

基于上下文以及多尺度信息融合的目标检测算法

吕培建¹ 陈佳鹏² 袁飞¹ 彭强² 项煜³

(河南省高速公路联网监控收费通信服务有限公司 郑州 450000)¹

(西南交通大学信息科学与技术学院 成都 611756)² (长安大学公路学院 西安 710064)³

摘要 卷积神经网络的快速发展极大地提升了目标检测的性能。针对 SqueezeDet 算法没有利用多尺度以及上下文信息的问题,文章结合跳过连接(skip connection)和快捷连接(shortcut connection)来汇聚多尺度特征图,利用膨胀卷积(dilated convolution)来扩大卷积感受野以及上下文信息,提出了一种基于上下文的多尺度目标检测模型,提升了整个网络对复杂场景下的目标检测的精度和鲁棒性。该模型融合 3 种不同分辨率的特征图:将最小以及中间尺寸的特征图通过不同采样率的膨胀卷积聚集上下文信息,然后通过双线性插值的方式将最小特征图的分辨率放大一倍,最大特征图经卷积层降采样之后获得与中间特征图相同的尺寸,与之进行融合,并且使用了快捷连接来连接不同尺寸的特征图,从较大特征图中获取丢失的信息。将该模型在自动驾驶国际公开基准测试数据集 KITTI 中进行了实验,与 SqueezeDet 相比,所提算法的准确率提升约 5%,同时在 GPU 中的推断速度可达 30fps。

关键词 卷积神经网络,跳过连接,快捷连接,膨胀卷积

中图分类号 TP391 **文献标识码** A

Object Detection Algorithm Based on Context and Multi-scale Information Fusion

LV Pei-jian¹ CHEN Jia-peng² YUAN Fei¹ PENG Qiang² XIANG Yu³

(Henan Expressway Network Monitoring Charge Communication Service Company, Transportation Department of Henan Province, Zhengzhou 450000, China)¹

(School of Information Science and Technology, Southwest Jiaotong University, Chengdu 611756, China)²

(School of Highway, Chang'an University, Xi'an 710064, China)³

Abstract Recent advances in convolutional neural networks(CNNs) have led to significant improvement in object detection. To solve the problem of missing context and multi-scale information of SqueezeDet algorithm, this paper combines skip connection and shortcut connection to aggregate multi-scale feature maps, and use dilated convolution to expand the convolutional receptive field and context. A context-based multi-scale object detection model was proposed to effectively improve the accuracy and robustness of object detection for complex scenes. This model fuses three different resolution feature maps: the minimum and middle size feature maps gather context through dilated convolution, the minimum size feature maps are doubled through bilinear interpolation and the maximum size feature maps use convolution whose stride is 2 to down-sample. Then the three feature maps have the same size and can be fused. In addition, this paper uses shortcut connection to connect different size of feature maps to obtain lost information from the larger feature maps. The model is evaluated on the autopilot international benchmark dataset KITTI and achieves 6% improvement compare to the SqueezeDet. The speed of the model reach 30fps on a GPU.

Keywords Convolutional neural network, Skip connection, Shortcut connection, Dilated convolution

1 引言

随着计算机计算能力的提升,特别是基于通用计算单元(GP-GPU)的科学计算技术的成熟,图像处理以及计算机视觉获得快速发展,并取得了长足的进步。由于计算能力获得了数量级的提升,基于深度神经网络技术的计算机视觉技术也取得了新的发展,在图像分类、分割等任务上也取得了长足的进步。目标检测作为计算机视觉的重要任务,也同样引入

了深度学习技术进行优化提高。

SqueezeDet^[6]作为基于深度学习的快速目标检测框架,基于卷积神经网络从数据中不断学习,自动提取需要的特征,并且具有天然的多尺度以及平移不变性,在目标检测领域取得了较大的发展。但是在现实场景中,图像受光照、颜色等因素的影响十分严重,特征发生变化而导致模型判断失效的情况普遍存在。如何提取不变的特征显得尤为关键。由于卷积神经网络中存在池化操作使得分辨率变小,导致信息丢失;同

吕培建(1971—),男,高级工程师,主要研究方向为交通机电工程,E-mail:409676667@qq.com(通信作者);陈佳鹏(1993—),男,硕士生,主要研究方向为计算机视觉;袁飞(1974—),男,高级工程师,主要研究方向为公路机电工程;彭强(1962—),博士,教授,CCF高级会员,主要研究方向为视频编码与传输、图像处理、虚拟现实和智能交通;项煜(1987—),男,博士,工程师,主要研究方向为交通工程、交通信息化。

