counting Method Based on Multilayer BP Neural Networks and Non-parameter Tuning

XU Yang<sup>1,2</sup> CHEN Yi<sup>2</sup> HUANG Lei<sup>2</sup> XIE Xiao-yao<sup>1,2</sup>

(Key Laboratory of Information and Computing Science of Guizhou Province, Guizhou Normal University, Guiyang 550001, China)<sup>1</sup>

(Guizhou Normal University & Guiyang Public Security Bureau Joint Research Centre for Information Security,

Guizhou Normal University, Guiyang 550001, China)<sup>2</sup>

**Abstract** Because the performance of most existing crowd counting methods is decreased when they are applied to a new scene, a crowd counting method based on non-parameter tuning was proposed in the framework of multilayer BP neural network. Firstly, image blocks are cropped from the training images to obtain similar scale pedestrian as an input of crowd BP neural network model. Then, the predictive density map is learned by BP neural network model to obtain representative crowd blocks. Finally, in order to deal with the new scene, the target scene is adjusted on the trained BP neural network model, retrieving samples with the same attributes, which includes candidate block retrieval and local block retrieval. The data set includes PETS2009 data set, UCSD data set and UCF\_CC\_50 data set. The effectiveness of the proposed method is verified by the experimental results on these scenes. Compared with the global regression counting method and density estimation counting method, the proposed method has advantages of average absolute error and mean square error, and overcomes the influences of the differences between the scenes and foreground segmentation.

**Keywords** Crowd counting, BP neural network, Non-parameter tuning, Density map, Average absolute error

## 1 引言

近年来,城市视频监控<sup>[1]</sup>越来越普遍,视频中的人群计数<sup>[2]</sup>也吸引了研究人员的关注。物体遮挡、场景的透视扭曲和多样化的人群分布<sup>[3]</sup>,使得人群计数成为一项非常具有挑战性的课题。大多数现有的方法以回归为基础,目标是在低级特征和人群计数间学习映射关系。然而,这些方法都有明确的场景,在新场景下需要重新训练和标注,这一问题是该课题研究的难点和重点。

一般人群计数方法可以分为 3 类,即全局回归计数、密度估计计数和深度学习方法。

全局回归计数通过检测或轨迹聚类进行人群计数,局限于人与人之间的遮挡问题。文献[4]提出了半监督回归和数据传输方法,以减少所需的训练数据量,但需要目标人群场景的标签。文献[5]针对高密度人群场景,提出了基于截面流量统计的行人计数方法,利用梯度运动历史检测前景,结合运动速度提取,改进了基于特征的人群计数方法。但估计人口密集的人群数量是基于多源图像的信息而不是一般的监控视频。

到稿日期:2017-03-17 返修日期:2017-07-28 本文受贵州省基础研究重大项目(黔科合 J 字 20142001),贵州省科技合作计划重点项目(黔科合 LH 字 20157763),住房和城乡建设部科学技术计划项目(2016-K3-009),全国统计科学研究项目(2016LY81)资助。

徐 洋(1983-),男,博士后,副教授,硕士生导师,主要研究方向为机器学习、信息安全、大数据等,E-mail:xy@gznu.edu.cn(通信作者);陈 燧(1992-),男,硕士,主要研究方向为机器学习、信息安全;黄 磊(1981-),男,主要研究方向为网络安全;谢晓尧(1952-),男,博士,教授,博士生导师,主要研究方向为大数据、信息安全。

密度估计计数是通过一种概率估计的方式来估计结果。文献[6]提出了一种基于对象密度图回归的计数方法,这种方法旨在利用随机森林回归来提高训练效率。基于密度回归的方法不仅考虑了空间信息,还能够在一幅图像的任何区域评估对象的数量。文献[7]首先将图像均匀分块,计算图像块的平均梯度,然后构造视频动态纹理,比较相邻帧的动态纹理相关性和 SIFT 特征匹配程度,并根据匹配程度得出检测结果。然而,上述方法适用于特定场景,不适用于跨场景计数。

对于各种监控应用,许多方法引入了深度学习,如行人检测<sup>[8]</sup>、群体行为分析<sup>[9]</sup>和人群分割<sup>[10]</sup>等。然而,学习方法的训练和测试识别时间往往较长,限制了实际应用,而且特定场景的训练会造成对新场景的不适应<sup>[11]</sup>。

