

# 基于多级子网络和排序性 Dropout 机制的人脸属性识别

高淑蕾 周 冕 薛彦兵 徐光平 高 赞 张 桦

(天津理工大学计算机视觉与系统省部共建教育部重点实验室, 天津市智能计算及软件新技术重点实验室, 天津, 300384)

**摘 要:** 如何提高自然环境下或非受限环境下人脸属性识别的准确率是应用人脸属性的一个重要问题。在日常生活中, 人脸姿势和光照等不可控制的因素对识别人脸属性产生了较大影响, 如何在上述因素影响下提高识别的精度是我们研究人脸属性识别的关键问题。目前卷积神经网络(Convolutional neural network, CNN)在图像分类中已经取得显著性成果, 本文通过采用多级子网络和排序性 Dropout 机制算法重新构建一个网络结构, 该结构对处理人脸姿势变化等具有较强的鲁棒性, 在 CelebA 数据集和 LFWA 数据集中取得较好的效果, 且大大降低了网络体积。

**关键词:** 卷积神经网络; 人脸属性识别; 深度学习; 多级子网络; 排序性 Dropout 机制

**中图分类号:** TP391      **文献标志码:** A

## Face Attributes Recognition by Multi-level Sub-network and Ranked Dropout Mechanism

Gao Shulei, Zhou Mian, Xue Yanbing, Xu Guangping, Gao Zan, Zhang Hua

(Key Laboratory of Computer Vision and System, Ministry of Education, Tianjin Key Laboratory of Intelligence Computing and Novel Software Technology, Tianjin University of Technology, Tianjin, 300384, China)

**Abstract:** How to improve the accuracy of face attributes recognition in natural environment or unrestricted environment is an important question in applying face attributes. In daily life, the uncontrollable factors, such as face postures and light, have a great influence on the recognition of human face attributes. How to improve the accuracy under the influence of the above factors is a key problem in the study of face attribute recognition. Given the success of convolutional neural network (CNN) in image classification, a new network structure is built by using multi-level sub-network and ranked Dropout mechanism algorithm. The structure has strong robustness to deal with face changes, thus achieving better results in the CelebA dataset and LFWA dataset, and reducing the network size significantly as well.

**Key words:** convolution neural network; face attributes prediction; deep learning; multi-level sub-network; ranked dropout mechanism

## 引 言

人脸识别的应用在日常生活中发挥着越来越重要的作用, 备受学者关注。传统的人脸识别方法有

多种,最具有代表性的如特征脸方法(Eigenface)<sup>[1]</sup>等;同时3D人脸识别也是一个新的研究方向<sup>[2]</sup>。但是,由于受到姿态、光照及表情变化遮挡等因素的影响,传统的人脸识别方法自身的局限性,其识别精度受到制约。近几年,卷积神经网络已在人脸识别等应用领域取得显著性成果。国际上许多学者和公司将深度学习成功地运用到人脸识别中,如DeepID<sup>[3]</sup>、DeepFace<sup>[4]</sup>、FaceNet<sup>[5]</sup>等,上述算法均基于海量的数据集进行训练,利用CNN可自动地从海量的数据中学习对于光照、表情、角度等不变的特性。其中FaceNet在LFW<sub>1</sub>数据集<sup>[6]</sup>上达到99.63%的准确率位居第一,已超过了人眼的识别结果。LFW数据集是由美国马萨诸塞大学阿姆斯特分校计算机视觉实验室整理完成,用于研究无约束条件下人脸识别问题,已成为学术界评价识别性能的标准参照。