时,现实场景中目标距离的变化会导致尺度变化较大,往往造成检测精度的下降。为了有效地克服以上问题,本文基于 SqueezeDet^[6]提出了一种新型的目标检测算法。该算法采用 skip connection 以及 shortcut connection 将不同分辨率的特征图连接起来,进而获得丢失的信息并形成语义丰富的新特征图。如图 1 所示,(a)为 skip connection 连接方式,即两个相同大小的特征图按通道维度拼接起来形成新的特征图。(b)为 shortcut connection,即将两个大小、通道维度相同的特征图按照“Eltw sum”方式相加得到新的特征图(即对应元素相加)。因此,基于以上考量,本文以 SqueezeDet 为基础,结合跳过连接(skip connection)^[7]和快捷连接(shortcut connection)^[8],利用膨胀卷积(dilated convolution)^[9]扩大卷积感受野以及上下文信息,有效地提升了整个网络在复杂场景下的目标检测精度和鲁棒性。




图 1 跳过连接以及快捷连接

为了提取多尺度信息,本文使用一系列连续的膨胀卷积(dilated convolution)来使上下文信息汇聚,也可以利用一系列不同采样率的 dilated convolution,以并联的方式在最后提取出来的特征图上提取多尺度信息。本文中不同采样率的 dilated convolution 通过串并联的方式组合起来,可以实现特征复用,提升参数的利用率。同时,将 dilated convolution 与 skip connection 相结合,最后将两个分辨率的特征图利用不同采样率的 dilated convolution 连接起来,使最后提取出来的特征图具有更强的特征表达能力。本文的主要贡献如下:

1) 提出了结合跳过连接、快捷连接的新式网络结构,能够有效捕捉多尺度信息;

2) 利用多种采样率的膨胀卷积构造不同尺度的感受野,获得多尺度的上下文信息。

在国际评测基准数据集 KITTI^[10]上对本文模型进行了实验,结果显示,其检测准确率相对于 SqueezeDet 大约提升了 5%,并且可以达到实时检测的速度。

2 相关工作

目前以卷积神经网络为基础的目标检测算法可以分为两种。

(1) 以 Faster-RCNN^[2]为代表的两步检测算法(two-stages)。该类算法主要利用候选框定位,然后利用分类网络对候选框进行分类以及进一步坐标回归,能获得更高精度的检测结果。算法流程主要分为两步:1)首先利用一个区域候选框提取网络(Region Proposal Network, RPN)从一张图片中提取感兴趣区域(RoIs);2)利用多任务的分类及回归网络对第 1 步中提取出来的感兴趣区域进行细分类以及位置回归^[3]。

(2) 以 YOLO^[4],SSD^[5]为代表的单步(one-stage)检测算

法。这类算法为了在一定的精度下提升速度,预先在图片中设定一系列的 anchors 并对其进行分类,直接预测图片中物体的类别以及位置。单步检测法的基本思想就是在提取感兴趣区域的同时进行多类别分类,其本质与 RPN 网络类似。为了提高其检测精度和泛化能力,SSD 在多个尺度的特征图上做了检测,融合过滤多尺度检测目标,精化最终检测结果。

与 two-stages 检测算法相比,One-stage 检测算法是一种端到端(end to end)的网络,梯度可以很好地传递,因此网络相对容易训练;并且 One-stage 检测算法没有候选提取过程,速度很快,适用于现实中很多对实时性要求很高的场景(例如无人驾驶、视频目标检测)。SqueezeDet^[6]是一种类似于 YOLO 的检测算法,首先利用一个在 ImageNet 上预训练的模型,从一张图片中提取高维特征图。与 YOLO 相比,SqueezeDet 使用卷积层代替参数繁多的全连接层,大幅度减少了整个网络的参数,进一步提升了网络的泛化能力以及速度。但是,由于 SqueezeDet 只利用了单尺度的特征图,使得其在无人驾驶、视频检测等尺度快速变化的场景下表现欠佳。