人群计数的目标是从图像中学习映射关系,然后在新的目标场景中使用该映射。其主要挑战是:1)开发有效的特征来描述人群;2)不同的场景有不同的透视形变、人群分布和照明条件,没有额外的训练数据,在一个特定的场景中训练的模型很难用于其他场景;3)对于大多数方法,前景分割是人群计数不可缺少的步骤,但是,在拥挤的场景中,不能准确地分割出人群,而且人群静止和运动同时存在。

针对这些挑战,在 BP 神经网络的框架下,引入数据驱动方法来微调训练好的 BP,以使其适应一个新的目标场景。本文的主要工作如下:

1)BP 模型使用切换学习对人群场景进行训练,学习的目标是人群密度图和人群数量。这两者可以相互协助,以获得更好的局部最优解。

2)目标场景不需要额外的标签,预训练的 BP 模型将对每个目标场景进行微调,消除了不同场景之间的区别。

3)提出的方法不依赖于前景分割结果,因为其只考虑外观信息,无论人群是否移动,人群纹理都会被 BP 模型捕捉。

## 2 提出的方法

### 2.1 归一化的人群密度图

本文提出的人群 BP 模型的主要目标是学习映射关系。 $F: X \rightarrow D$ ,其中, $X$ 是一组从训练图像中提取的底层特征集, $D$ 是图像的人群密度图。假设每个行人的位置都已经被标记,密度图的创建基于行人空间位置、人体形状和图像透视形变。从训练图像中随机选择图像块作为训练样本,相应图像块的密度图被视为人群 BP 模型的参考标准。作为一个辅助目标,被选训练块中的总人群数是通过整合的密度图计算得出的。这个总数将是一个小数,而不是一个整数。

一般情况下,定义密度图回归中的真实数据为集中在目标位置的高斯核总和<sup>[6]</sup>。这种密度图适用于描述圆形物体(如细胞和细菌)的密度分布。然而,将它用于人群时,这种假设可能不成立,因为相机一般不是以俯瞰视角进行拍摄的。行人图片有 3 个明显的特征:1)在监控视频中的行人图像因透视形变而具有不同的尺寸;2)行人的形状更类似于椭圆;3)由于遮蔽,头部和肩膀成为了用于判断每个位置是否存在行人的主要线索,而行人的身体部分对于行人的识别是不可靠的。考虑到这些特点,人群密度图的创建可由几个透视归一化的分布组合而成。

受文献[4]的启发,本文为每一个场景随机选择一些成年

行人,并从头到脚进行标注。假设成人的平均身高为 170 cm,则透视图可以通过线性回归近似得到,在获取透视图和感兴趣区域(ROI)中行人头部  $P_h$  的中心位置后,利用式(1)创建人群密度图:

$$D_i(p) = \sum_{P \in P_i} \frac{1}{\|Z\|} (N_h(p; P_h, \sigma_h) + N_b(p; P_b, \Sigma)) \quad (1)$$

其中,人群密度分布内核包含两项:归一化的二维高斯核  $N_h$ ,表示头部;双变量归一化分布  $N_b$ ,表示身体。 $P_b$  是行人身体的位置,由头部位置和透视远近值估计获得。为了最好地表示行人的轮廓,为  $N_b$  设置方差  $\sigma_h = 0.2M(p)$ ,为  $N_h$  设置方差  $\sigma_x = 0.2M(p)$ , $\sigma_y = 0.5M(p)$ ,以确保密度图中所有密度值的集合等于原始图像中的人群总数。总分布由  $Z$  归一化。

### 2.2 人群多层 BP 模型

输入是从训练图像中裁切的图像块。为了获得相似尺度的行人,每个不同位置的图像块尺寸按照图像中心像素的透视值选择。使每个图像块覆盖一个实际场景中  $9\text{m}^2$  的平面,然后把图像块缩放到  $72 \times 72$  像素并,将其作为人群 BP 模型的输入。提出的人群 BP 模型包括输入层、输出层和 3 个隐层(h1, h2 和 h3)。h1 中有 32 个  $7 \times 7 \times 4$  的滤波器,h2 中有 32 个  $5 \times 5 \times 32$  的滤波器,h3 中有 64 个  $3 \times 3 \times 32$  的滤波器。

