中国科学院软件研究所学术年会’2019
暨计算机科学国家重点实验室开放周

学术论文

尺度不变的全卷积神经网络：高效的人手检测
Scale Invariant Fully Convolutional Network: Detecting Hands Efficiently

刘丹[1], 独大为[2], 张立波[3,*], 罗铁坚[1], 武延军[3], 黄飞跃[4], Siwei Lyu[2]

[1]中国科学院大学, 中国　[2]纽约州立大学奥尔巴尼分校, 美国

[3]智能软件研究中心，中国科学院软件研究所, 中国　[4]腾讯Youtu实验室, 中国

会议：AAAI 2019
通讯作者：张立波
联系方式：
18655882017
libo@iscas.ac.cn

问题: 高效的人手检测
应用: 虚拟现实、人机交互、驾驶监控等

动机

	代表性方法	不足
传统方法: 人工提取特征 + 分类器	皮肤特征 (Dardas and Georganas 2011)	• 特征提取的时间和精力开销大 • 非端到端优化过程 • 特征的局限性
	手的形状和背景信息 (Mittal, Zisserman, and Torr 2011)	
	方向梯度直方图（HOG） (Betancourt et al. 2015)	
基于深度学习的方法: CNNs	候选区域 + CNN (Bambach et al. 2015)	• 小的手部区域漏检率大 • 网络结构复杂，训练和测试时间长，不能达到实时检测
	FCN + 分类 (Le et al. 2017)	
	旋转 & 解旋转 (Deng et al. 2018)	

贡献

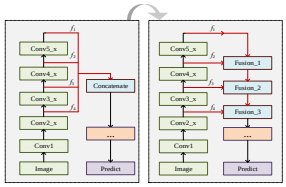

Simultaneously (Yan et al. 2017)　Iteratively (Ours)

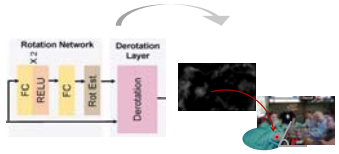

Derotation and Rotation Layers (Deng et al. 2018)　Rotation Map (Ours)

- 提出尺度不变的全卷积神经网络，补充加权特征融合模块（CWF block）可以学习每个尺度特异与其他尺度的特征，并以一种迭代的方式融合多个尺度的特征进行最后的预测
- 提出多尺度损失函数，对网络的中间层也加入了监督，加快了模型收敛的速度
- 与当前最好的方法相比，在保证精度的同时检测速度更加快

尺度不变的全卷积神经网络

1. 特征提取

- 取VGG16网络pooling-2到pooling-5的特征图；ResNet50网络conv2_1，conv3_1，conv4_1，conv5_1的特征图
- 特征大小分别是输入图像的$\left(\frac{1}{4}\right)^2$，$\left(\frac{1}{8}\right)^2$，$\left(\frac{1}{16}\right)^2$，$\left(\frac{1}{32}\right)^2$

2. 特征融合

- 在unpooling层，上一层（较高层次）特征图上采样到当前特征图相同大小，记为u_{s-1}
- （CWF）对当前特征图f_s进行加权：

$$\begin{cases} W(f_s) = f_s * C(u_{s-1}), \\ C(u_{s-1}) = 1 - Conv_{1\times1}(u_{s-1}). \end{cases}$$

- 将上面得到的两层的特征图在通道维度上进行连接
  - 经过1 × 1卷积减少输出通道数
  - 经过3 × 3卷积融合不同层次的特征
- 融合后的特征图作为下一个融合模块（UF或CWF）的基本特征图进行下一步的迭代融合

3. 输出

- 输出包括三部分：得分图，角度图和距离图，分别记录预测手型区域的置信度、旋转角度和几何信息。

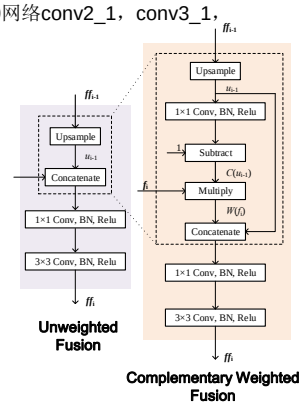

- s : the current scale
- f_s : the current scale feature maps
- $W(f_s)$: the weighted feature maps
- $C(u_{s-1})$: the complementary feature maps
- $*$: element-wise multiplication

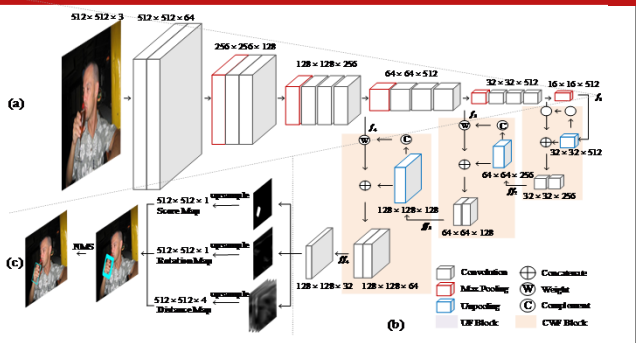

以VGG16为骨干网络的SIFCN网络结构。主要包含三部分: (a) 特征提取部分, (b) 特征融合部分, 和 (c) 输出部分.