在目标检测中,上下文信息对物体的检测非常重要,比如人戴着猫耳朵,若仅仅看到猫耳朵,则检测算法非常有可能发生误检,如果可以联系上下文信息,则可避免误检。Dilated convolution 可以有效地汇集多尺度以及上下文信息。图 2 为 3×3 的 dilated convolution,红色为卷积核中心,蓝色为周围的点。Dilated convolution 与传统卷积相比,拥有额外的超参数 rate。图 2 中(a)、(b)、(c)分别为 rate 为 1,2,3 的 dilated convolution。图(a)与传统的卷积完全相同,传统卷积可以看作 dilated convolution 的一个特例。从图 2 中可以看出,通过设置不同的 rate,可以获取物体周围的信息。本文受到现有方法的启发,结合上下文以及多尺度信息,将 dilated convolution, skip connection 以及 shortcut connection 结合在一起以增强特征的表达能力,具体内容见第 3 节。




图 2 膨胀卷积(电子版为彩色)

3 算法框架

本文以 SqueezeDet 为基础,首先介绍 SqueezeDet 流程,之后介绍本文的改进。

3.1 SqueezeDet 算法流程

SqueezeDet 选取在 ImageNet 上预训练的 SqueezeNet^[11]作为基础网络结构,检测流程类似于 yolo9000^[12],以最后一个特征图上的每一个点为中心,设置 k 个大小以及长宽比不同的 anchor。为了避免手工设计 anchor, SqueezeDet 在 KITTI 数据集上,根据 ground-truth box 的长与宽,利用 K-means 算法进行聚类,获得 k 个不同的 anchor 的比例。

由于 SqueezeDet 面向无人驾驶应用,为保证速度, SqueezeDet 直接选取一个卷积核为 3×3 的卷积层作为检测

器对每个 anchor 位置进行微调,并输出 anchor 中包含物体的位置置信度以及所属类别的条件概率。

3.2 多尺度以及上下文信息的提取

SqueezeDet 在最后一个特征图上进行检测,该特征图的宽与高为原始图像的 1/16,即原图中 16×16 的物体映射到该特征图上仅有 1×1 的大小,信息丢失十分严重,因此小目标的检测十分困难。对于卷积神经而言,由于有下采样的存在,中间产生了很多不同分辨率的特征图,具有天然的多尺度信息,通常前面较大的特征图具有物体的局部细节,而后面更小的特征图具有更加丰富的语义。因此本文考虑利用 skip connection 将不同分辨率的特征图联合起来,并在较大的特征图上进行检测,这样做有两点好处:

(1)新得到的层既含有丰富的语义,又含有物体的局部细节,并且可以很好地利用卷积神经网络中的多尺度信息;

(2)特征图变大后所选取的 anchor 的数量变多,采样更加密集,可以更好地得到物体的位置。

通常来讲,物体周围的上下文信息对物体的检测具有十分重要的作用,而 dilated convolution 通过设置不同的 rate 可以获取物体不同范围的信息,因此首先考虑将不同 rate 的 dilated convolution 并联起来提取物体周围的信息,如图 3 以及图 4 所示。其中,类似残差网络将输入与输出结果进行融合,使 dilated convolution 可以更好地提取上下文信息。




图 3 DR 模块




图 4 IN-DR 模块

Dilated convolution 在进行串联时可以非常快地增大感受野,而适当大的感受野对物体的检测有一定的帮助,因此本文考虑将 dilated convolution 串联。为了使参数利用率更高,本文在串联过程中每经过一层通道数减半并将中间产生的特征图也当作该模块的输出,进而实现特征复用,如图 5 所示。在输入以及输出均为 512 通道特征图时,串并联模块大概可以节省 1/3 的参数。




图 5 HYDR 模块

本文将 dilated convolution 与 skip connection 结合起来,算法网络结构如图 6 所示。卷积神经网络在进行池化时往往

伴随着信息的丢失。本文还利用 shortcut connection 以“Eltw sum”方式将较小的特征图与较大的特征图连接起来,企图缓解池化过程中信息的丢失。为了保持预训练模型不变,本文将 shortcut connection 模块中 1×1 卷积初始化为 0。