上述研究方法表明人脸识别的科学问题利用大数据集和深度学习已得到较好的解决。随着人脸识别技术的逐渐成熟,人脸属性识别也受到了越来越多的关注,同时人脸识别涉及到人的身份信息是较为敏感的信息,而人脸属性识别略过了这一敏感区域,所以有更加广泛的应用前景,比如,在安防方面对特定族群的识别。然而,人脸属性识别也同样面临人脸识别所面对的问题,如光照,姿势,表情等因素的影响,还需考虑其他面部特征,如鼻子、眼睛的大小等。Liu等<sup>[7]</sup>提出在自然环境下将人脸定位和人脸属性预测为一体的CNN框架。LNet首先负责从复杂的背景中定位人脸位置,ANet是在LNet的基础上进行人脸属性预测。LNet+ANet<sup>[7]</sup>算法同时也为CelebA数据集提供了评价标准。Zhong等<sup>[8]</sup>通过提取CNN中不同层的人脸特征,然后分析每个属性在不同CNN中的层次特征,通过支持向量机得到预测结果(Best representation)得出不同层次的特征在不同的人脸属性上有不同的效果。

上述方法在人脸属性识别方面获得了很好的效果,但均是由两个步骤完成:首先利用CNN提取特征,然后再利用支持向量机得到分类结果;而且只考虑了如何提高人脸属性的准确率,忽略了网络模型体积的大小。本文从如何提高人脸属性识别的准确率同时缩小网络模型的体积角度综合考虑,设计了一个新的CNN结构,通过大量实验证明了该网络的有效性,这项工作的主要贡献可以分为以下两点:

(1) 通过采用多级子网络结构,可从多角度学习人脸特征,且增加了网络的深度,使训练结果更精准地进行拟合,大大提高了两个大规模数据集的识别率。

(2) 通过排序性Dropout机制,可以选择出响应值较高的卷积核滤波器,保留对网络贡献较大的神经元,在提高识别精度的同时又缩小了网络模型体积。

## 1 CNN 框架

CNN作为一种特殊的深度学习架构凭其优秀的表现再次受到许多学者广泛的关注,且因具有局部感受区域、层次结构化、特征提取和分类过程相结合的全局训练的特点和自动地从海量的数据中学习对于光照、表情、角度等不变的特性,故本文利用CNN架构<sup>[9]</sup>来解决人脸属性识别问题,网络结构图如图1所示。

本文网络由4个子网络构成,共有31层。每个卷积层后面均有一个非线性的激活函数,可增加特征的非线性,使学习到的特征更拟合训练数据,效果达到最好。最后使用SPP<sup>[10]</sup>层,可以增加多个尺度的特征映射图,更加有利于人脸属性的识别。相较于其他人脸属性识别深度学习的算法,本文网络结构更深,其训练结果可对训练数据更准确地拟合,识别精度相较于LNet+ANet、Best Representation算法更高。

### 1.1 多级子网络

在CNN中,使用更多的滤波器和构建深层次的网络结构可学习到更丰富的特征信息,有助于提升整个网络的识别率。然而,CNN中的卷积层是用线性滤波器对图像进行内积运算,在每个局部输出后用一个非线性的激活函数得到特征映射图,这种卷积滤波器是一种广义线性模型(Generalized linear




图 1 本文 CNN 结构的总框架,由 4 个子神经网络和 2 个全连接层构成

Fig. 1 Overall structure of the proposed CNN, encompassing the stacking of four sub-neural networks and two full connected layers

model, GLM)。其抽象能力是较低水平的。抽象是对同一概念的不同变体保持不变的特征,其实就隐含性地假设特征是线性可分的,但是实际问题往往是难以线性可分的,所以这里用一种抽象能力更强的模型去替换它,从而提高 CNN 的表达能力。而且层次较深的网络层是对较浅网络层学习到特征的整合,在对特征进行高层次整合之前,进一步的抽象是必要的。

在构建更深层次网络模型的过程中通过采用(Network in network, NIN)<sup>[11]</sup>思想,又从人脸姿势的多样性和光照的不可改变性因素考虑,将网络结构可分为 4 个子网络,除去第一个卷积层,其他卷积层均采用 pad 为 1 的卷积核(pad:1 是指在原图的左右两边分别补充一个像素值为 0 的像素块);每个子网络由 3 个卷积层构成,如图 2(b)所示。图 2(a)是一个普通的线性卷积层,图 2(b)是一个子神经网络,在每个子网络中,经过多次卷积,特征映射图尺寸保持不变,即在不损失图像分辨率的前提下,对局部感受野的神经元进行更加复杂的运算,使 CNN 能够学习到更加抽象和有效的非线性特征,使局部模型有更强的抽象能力,从整体上增强了整个网络的表达能力。使用多级子网络结构,大大提高了人脸属性的精度,主要可归为以下两点原因:

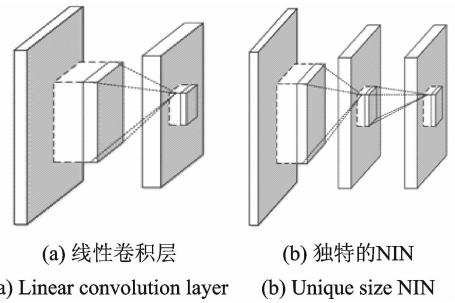


图 2 线性卷积层和独特的 NIN 结构对比  
Fig. 2 Comparison of linear convolution layer and unique size NIN

(1) 由于人脸受到其姿势多变和光照等不可控制因素的影响,选择采用的卷积核能更好的获得图像的局部特征,即是对图像的细化,更适用于人脸面部结构;而较大的卷积核,是非局部、更全局的特征,不适用于人脸属性较为细微的结构;同时增加卷积核参数的个数,使滤波器学习到更充分更丰富的人脸属性特征信息,有助于提高网络的识别率。

(2) 在每个子网络中,经过多次卷积,特征映射图不变,即没有损失分辨率,又可以从多个角度学习到更多的人脸特征信息,迎合了人脸姿势多变的需求;且子网络间的特征映射图呈等级趋势缩小,不仅可以丢弃冗余信息,又能学习到最具代表性的特征信息,增强网络的表达能力,而且还可以增加网络深度,从整体上提高人脸属性识别的准确率。

### 1.2 排序性 Dropout 机制

在 CNN 中,不同的滤波器在图片的像素上有不同的权值。权值不同,卷积核滤波器可视化后的特征映射图就不同,一部分特征映射图可清晰地描绘出物体的轮廓纹理信息;一部分特征映射图则较模糊,因此从特征映射图角度,可将 CNN 分为两段:高响应段和低响应段。为了评估每一个卷积核滤波器对卷积模型的贡献度,本文定义了一种评估标准——平均响应值(Average response energy, ARE),每一

个响应值由被测卷积核滤波器计算后的特征映射统计得到,如果该卷积核滤波器的响应值高说明该卷积核滤波器对于模型贡献度大,否则,对网络贡献度较小。2012年, Hinton 等人提出 Dropout<sup>[12]</sup> 思想,在深度学习网络的训练过程中,按照一定的概率随机丢弃网络中的神经网络单元以防止过拟合现象的发生,同时也提高了训练效果,如经典的 AlexNet<sup>[13]</sup> 网络等。但由于是随机丢弃一些神经网络单元,在一定程度上可能舍弃响应值较高的神经网络单元,对网络损失较大。

从两个维度来分析一个标准的 CNN:深度和宽度。深度代表的是该网络有多少层结构,宽度即每一个卷积层的滤波器卷积核的数量。将本文中网络结构的第一个卷积层可视化得出其特征映射图,如图 3 所示。由图 3(b)可知,在 64 个卷积特征映射图中,一些特征映射图可清晰的描述出原图中的轮廓特征,对网络的贡献程度大;而其他的一些特征映射图对原图响应值较低,轮廓特征或纹理信息比较模糊,对网络的贡献程度较小。但是在一个网络结构中,若一个卷积层有数百个甚至上千个卷积核滤波器,即可对应的卷积特征映射,通过可视化的方法来判断是不可行的。