4. 多尺度损失函数

$$L = \sum_{s\in S} w_s(\alpha L_s + \beta L_r + L_d), \quad S = \{1,2,3,4\}$$

$$\begin{cases} L_s = \dfrac{2\sum_i^N p_i g_i}{\sum_i^N p_i^2 + \sum_i^N g_i^2} \\ L_r = 1 - \cos(\tilde{\theta} - \theta) \\ L_d = -\log\dfrac{\tilde{X} \cap X}{\tilde{X} \cup X} \end{cases}$$

多尺度损失函数增加了对网络中间层的监督，加快了模型收敛的速度

实验

VIVA人手数据集(Das, OhnBar, and Trivedi 2015)

- Train: 5,500 images Test: 5,500 images
- 真实的驾驶场景
- 标注为轴对齐的边界框

Table 1: Results on VIVA Dataset.

Methods	Level-1(AP/AR)/%	Level-2(AP/AR)/%	Speed/fps	Environment
MS-RFCN (Le et al. 2017)	**95.1/94.5**	86.0/**83.4**	4.65	6 cores@3.5GHz, 32GB RAM, Titan X GPU
MS-RFCN (Le et al. 2016)	94.2/91.1	**86.9**/77.3	4.65	
Multi-scale fast RCNN (Yan et al. 2017)	92.8/82.8	84.7/66.5	3.33	6 cores@3.5GHz, 64GB RAM, Titan X GPU
FRCNN (Zhou, Pillai, and Yalla 2016)	90.7/55.9	86.5/53.3	-	-
YOLO (Redmon et al. 2016)	76.4/46.0	69.5/39.1	35.00	6 cores@3.5GHz, 16GB RAM, Titan X GPU
ACF.Depth4 (Das, Ohn-Bar, and Trivedi 2015)	70.1/53.8	60.1/40.4	-	-
Ours (VGG16+UF)	88.9/82.8	72.6/56.7	13.88	
Ours (VGG16+UF+Multi-Scale Loss)	92.9/88.3	80.9/62.7	13.16	
Ours (VGG16+CWF+Multi-Scale Loss)	92.3/89.1	83.6/68.8	13.10	4 cores@4.0GHz, 32GB RAM, GeForce GTX 1080
Ours (ResNet50+UF)	93.7/89.9	83.6/73.6	20.40	
Ours (ResNet50+UF+Multi-Scale Loss)	94.0/90.1	85.7/74.0	20.00	
Ours (ResNet50+CWF+Multi-Scale Loss)	**94.6/92.1**	**86.3/75.8**	19.68	

Oxford人手数据集(Mittal, Zisserman, and Torr 2011)

- Train: 2,250 images Test: 436 images
- 多种场景
- 标注为带有旋转角度的边界框

Table 2: Results on Oxford Dataset.

Methods	AP/%
MS-RFCN (Le et al. 2017)	**75.1**
Multiple proposals (Mittal, Zisserman, and Torr 2011)	48.2
Multi-scale CNN (Yan et al. 2017)	58.4
Ours (VGG16+UF)	68.7
Ours (VGG16+UF+Multi-Scale Loss)	77.8
Ours (VGG16+CWF+Multi-Scale Loss)	78.0
Ours (ResNet50+UF)	78.2
Ours (ResNet50+UF+Multi-Scale Loss)	78.6
Ours (ResNet50+CWF+Multi-Scale Loss)	**80.4**

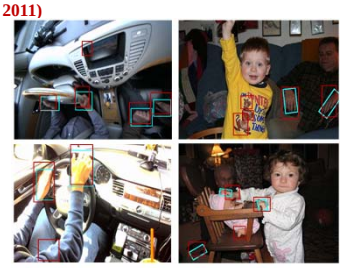

(a)　(b)

结果对比：SIFCN (青色，我们的) 和 Multi-scale fast RCNN (红色，Yan et al. 2017) 。(a) VIVA 数据集 (b) Oxford 数据集

消融研究

得分图和角度图的作用

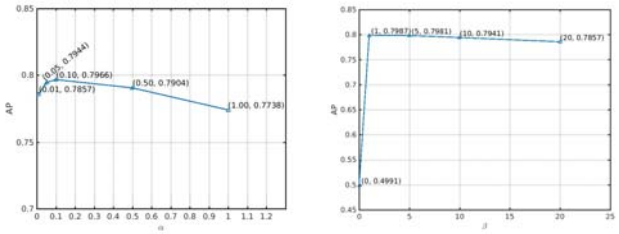

(a)　(b)

在Oxford人手数据集上平均准确率（average precision）随α和β的变化趋势. (a) 平均准确率 vs. α（β= 20）. (b) 平均准确率 vs. β（α= 0.01）.

多尺度损失函数的效果

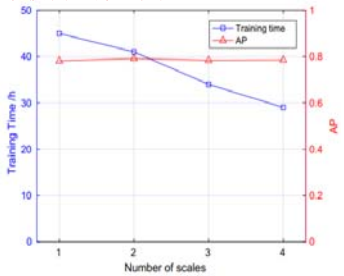

Training time and AP score vs. different numbers of scales for the Oxford dataset.

补充加权特征融合（CWF）模块的作用

- 无论使用VGG16还是ResNet50作为骨干网络，使用补充加权特征融合模块（CWF）的性能都优于非加权模块（UF）
- 使用补充加权特征融合模块（CWF） 相较于非加权模块（UF） 产生的假负例更少，更好的利用了不同尺度的特征.

Code here