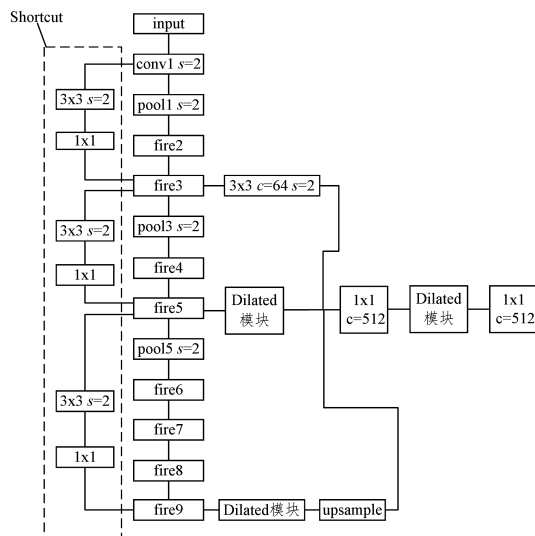


图 6 算法结构

4 实验

KITTI 数据集是专注于无人驾驶的数据集,其中包含 2D 检测任务,具有 7 481 张训练图片,每张图片中含有大量的目标,如图 7 所示。KITTI 根据每类物体大小、遮挡(occlusion)以及边界截断(truncation)的程度将物体分为 Easy, Moderate 以及 Hard 3 种级别,划分条件如表 1 所列。



图 7 KITTI 数据集图片

表 1 KITTI 目标级别划分标准

级别	高度	遮挡	边界截断/%
Easy	40	完全可见	15
Moderate	25	部分闭塞	30
Hard	25	几乎看到	50

本文所有实验均在 KITTI 数据集上进行。KITTI 数据集采用的评价指标为 Average-Precision(AP),即平均精度相当于 Precision-Recall 曲线面积。论文的代码实现框架为 Tensorflow。与原论文相同,在实验过程中将输入图像大小归一化到 1242×375 ,数据集随机划分,其中一半为训练集,一半为测试集。训练时 batch size 为 20,采用随机梯度下降来优化损失函数,初始学习率为 0.01,每隔 10 000 步,学习率下降 0.5,图像增强以及 anchor 的选择与原论文一致,实验机器为 NVIDIA TITAN X GPU,实验效果如图 8 所示,实验数据如表 2 所列(图 6 中 dilated 模块由图 5 代替)。



图 8 实验效果图

表2 实验对比

方法	Car			Speed/fps
	E	M	H	
SqueezeDet	91.1	85.2	74.5	58.8
SubCNN ^[13] *	90.8	89.0	79.3	0.2
MS-CNN ^[14] *	90.0	89.0	76.1	2.5
PNET*	81.8	83.6	74.2	10
Pi ^e *	89.4	89.2	74.2	0.83
FRCN+VGG16 ^[15] *	92.9	87.9	77.3	1.7
FRCN+Alex ^[15] *	94.7	84.8	68.3	2.9
本文采用结构	96.3	89.0	80.3	30

KITTI上拥有大量的车,车辆分为3个难度:简单、中等以及困难;而自行车与行人数量较少,检测车辆的结果更具有代表性,因此本文仅列出车辆的AP。对比检测结果如表2所示,其中*部分为SqueezeDet中提供的结果。为了全面地评价本文方法的性能,将其与SqueezeDet以及通用的目标检测方法Faster RCNN(VGG16)、Faster RCNN(Alex)、SubCNN以及MS-CNN做了全面的对比。

从表2中可以看出,本文所提方法对SqueezeDet在简单、中等以及困难3个级别的测试数据上均有较大提升,其中在困难级别大约提升6%,这主要是因为本文用于检测的特征图分辨率放大一倍,图中anchors采样更加精细,并且该特征图聚集了较小特征图中丰富的语义以及较大特征图中物体的局部细节,具有更好的表示能力。另外,dilated convolution也可以很好地提取的物体周围的上下文信息,进一步丰富了本文所提取特征。Faster RCNN(Alex),SubCNN的准确率分别接近本文方法,但是速度相差甚远,由此证明了本文所提方法十分有效。接下来将对每种技术所起到的作用进行分析。

4.1 Skip connection的作用

为了探索skip connection的作用,本文进行了分析实验,结果如表3所列。其中,“SK”指仅在网络中使用skip connection将不同特征图进行融合,“SK-DR”指在skip connection中以并联方式使用不同rate的dilated convolution。本文仅使用skip connection,相对于SqueezeDet mAP提升1.6%。对于Moderate以及Hard级别的汽车而言,skip connection有较大提升,尤其是在Hard级别上将SqueezeDet检测AP值提升了3.7%。Easy级别反而有所下降,其原因为:

- (1)对于Easy级,别1/16特征图信息已经足够;
- (2)两者感受野大小相同;
- (3)SqueezeDet在fire9后有fire10以及fire11两个模块。