在人群模型中,引入一种迭代切换处理来优化密度图的估计任务。人群 BP 模型的第一个任务是估计输入块的人群密度图。输出密度图下采样到  $18 \times 18$  大小,因此真实数据密度图也下采样到  $18 \times 18$  大小。由于密度图包含丰富的局部和细节信息,该 BP 模型能通过学习预测密度图,得到一个更具代表性的人群块。人群 BP 模型的第二个任务是计算输入图像块的总计数回归,由整合密度图的图像块计算获得。这两项任务的损失函数定义如下:

$$L_D(\Theta) = \frac{1}{N} \sum_i \|F_d(X_i; \Theta) - D_i\|^2 \quad (2)$$

$$L_Y(\Theta) = \frac{1}{N} \sum_i \|F_y(X_i; \Theta) - Y_i\|^2 \quad (3)$$

其中, $\Theta$  是 BP 模型的参数集, $N$  是训练样本的数目。 $L_D$  是估计密度图  $F_d(X_i; \Theta)$ (即 h2 的输出)和真实数据密度图  $D_i$  之间的损失。同理, $L_Y$  是估计人群数  $F_y(X_i; \Theta)$ (即 h3 的输出)和真实数据数  $Y_i$  之间的损失。两个目标之间的损失均采用欧氏距离度量。使用分批处理梯度下降法和反向传播法使损失最小化。

算法 1 描述了可切换训练的步骤。本文设置  $L_D$  为第一目标的损失。由于密度图可以引入更多的空间信息,因此密度图估计要求模型为人群学习的一般表示。在第一目标收敛后,模型切换到最小化全局计数回归,即第二个目标。计数回归是相对简单的任务,且其学习收敛速度比密度图回归任务更快。这里,两个目标的损失应该归一化到相同尺度,否则大尺寸目标将在训练过程中占主导地位。在实验中,本文将密度损失的尺度权重设置为 8,将计数的尺度权重设置为 1,训练损失在大约 8 次迭代后收敛。提出的切换学习方式可以取得较好的性能。

#### 算法 1 迭代切换损失训练

输入:训练集(其带有从整个训练数据中得到的计数和密度图的尺度归一化图像块)

输出:人群 BP 模型参数  $\Theta$

1. 将  $L_D$  设置为第一目标;
2. for  $t=1$  to  $T$  do
3. BP 学习  $\Theta$ ,直到确定损失率  $\Delta L$  降低到阈值  $\epsilon$  以下;
4. 切换目标损失函数;
5. end

### 3 后续优化:无参数微调

人群 BP 模型通过本文提出的切换学习过程且基于所有训练场景数据进行预训练。然而,每个人群场景都有其独特的场景属性,如不同的视角、尺度和密度分布。这些属性显著改变了人群块的外观,影响了人群的神经网络模型的性能<sup>[12]</sup>。为了弥补训练场景和测试场景之间的差距,本文设计了一个无参数微调方案,使预训练 BP 模型自适应新的目标场景。在训练场景中,检索有相同属性的样本,添加训练数据来微调人群 BP 模型。该检索任务由两个部分组成,即候选场景检索和局部块检索。

#### 3.1 第一步优化:候选场景检索

众所周知,场景的视角和尺度是影响人群外观的主要因素。透视图可以显示视图的视角和比例。为了消除不同场景之间的尺度差距,将每个输入图像块归一化到相同尺寸,根据透视图,图像块在现实场景中占地  $3\text{ m} \times 3\text{ m}$ 。因此,本文提出的无参数微调法第一步的重点是在所有训练场景中检索与目标场景有类似视角的训练场景,这些检索场景被称为候选微调场景。本文设定透视描述符代表每个场景的视角,由于透视图沿  $y$  轴线性拟合,本文使用垂直梯度  $\Delta M_y$  描述视角。