$$ARE = \frac{\sum_{j=1}^k \bar{E}_j}{\sum_{j=1}^n \bar{E}_j} \quad (1)$$

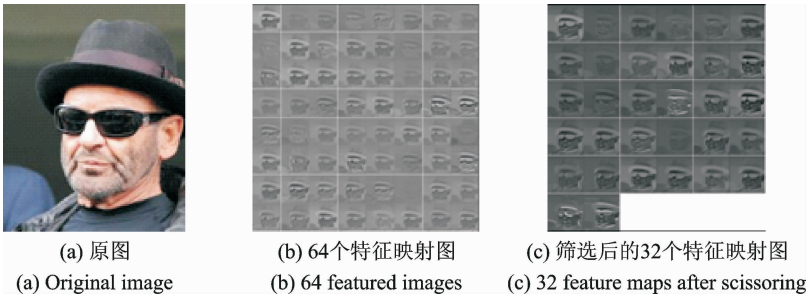


图 3 特征映射图对比

Fig. 3 Feature map comparison

通过 ARE 阈值的方法来计算,如式(1),其中  $k$  为需要保留的卷积核数目,  $n$  为当前卷积层的卷积核个数,  $E_j$  代表的是  $j$  通道的响应值。ARE 阈值是通过计算每一个卷积层中每一个卷积核滤波器的 ARE 来统计并对所有的卷积核滤波器的贡献程度进行排序, ARE 值越高,代表该滤波器对网络的贡献程度越大,即将网络中的神经元进行排序,选择贡献度较大的神经元。通过该方法即可避免 Dropout 中随机丢弃神经元所造成的损失,又可以防止过拟合现象的发生。通过实验可得出, 阈值选定为 0.99, 可以通过公式得到满足条件的最小  $k$  值, 计算出保留  $k$  个高 ARE 卷积核滤波器, 可以得到一个和原始网络模型相差无几的效果, 但是又可以减少参数, 缩小网络模型体积。通过调整阈值的大小调整每个卷积层的滤波器个数, 寻找到一个合适的阈值来达到模型性能的最优。本文将一个完整的 CNN 通过高低 ARE 排序的方式进行选取, 分别选取每个卷积层中原有滤波器数量 1/2 高 ARE 卷积核滤波器, 其他均舍弃, 即有选择性地 Dropout, 将筛选后滤波器卷积后的特征映射图可视化后如图 3(c) 所示, 可清晰地描绘出图像的轮廓特征。

本文分别选取网络结构中每个卷积层中的 1/2 ARE 高的滤波器, 将其封装成一个新的网络模型, 其他参数设置均保持不变。为了验证本文筛选策略是否有效, 将原始网络模型和重构网络模型分别在 CelebA 数据集和 LFWA 数据集做对比, 如表 1 所示。第 2 列代表的是网络模型的大小, 原始网络模型的参数是重构网络模型的 4.6 倍, 并分别在 CelebA 数据集和 LFWA 数据集上进行实验, 实验前后的精

度相差不超过 1%,但大大地减少了网络模型的体积,并减少了训练时间。

表 1 模型大小及数据集准确率对比表

Tab. 1 The size of model and dataset accuracy comparison

模型	CNN 模型	CelebA_mAP/%	LFWA_mAP/%
原始	121.7 M	90.9	87.8
重构	26.3 M	91.4	88.6

为验证通过排序性 Dropout 方法来减少网络模型的体积应用到其他网络上是否有效,本文又在 CNN 模型 ZFNet<sup>[14]</sup>上做实验,通过高低 ARE 排序的方式分成两个子模型,一个子模型包含 1/2ARE 高的卷积核滤波器,称为 HighZF-Sub,则另外一个包含 1/2ARE 低的卷积核滤波器,LowZF-Sub。两个子模型网络结构相同,且每一层卷积层的卷积核滤波器数量均相同,然后将其在 LFWA 数据集上进行测试,结果如表 2 所示。从表 2 中可以看出包含有高 ARE 卷积滤波器的 HiZFsub 子模型平均准确率明显高于低 ARE 卷积滤波器组成的子模型 LoZFsub,实验结果证明了高 ARE 的卷积滤波器对于模型的贡献很明显。

表 2 子模型实验对比结果

Tab. 2 Comparison experiment results of the sub-model

模型	Conv1	Conv2	Conv3	Conv4	Conv5	mAP
ZFNet	96	256	384	384	256	0.82
HighZF-Sub	48	128	192	192	128	0.78
LowZF-Sub	48	128	192	192	128	0.54