在skip connection中使用dilated convolution后,感受野增大,Easy级别的检测准确率也有所提升。

表3 跳过连接实验

方法	Car			mAP
	E	M	H	
SqueezeDet	91.1	85.2	74.5	83.6
SK	90.9	86.6	78.2	85.2
SK-DR	92.8	87.7	79.1	86.5

4.2 Dilated convolution的作用

本文通过大量的实验来证明dilated connection的作用,结果如表4所列。“SK-3×3”指在skip connection中使用3×3卷积,“SK-DR”指在skip connection中使用不同rate的

dilated convolution并联,“SK-3×3+IN-DR”指在“SK-3×3”模块后增加“IN-DR”模块(dilated convolution并联输出时将输入也作为输出),“SK-3×3+IN-3×3”指在“SK-3×3”模块后新增模块中使用普通3×3卷积,“SK-DR+IN-DR”指在skip connection以及后面新增模块中均使用不同rate的dilated convolution并联。

表4 膨胀卷积实验

方法	Car			mAP
	E	M	H	
SK-3×3	90.9	86.6	78.2	85.2
SK-DR	92.8	87.7	79.1	86.5
SK-3×3+IN-3×3	94.3	87.9	79.4	87.2
SK-3×3+IN-DR	95.0	88.5	79.8	87.8
SK-DR+IN-DR	96.0	89.1	80.4	88.5

为了说明dilated convolution的作用,对比实验中将两者参数设置为相同。从表4中可以看出使用dilated convolution后准确率均有提升,充分地证明了将不同rate的dilated convolution并联起来可以获取上下文信息,进而获得更好的特征。

“SK-DR”相对于“SK-3×3”,车辆检测mAP值提升1.3%,而“SK+IN-DR”相对于“SK+IN-3×3”仅提升0.6%,可以看出在skip connection上使用dilated convolution效果更加好。另外“SK-DR+IN-DR”对于“SK+IN-DR”,mAP值从87.8%提升到88.5%,提升了0.7%,更加证明了刚才的猜想。这可能是因为在skip connection过程中,对fire9以及fire5均使用了dilated convolution,相当于在不同尺度提取上下文信息,使得所提取特征更为细腻。

串并联方式使用不同rate的dilated convolution(指表5中的HYDR模块),与单纯的并联方式相比,可以节约1/3的参数,两者效果如表5所列。两者效果相差不大,并且在最后一组实验中,串并联方式的mAP值更高。“SK-HYDR+HYDR+SC”是本文的最终模型(SC指shortcut convolution),采用了skip connection,dilated convolution以及shortcut convolution 3种技术。另外,串并联方式与普通卷积相比,节约了1/3的参数,并且准确率更高。

表5 串并联以及单纯的并联方式的比较

方法	Car		
	E	M	H
SK-DR	92.8	87.7	79.1
SK-HYDR	92.7	87.1	78.6
SK-DR+IN-DR	96.0	89.1	80.4
SK-HYDR+HYDR	95.8	88.3	79.8
SK-DR+IN-DR+SC	95.4	88.9	80.2
SK-HYDR+HYDR+SC	96.3	89.0	80.3

4.3 Shortcut connection的作用

为了验证shortcut connection的作用,本文进行了对比实验,结果如表6所列。除了“SK-DR+IN-DR”结构,其他所有结构使用shortcut connection后AP值均有提升,从而很好地证明了shortcut connection通过连接不同分辨率的特征图,可以使较小的特征图从较大的特征图中获取丢失的信息以及物体的局部细节,进而有效地避免了池化过程中信息的丢失。而“SK-DR+IN-DR”结构中AP值下降是因为该结构

中参数众多,进而造成了过拟合现象,在实际应用中可以通过迁移学习或者增大数据集来缓解这种情况的发生,因此 shortcut connection 仍有一定的意义。

表 6 快捷连接实验

方法	是否使用	Car		
		<i>E</i>	<i>M</i>	<i>H</i>
SK-3×3	否	90.9	86.6	78.2
	是	91.9	86.9	78.4
SK-3×3+IN-DR	否	95.0	88.5	79.8
	是	96.0	89.0	80.2
SK-DR+IN-DR	否	96.0	89.1	80.4
	是	95.4	88.9	80.2
SK-HYDR	否	92.7	87.1	78.6
	是	93.1	87.5	79.1
SK-HYDR+HYDR	否	95.8	88.3	79.8
	是	96.3	89.0	80.3