#### 3.2 第二步优化:局部块检索

从候选场景中选择相似块,即测试场景中拥有相似密度分布的图像块。除了视角和尺度,人群密度分布也影响人群的外观形态。更高密度的人群有更加严重的遮挡,只有头和肩膀可以被看到。相反,在稀疏的人群中,行人会展现出完整的身体形态。本文尝试预测目标场景的密度分布,并从候选场景中检索与预测目标密度分布相匹配的相似块。例如,对于一个高密度的人群场景,高密度的图像块更容易被检索出来,用以微调预训练模型以适应目标场景。

利用提出的预训练 BP 模型可以粗略地预测目标图像每个块的密度及总数。假设拥有类似密度图的图像块通过预训练模型将有类似的输出。基于预测结果,本文为目标场景计算一个密度分布直方图,直方图中每个条块(bins)的计算如下:

$$c_i = \lfloor \ln(\hat{y}_i + 1) \times 2 \rfloor \quad (4)$$

其中,  $\hat{y}_i$  是样本  $i$  估计密度图的积分计数。因为  $3\text{ m} \times 3\text{ m}$  的平面上几乎不可能同时存在 20 个以上的行人,当  $\hat{y}_i > 20$  时,将图像块分为 6 组,即  $c_i = 6$ 。目标场景的密度分布可以通过式(4)求得。从检索后的训练场景中随机选择图像块,不同密度图像块的数目和目标场景的密度分布相匹配。以本文的微调方法检索具有相似视角、规模和密度分布的图像块。实验结果表明:对于目标场景,微调后的人群 BP 模型取得了更好的性能。

## 4 实验与分析

使用 3 个不同的数据集进行实验,分别为 PETS2009 人

群计数数据集<sup>[13]</sup>、UCSD 行人数据集<sup>[14]</sup>和 UCF\_CC\_50 数据集<sup>[15]</sup>,其详细信息如表 1 所列。其中,  $N_f$  表示帧数,  $N_c$  表示场景数,  $R$  表示分辨率,  $FPS$  表示每分钟的帧数,  $D$  表示在某一帧的感兴趣区域中人数的最小值和最大值,  $T_p$  表示带标记的行人总数。

表 1 3 个数据集的信息

Table 1 Information of three data sets

数据集	$N_f$	$N_c$	$R$	$FPS$	$D$	$T_p$
UCSD	2000	1	$158 \times 238$	10	11,46	49885
PETS2009	150	10	$576 \times 480$	50	2,23	10023
UCF_CC_50	50	50	—	图片	94,4543	63974

### 4.1 PETS2009 数据集

首先,引入较小规模的人群计数数据集,即 PETS2009 数据集的户外校园视频,每个相机每帧平均能看到 25 个人,由 6 个监控摄像机拍摄。由于频繁的遮挡和突然的运动变化,跟踪群组内的个人比较困难。在此数据集中,把数据集分成两个部分。测试集包含 5 个来自 5 个不同场景的 1 小时时长的视频序列。每个测试场景中有 25 个标记的帧,两帧之间的间隔为 30 s。

本文采用平均绝对误差(Mean Absolute Error, MAE)作为评价指标。PETS2009 数据集上的平均绝对误差如表 2 所列。本文提取 LBP 特征并使用岭回归<sup>[16]</sup>(Ridge Regression, RR)估计人群人数,结果如表 2 中第一行所列。未经微调的人群 BP 模型的预测结果如表 2 中第二行所列。使用数据驱动微调的人群 BP 模型的预测结果如表 2 中第三行所列。这 3 种方法不使用测试场景的任何数据。提出的人群 BP 模型可以有效地估计密度图和人群计数。在一些测试场景中,数据驱动的微调方法提高了计数的准确性。从训练数据中检索到的相似样本可以帮助该模型更好地拟合测试数据。

表 2 PETS2009 人群数据集的平均绝对误差

Table 2 Mean absolute errors of PETS2009 crowd counting dataset

方法	场景 1	场景 2	场景 3	场景 4	场景 5	平均
LBP+RR	12.5	57.3	37.2	21.9	23.5	31.5
人群 BP	10.2	14.2	15.4	25.7	4.2	13.9
微调后的人群 BP	9.7	13.2	14.4	22.3	3.8	12.7
文献[4]的方法	2.3	86.6	22.3	16.5	5.5	26.6
文献[7]的方法	2.2	54.7	9.7	11.4	3.5	16.3
本文方法	1.8	25.8	9.9	10.0	3.1	10.1