## 2 实 验

### 2.1 实验数据

本文的实验数据是 CelebA 数据集和 LFWA 数据集,如图 4 所示。CelebA 数据集由约 1 000 个人构成的 202 599 张人脸图片组成,每张图片均有 40 个属性。LFWA 数据集是由约 5 749 个人组成的 13 233 张人脸图片,每张人脸均有 40 个属性。这两个数据集均具有挑战性,且在人脸姿势,光照和图像质量方面变化较大,其范围包含了人的身体特征,如鼻子大小、眉毛形状、头发颜色和表情等。将数据集分别分为训练集、验证集、测试集。本文按照文献[7,8]中的划分比例,训练集、验证集、测试集所占整个数据集的比例依次是 80%,10%,10%。CelebA 数据集中,训练集、验证集、测试集依次为 162 770 张、19 867 张、19 962 张,LFWA 数据集中,训练集、验证集、测试集分别为 10 513 张、1 314 张、1 316 张。



图 4 CelebA 数据集(第 1 行)和 LFWA 数据集(第 2 行)

Fig. 4 Images from CelebA (top row) and LFWA (bottom row)

### 2.2 人脸对齐

人脸对齐是根据输入的人脸图像,自动定位出面部关键特征点,如眼睛、眉毛等人脸各部件的轮廓点,如图 5 所示。其在处理人脸问题占有很重要的地位,尤其是处理无约束条件下的人脸识别问题。人脸对齐的方法有多种,本文采用的方法适用于在自然环境下或者无约束的条件下中的图像,对人脸姿态



变化的鲁棒性较强,所以较适合本文实验中的两个数据集。该方法首先生成进行图片标记的CDPM<sup>[15]</sup>库,然后调用CDPM库可自动地人脸图片进行标记,可以得到68个标记点的坐标精确信息。该方法不仅可以对人脸的面部轮廓进行精确的定位,而且鲁棒性较强,最后再用仿射变换的方法进行人脸对齐。




图5 调用CDPM库对人脸标记68个点

Fig. 5 Using the CDPM library to mark faces by 68 points

### 2.3 属性预测

本文采用公开的两个人脸数据集:CelebA数据集和LFWA数据集。这里采用每个网络训练一个人脸属性的方法可以确保属性之间的权值互不影响,达到收敛速度快、识别率达到最高、模型体积最小的结果。采用重构的网络进行训练,训练时初始学习率base\_lr设为0.0001。

实验平台:实验的硬件配置为双路8核心AMD Opteron 2222台式工作站,16GB内存,GTX980 GPU,软件环境为Ubuntu14.04和深度学习Caffe框架<sup>[16]</sup>。

将本文方法和目前较好的LNet+ANet、Best Representation方法在CelebA数据集和LFWA数据集实验结果对比,如图6所示,从总体角度的对比结果如表3所示,同时以数字的形式呈现在CelebA和LFWA数据集上的结果,如表4所示。由上述图表可得出:

- (1) 本文算法不仅可以缩减网络模型的体积,加快网络收敛速度,且在大规模数据集上具有有效性,可获得当前最好的效果。
- (2) 本文方法在Oval face, Bags under eyes, BlondHair, WearLipstick等人脸属性效果上尤为明显。

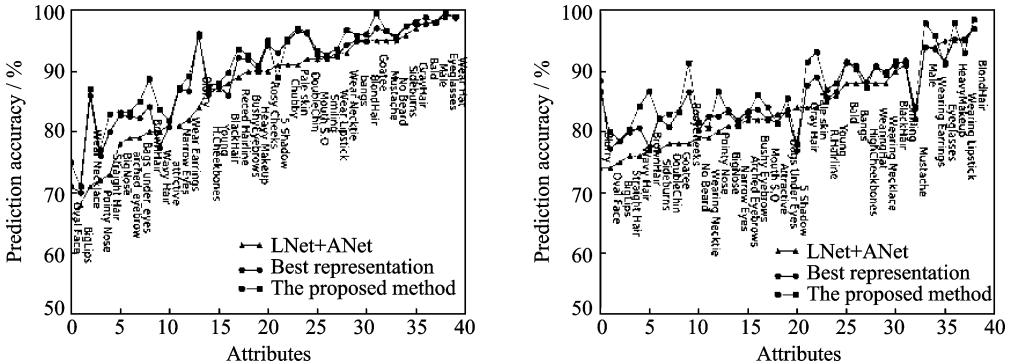


图6 CelebA数据集(左)和LFWA数据集(右)每个属性准确率对比图

Fig. 6 Comparative prediction accuracy on CelebA (left) and LFWA datasets (right) on each attribute