结束语 本文利用 shortcut connection, skip connection 以及 dilated convolution 提取多尺度以及上下文信息,整体准确率相比 SqueezeDet 提升了 5% 左右,特别是在困难级别取得了将近 6% 的提升,充分证明了本文所提方法的有效性。与此同时,本文所提方法可以达到 30 fps 的实时检测效果,具有很强的实用价值。

参考文献

- [1] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[C]// Advances in Neural Information Processing Systems. IEEE, 2012: 1097-1105.
- [2] REN S, HE K, GIRSHICK R, et al. Faster r-cnn: Towards real-time object detection with region proposal networks[C]// Advances in Neural Information Processing Systems. 2015: 91-99.
- [3] GIRSHICK R. Fast R-CNN[C]// 2015 IEEE International Conference on Computer Vision (ICCV). IEEE, 2015: 1440-1448.
- [4] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2016: 779-788.
- [5] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector[C]// European Conference on Computer Vision. Cham: Springer, 2016: 21-37.
- [6] WU B, IANDOLA F, JIN P H, et al. SqueezeDet: Unified, Small, Low Power Fully Convolutional Neural Networks for Real-Time Object Detection for Autonomous Driving[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. IEEE, 2017: 129-137.
- [7] KONG T, YAO A, CHEN Y, et al. Hypernet: Towards accurate region proposal generation and joint object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016: 845-853.
- [8] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2016: 770-778.
- [9] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions[J]. arXiv:1511.07122, 2015.
- [10] GEIGER A, LENZ P, URTASUN R. Are we ready for autonomous driving? the kitti vision benchmark suite[C]// 2012 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2012: 3354-3361.
- [11] IANDOLA F N, HAN S, MOSKEWICZ M W, et al. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5 MB model size[J]. arXiv:1602.07360, 2016.
- [12] REDMON J, FARHADI A. YOLO9000: Better, Faster, Stronger[C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2017: 6517-6525.
- [13] XIANG Y, CHOI W, LIN Y, et al. Subcategory-aware convolutional neural networks for object proposals and detection[C]// 2017 IEEE Winter Conference on Applications of Computer Vision (WACV). IEEE, 2017: 924-933.
- [14] CAI Z, FAN Q, FERIS R S, et al. A unified multi-scale deep convolutional neural network for fast object detection[C]// European Conference on Computer Vision. Cham: Springer, 2016: 354-370.
- [15] ASHRAF K, WU B, IANDOLA F N, et al. Moskewicz, Kurt Keutzer: Shallow Networks for High-accuracy Road Object-detection[C]// VEHTS. 2017: 33-40.
- [16] (上接第 278 页)
- [17] KUMAR R, BANERJEE A, VEMURI B C, et al. Maximizing all margins: Pushing face recognition with Kernel Plurality[C]// International Conference on Computer Vision. IEEE, 2011: 2375-2382.
- [18] DENG W, HU J, GUO J. Extended SRC: Undersampled Face Recognition via Intra-class Variant Dictionary[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2012, 34(9): 1864-1870.
- [19] ZHU P, ZHANG L, HU Q, et al. Multi-scale Patch Based Collaborative Representation for Face Recognition with Margin Distribution Optimization[C]// European Conference on Computer Vision. IEEE, 2012: 822-835.
- [20] ZHU P, YANG M, ZHANG L, et al. Local Generic Representation for Face Recognition with Single Sample per Person[M]. Springer International Publishing, 2014: 41-50.
- [21] WRIGHT J, YANG A Y, GANESH A, et al. Robust face recognition via sparse representation[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2008, 31(2): 210-227.
- [22] LOUGHERY J. Making FLDA applicable to face recognition with one sample per person[J]. Pattern Recognition, 2004, 37(7): 1553-1555.
- [23] ZHANG L, YANG M, FENG X. Sparse representation or collaborative representation: Which helps face recognition? [C]// IEEE International Conference on Computer Vision (ICCV 2011). Barcelona, Spain; IEEE, 2011: 471-478.
- [24] SU Y, SHAN S, CHEN X, et al. Adaptive generic learning for face recognition from a single sample per person[C]// Computer Vision and Pattern Recognition. IEEE, 2010: 2699-2706.
- [25] LU J, TAN Y P, WANG G. Discriminative Multimanifold Analysis for Face Recognition from a Single Training Sample per Person[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2012, 35(1): 39-51.