目标场景中的一些辅助标签可以提升所提方法的性能,具体场景信息的引入也可以消除大部分背景噪声。因此,预测密度图可以被视为特征和用于拟合行人数量的岭回归。相比之下,文献[4]的方法是全局回归法,使用了多种手工特征,包括面积、周长、边缘和局部纹理特征;而文献[7]采用多特征镜头检测。这两种方法使用每个测试场景中前 60 个带标记的帧训练,剩下的帧用作测试集。由于场景 2 中存在大量的固定人群,很难获得准确的前景,本文提出的跨场景人群计数方法优于传统方法,如表 2 所列。从表 2 还可以看出,对于测试场景 1、场景 3 和场景 4,提出的方法的误差都有明显的降低。对于场景 2,岭回归的结果比较差,这是因为前 60 个训练帧的密度分布和剩下的测试帧的密度分布有明显差异。

图 1 给出了 PETS2009 数据集在某个场景下的跟踪结

果,可以看出场较为拥挤且存在遮挡。本文用不同框图显示群组变化。




图1 PETS2009数据集中的某个场景下的跟踪结果

Fig.1 Trace results of certain scene on PETS2009 dataset

#### 4.2 UCSD数据集

为了验证单场景人群计数,从校园的监控相机拍摄的视频中选择一个2000帧的视频数据集<sup>[13]</sup>。数据集的视频尺寸为 $158 \times 238$ ,帧率为10 fps。数据集提供了感兴趣区域和透视图,带标记的真实数据位于每个行人的中心。图2给出了UCSD数据集的一个视频图像实例。



图2 UCSD数据集的视频图像实例

Fig.2 Video image instance of UCSD dataset

将501-1300帧作为训练数据,并把其余1200帧作为测试集,从未经归一化的图像中提取 $72 \times 72$ 的图像块。从每个图像中随机裁剪800个图像块来训练模型。对于测试集,图像块以50%重叠的滑动窗口形式提取。每个像素的密度估计值由所有预测重叠块取平均值获得。可以将BP模型中得到的预测密度图视为特征,而岭回归用来拟合训练集。表3列出了提出的方法和其他方法的错误率比较结果,其采用了两个指标,即平均绝对误差MAE和均方误差MSE。特别地,提出的方法对感兴趣区域进行测试时不依赖于任何前景信息,而其他对比方法则依赖于前景分割功能。

表3中用于对比的方法采用了类似的手工定义的特征,如分割特征(面积和周长)、用canny算子得到的边缘特征和局部纹理特征。实验结果表明,通过合并额外的密度信息,本文方法提高了人群计数的准确性。

表3 UCSD数据集上的误差比较

Table 3 Error comparison on UCSD dataset

方法	MAE	MSE
岭回归	2.06	7.38
文献[4]的方法	2.13	7.75
文献[6]的方法	2.12	7.89
文献[7]的方法	1.96	6.79
本文方法	1.58	3.24

将提出的方法在UCSD数据集上的平均绝对误差与文献[6]、文献[7]的方法进行比较,结果如表4所列。该数据被分成4种不同的训练集和测试集:1)“最大”,训练帧为500:5:1300;2)“降低”,训练帧为1105:5:1500;3)“上升”,训练帧为705:5:1000;4)“最小”,训练帧为540:80:1260训练。

训练范围以外的帧用于测试,4组数据以不同的训练图像数和不同的平均行人数进行划分。

表4 UCSD数据集上的平均绝对误差

Table 4 Mean absolute error on UCSD dataset

方法	最大	降低	上升	最小
文献[6]的方法	1.73	1.27	1.74	2.03
文献[7]的方法	1.23	1.32	1.79	1.53
本文方法	1.69	1.24	1.63	1.55

由表4可以看出,“降低”和“上升”均取得最优,而文献[7]在“最大”和“最小”取得最优,这主要归功于其使用了前景分割。

#### 4.3 UCF\_CC\_50数据集

UCF\_CC\_50数据集<sup>[15]</sup>包含从网上搜集的图片,是一个具有挑战性的数据集,因为数据集中只有50幅图片,行人数目为94~4543。该数据集是带标记的真实数据,可用来产生真实数据密度图。该数据集的部分图像实例如图3所示。