表3 LNet+ANet、当前最好的Best representation方法与本文方法的比较

Tab. 3 Overall comparisons of LNet+ANet, current state-of-the-art best representation) and the proposed method %

数据集	LNet+ANet	Best representation	The proposed
CelebA	87	89.8	90.1
LFWA	84	85.9	87.8

表 4 本文在 CelebA 和 LFWA 数据集上的属性识别准确率的百分比形式

Tab. 4 Our attribute recognition accuracy on the CelebA and LFWA

%

人脸属性	CelebA	LFWA	人脸属性	CelebA	LFWA
5o'ClockShadow	0.889 6	0.778 8	Male	0.979 5	0.979 5
Arched eyebrow	0.832 8	0.827 0	Mouth S. open	0.934 3	0.840 4
Attractive	0.817 7	0.817 3	Mustache	0.966 8	0.940 0
Bags under eyes	0.849 1	0.854 2	Narrow eyes	0.872 5	0.811 4
Bald	0.988 8	0.915 6	No Beard	0.956 9	0.815 9
Bangs	0.959 5	0.902 5	Oval face	0.749 4	0.799 9
Big lips	0.708 0	0.785 7	Pale skin	0.971 0	0.931 2
Big nose	0.832 1	0.832 1	Pointy nose	0.773 8	0.866 1
Black hair	0.897 1	0.917 0	Receding hairline	0.936 9	0.869 8
Blond hair	0.960 3	0.984 7	Rosy cheeks	0.949 9	0.913 5
Blurry	0.956 9	0.865 7	Sideburns	0.974 7	0.820 9
Brown hair	0.886 7	0.866 1	Smiling	0.927 5	0.911 7
Bushy eyebrows	0.926 2	0.860 9	Straight hair	0.827 0	0.804 1
Chubby	0.953 4	0.775 3	Wavy hair	0.836 3	0.841 9
Double chin	0.964 0	0.830 0	Wearing earrings	0.891 0	0.958 0
Eyeglasses	0.996 1	0.911 8	Wearing hat	0.989 8	0.907 0
Goatee	0.995 1	0.832 9	Wearing lipstick	0.936 5	0.930 3
Gray hair	0.981 3	0.915 3	Wearing necklace	0.864 4	0.893 0
Heavy makeup	0.908 7	0.979 0	Wearing necktie	0.968 1	0.805 3
High cheekbones	0.875 1	0.872 0	Young	0.880 3	0.879 8

### 3 结束语

本文在基于深度 CNN 的框架下,通过多级子网络和排序性 Dropout 机制解决了在自然环境下或非受限环境下人脸属性识别的难题。多级子网络算法有效地解决了人脸识别及人脸属性识别中均不可避免的问题:人脸姿势的多变性。排序性 Dropout 算法是通过 ARE 阈值方法筛选出对网络贡献度较大的卷积核,保留响应值高的神经元,舍弃响应值低的神经元,不仅大大地提高了人脸属性识别的精度,且很大程度上缩减了网络模型的体积,使其能更快运用到实际应用中。在后续的工作中,将搭建一个端到端的网络,将人脸检测、人脸识别和人脸属性识别集成为一体,使其有更广阔的应用前景。

### 参考文献:

- [1] Turk M, Pentland A. Eigenfaces for recognition[J]. Journal of Cognitive Neuroscience, 1991, 3(1): 71-86.
- [2] Choi H C, Kim S Y, Oh S H, et al. Pose invariant face recognition with 3D morphable model and neural network[J]. Journal of Social Psychology, 2008, 48(1): 4131-4136.
- [3] Sun Yi, Wang Xiaogang, Tang Xiaoou. Deep learning face representation from predicting 10 000 classes[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition. Oregon, USA; IEEE, 2014: 1891-1898.
- [4] Taigman Y, Yang Ming, Ranzato M A, et al. Deepface: Closing the gap to human-level performance in face verification [C]//2013 IEEE Conference on Computation Vision and Pattern Recognition. Oregon, USA; IEEE, 2013: 1701-1708.
- [5] Schroff F, Kalenichenko D, Philbin J. Facenet: A unified embedding for face recognition and clustering[C]//2015 IEEE Conference on Computation Vision and Pattern Recognition. Boston, Massachusetts, USA; IEEE, 2015: 815-823.
- [6] Huang G B, Ramesh M, Berg T, et al. Labeled faces in the wild: A database for studying face recognition in unconstrained environments[R]. Marseille, France; Workshop on Faces in "Real-Life" Images: Detection, Alignment, and Recognition,

2007:1-14.

- [7] Liu Ziwei, Luo Ping, Wang Xiaogang, et al. Deep learning face attributes in the wild [C]// Proceedings of International Conference on Computer Vision. Santiago, Chile: [s. n.], 2016.
- [8] Zhong Yang, Sullivan J, Li Haibo. Leveraging mid-level deep representations for predicting face attributes in the wild [C]// IEEE International Conference on Image Processing. Las Vegas, Nevada, USA: IEEE, 2016.
- [9] 卢宏涛, 张秦川. 深度 CNN 在计算机视觉中的应用研究综述 [J]. 数据采集与处理, 2016, 31(1): 1-17.  
Lu Hongtao, Zhang Qinchuan. A survey of the application of deep convolution neural network in computer vision [J]. Journal of Data Acquisition and Processing, 2016, 31(1): 1-17.
- [10] He Kaiming, Yu Xiang, Zhang Shaoqing, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [C]// 2015 IEEE ECCV. Zurich, Switzerland: IEEE, 2014: 346-361.
- [11] Lin Min, Chen Qiang, Yan Shuicheng. Network in network [C]// 2014 IEEE Conference on Computation Vision and Pattern Recognition. Columbus, Ohio, USA: IEEE, 2014.
- [12] Hinton G E, Srivastava N, Krizhevsky A, et al. Improving neural networks by preventing co-adaptation of feature detectors [J]. Computer Science, 2012, 3(4): 212-223.
- [13] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [C]// International Conference on Neural Computation (ICNC). Hawaii, USA: [s. n.], 2012, 25(2): 1097-1105.
- [14] Zeiler M, Fergus R. Visualizing and understanding convolutional networks [C]// Proc of the IEEE European Conference on Computer Vision. [S. l.]: IEEE, 2014.
- [15] Michal U, Vojtěch angwo F, Diego T, et al. Multi-view facial landmark detector learned by the structured output SVM [J]. Image and Vision Computing, 2016, 47: 45-49.
- [16] Yang Qing, Shelhamer J E, Donahue J, et al. Caffe: Convolutional architecture for fast feature embedding [C] // ACM International Conference on Multimedia. Florida, USA: [s. n.], 2014: 675-678.

#### 作者简介:



高淑蕾 (1992-), 女, 硕士研究生, 研究方向: 深度学习、图像分类, E-mail: 18790864870@163.com.



周 冕 (1979-), 男, 副教授, 研究方向: 机器视觉、模式识别, E-mail: zhoumian@hotmail.com.



薛彦兵 (1979-), 男, 副研究员, 研究方向: 计算机视觉、机器人系统、虚拟现实, E-mail: yanbingxue@163.com.



徐光平 (1977-), 男, 副教授, 研究方向: 计算机视觉处理算法、分布式存储系统、网络优化及其算法, E-mail: xugp@tjut.edu.cn.



高 赞 (1980-), 男, 副教授, 研究方向: 模式识别、机器学习、图像处理, E-mail: gaozan114@126.com.



张 桦 (1962-), 女, 教授, 研究方向: 计算机视觉、三维重建、可视化、基于网络的信息处理, E-mail: hzhang@tjut.edu.cn.

(编辑: 张 彤)