图3 UCF\_CC\_50数据集的部分图像实例

Fig.3 Partial image instance of the UCF\_CC\_50 dataset

随机划分数据集,执行5折交叉验证,并将MAE和MSE作为评价指标。实验的设置与UCSD数据集相似。从每个图像中随机裁剪1200个图像块用于训练。图像块的尺寸为 $72 \times 72$ 。测试图像块是以50%的重叠率进行选择的。每个像素的预测密度通过重叠的预测图像块的平均值获得。误差比较结果如表5所列。

表5 UCF\_CC\_50数据集上的误差比较

Table 5 Error comparison on UCF\_CC\_50 dataset

方法	MAE	MSE
文献[4]的方法	5.53	7.85
文献[6]的方法	4.21	7.08
文献[7]的方法	7.87	9.32
本文方法	2.93	3.82

在UCF\_CC\_50数据集上比较了3种方法,文献[4]是一种全局回归方法,文献[6]利用密度图估计提高人群检测结果,文献[7]采用多特征镜头检测。这3种方法都没有后处理过程。从表5可以看出,提出的方法获得了最好的MAE结果,并有效地实现了跨场景计数,其有效性和优越性在另一个数据集上得到了验证。

**结束语** 该文使用多层BP神经网络解决跨场景人群计数问题,并利用两个相关的学习目标交替训练,提出的可切换学习方法能够为目标获得更好的局部最优解。为了处理新场景,提出一种数据驱动的方法为目标场景进行微调训练。在3个数据集上的实验结果验证了提出的方法的可行性和优势。

BP模型虽然被成功地应用,但依然有一些缺陷,如BP还无法扩展到平面视觉以外的地方。未来将考虑能否按照重要程度进行局部训练。

## 参 考 文 献

- [1] HASHEMZADEH M. Crowd Counting Using Motion Clues of Feature-Points [D]. Hangzhou: Zhejiang University, 2013. (in Chinese)  
Hashemzadeh M. 基于特征点运动信息的人群计数方法研究 [D]. 杭州:浙江大学,2013.
- [2] QIN X H, WANG X F, ZHOU X, et al. Counting People in Various Crowded Density Scenes Using Support Vector Regression [J]. Journal of Image and Graphics, 2013, 18(4): 392-398. (in Chinese)  
覃勋辉,王修飞,周曦,等. 多种人群密度场景下的人群计数[J]. 中国图象图形学报, 2013, 18(4): 392-398.
- [3] LIANG R H, LIU X D, MA X Y, et al. High-Density Crowd Counting Method Based on SURF Feature [J]. Journal of Computer-Aided Design & Computer Graphics, 2012, 27(12): 1568-1575. (in Chinese)  
梁荣华,刘向东,马祥音,等. 基于 SURF 的高密度人群计数方法[J]. 计算机辅助设计与图形学学报, 2012, 27(12): 1568-1575.
- [4] CHEN C L, GONG S, XIANG T. From Semi-supervised to Transfer Counting of Crowds [C] // 2013 IEEE International Conference on Computer Vision (ICCV). IEEE, 2013: 2256-2263.
- [5] JI Q G, CHEN J, CHI R, et al. Counting Pedestrians in High-Density Crowd Scenes Using Cross-Sectional Flow Statistics [J]. Journal of Software, 2014, 25(S2): 258-267. (in Chinese)  
纪庆革,陈婧,迟锐,等. 采用截面流量统计的高密度人群行人计数[J]. 软件学报, 2014, 25(S2): 258-267.
- [6] LEMPITSKY V S, ZISSERMAN A. Learning To Count Objects in Images [J]. NIPS, 2010, 43(3): 1591.
- [7] PENG T L, ZHANG W J, WANG Y B, et al. Video shot boundary detection algorithm based on multi-features [J]. Chinese Journal of Scientific Instrument, 2015, 36(9): 2013-2020. (in Chinese)  
彭太乐,张文俊,汪友宝,等. 基于多特征的视频镜头检测方法 [J]. 仪器仪表学报, 2015, 36(9): 2013-2020.
- [8] LI R P. The application of deep learning in pedestrian re-identification [D]. Beijing: University of Chinese Academy of Sciences, 2013. (in Chinese)  
李瑞平. 深度学习在行人重现检测中的应用研究 [D]. 北京:中国科学院大学, 2013.
- [9] JING S, KAI K, CHEN L, et al. Deeply learned attributes for crowd scene understanding [C] // IEEE Conference on Computer Vision and Pattern Recognition. 2015: 4657-4666.
- [10] KANG K, WANG X. Fully Convolutional Neural Networks for Crowd Segmentation [J]. Computer Science, 2014, 49(1): 25-30.
- [11] RYAN D, DENMAN S, FOOKES C, et al. Crowd Counting Using Multiple Local Features [C] // Digital Image Computing: Techniques & Applications. 2009: 81-88.
- [12] PATTERSON G, XU C, SU H, et al. The SUN Attribute Database: Beyond Categories for Deeper Scene Understanding [J]. International Journal of Computer Vision, 2014, 108(2): 59-81.
- [13] FU H Y. Research on intelligent video scene understanding technology for crowd supervision [D]. Beijing: Beijing University of Posts and Telecommunications, 2014. (in Chinese)  
傅慧源. 面向人群监管的智能视频场景理解技术研究 [D]. 北京:北京邮电大学, 2014.
- [14] CHAN A B, LIANG Z S J, VASCONCELOS N. Privacy preserving crowd monitoring: Counting people without people models or tracking [C] // IEEE Computer Society Conference on Computer Vision and Pattern Recognition. 2008: 1-7.
- [15] 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. IEEE, 2013: 2547-2554.
- [16] YIN K. Comparison and analysis of commonly used statistical software on ridge regression calculation principle [J]. Statistical Research, 2013, 30(2): 109-112. (in Chinese)  
尹康. 常用统计软件关于岭回归计算原理的比较分析 [J]. 统计研究, 2013, 30(2): 109-112.
- [5] BAI J, LU R. Finite-time stability analysis of discrete-time fuzzy hopfield neural network [J]. Neurocomputing, 2015, 159(2): 263-267.
- [6] CAO Y. Dynamic modeling and neural network adaptive control of a deployable manipulator system [J]. Journal of Guidance Control & Dynamics, 2015, 29(1): 192-195.
- [7] ZHANG Y, CHEN D C, GUO D S. On exponential convergence of nonlinear gradient dynamics system with application to square root finding [J]. Nonlinear Dynamics, 2015, 79(2): 983-1003.
- [8] LI S. Accelerating a recurrent neural network to finite-time convergence for solving time-varying Sylvester equation by using a sign-bi-power activation function [J]. Neural Processing Letters, 2013, 37(2): 189-205.
- [9] WANG J. Analysis and design of a recurrent neural networks for linear programming [J]. IEEE Transactions on Circuits and Systems, 1993, 40(9): 613-618.
- [10] WHITNEY D E. Resolved motion rate control of manipulators and human prostheses [J]. IEEE Transactions on Man Machine Systems, 1969, 10(2): 467-453.
- [11] POLVERINI M, ZANCHETTIN A. A computationally efficient safety assessment for collaborative robotics applications [J]. Robotics and Computer-Integrated Manufacturing, 2017, 46: 25-37.
- [12] CHEN F T, SUN Y Y. Resolving manipulator redundancy under inequality constraints [J]. IEEE Transactions on Robotics Automation, 1994, 10(1): 65-71.
- [13] JIN L, ZHANG Y N. Neural network-based discrete-time Z-type model of high accuracy in noisy environments for solving dynamic system of linear equations [J]. Neural Computing & Applications, 2018, 29(11): 1217-1232.
- [14] LI Z P, SHAO X Y, ZHANG D X, et al. Steering System Control Strategy Based on Overview of Automotive Electric Power [J]. Journal of Chongqing Institute of Technology, 2015, 29(8): 6-11. (in Chinese)  
李志鹏,邵友友,张东兴,等. 基于 BP 神经网络的电控发动机故障诊断研究 [J]. 重庆理工大学学报(自然科学), 2015, 29(8): 6-11.

(上接第 211 页)