

基于信息修正的深度残差学习

谢烟平^{1,2,3}, 谭晓阳^{1,2,3}

(1. 南京航空航天大学计算机科学与技术学院, 南京, 211106; 2. 模式分析与机器智能工业和信息化部重点实验室, 南京, 211106; 3. 软件新技术与产业化协同创新中心, 南京, 211106)

摘要: 提出了一种新的深度残差网络的拓展模块, 有效提高了学习表示的鲁棒性。所提出的方法是一个简单的即插即用模块, 即组卷积式编码-解码结构, 它可以作为一个额外的信息过滤部件集成到原来的深度残差网络中。利用编码器的下采样来产生信息压缩过的特征图, 解码器模块被驱动以产生激活准确的特征图, 其能够突出显示输入图片中最具有判别力的区域, 最后通过元素级相加和激活操作对输入特征进行信息修正。为了使设计的模型计算更加高效, 通过减少残差分支的通道数来探究其轻量级版本的表现, 发现并没有明显的性能下降现象。在各种基于残差网络的架构上进行实验, 获得了一致性的性能提高, 而且付出的计算代价与原始版本相比差别不大, 甚至还低。

关键词: 深度残差学习; 深度神经网络; 机器学习; 信息修正

中图分类号: TP311 **文献标志码:** A

Deep Residual Learning with Information Refinement

XIE Yanping^{1,2,3}, TAN Xiaoyang^{1,2,3}

(1. College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing, 211106, China; 2. MIIT Key Laboratory of Pattern Analysis and Machine Intelligence, Nanjing, 211106, China; 3. Collaborative Innovation Center of Novel Software Technology and Industrialization, Nanjing, 211106, China)

Abstract: A novel extension of residual learning is presented for deep networks which effectively improves the robustness of the learned representation. The method integrates a plug-and-play module, that is, a grouped convolutional encoder-decoder, as additional shortcuts to the original residual architecture. Due to the down-sampling in encoder stage, the decoder modules are driven to produce focally activated feature maps, which highlights the most discriminative regions of input images, and imposes local enhancement on input features through element-wise addition. For efficient model design, we exploit lightweight counterparts by removing part channels of residual mappings, without showing obvious performance degradation. We obtain consistent accuracy gain for various residual architectures with comparable or even lower model complexity.

Key words: deep residual learning; deep neural network; machine learning; information refinement

引言

在当今的计算机视觉任务中,比如图像分类^[1-2]、目标检测^[3-4]和图像分割^[5],深度卷积神经网络(CNNs)已经取得了一系列重大突破。这些成功主要归功于卷积神经网络可以在 ImageNet^[6]和 MS-COCO^[7]等大规模图像数据集上监督训练后泛化到其他各种任务中去。卷积核通过端到端的训练,会在高层产生输入图像的分布式表示^[8],不同的特征图激活不同的图像区域。但是这会带来分类精度的问题,如图1所示(第1行分别是输入图片、原模型输出的各个通道的平均激活和基于本文提出的方法输出的平均激活,第2行是随机采样得到的特定通道的特征图,数字代表通道号),对于1张测试图像而言,一些不相关的背景也会有高的激活值(第2行),会损害卷积神经网络的分类精度。

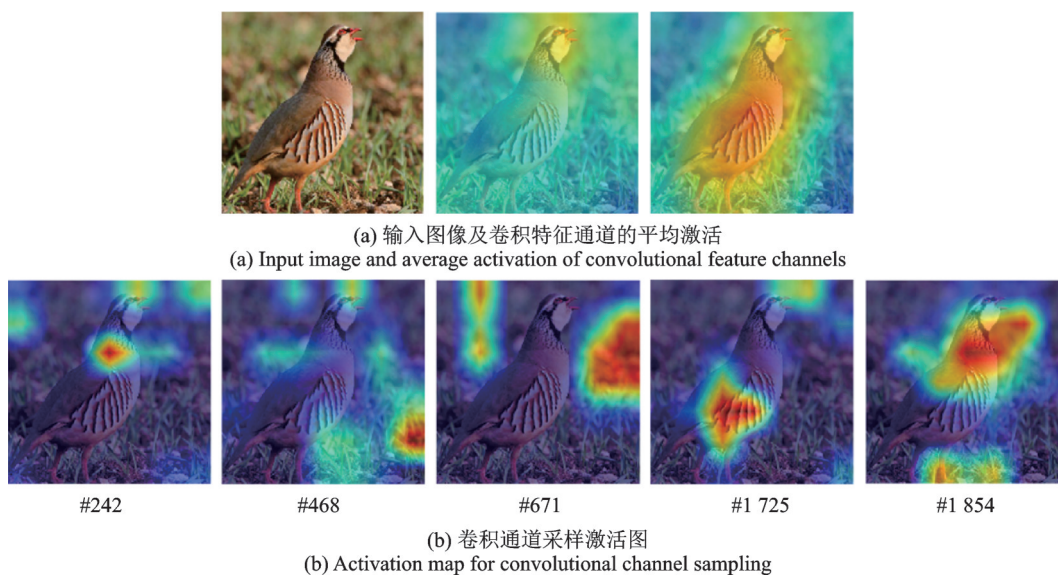


图1 卷积神经网络中输入图像的分布式表示

Fig.1 Distributed representation of input image in convolutional neural networks

深度残差网络(Residual network, ResNet)^[2]引进恒等映射来提高训练效率并且使得更多特征能够被重复利用。最近试图提高残差网络性能的方法可以分为两类:(1)通过注意力机制选择特征^[9]; (2)通过通道维度上的重新加权来进行通道选择^[10]。这些工作主要都是侧重于改善残差函数的表示能力,而对于残差网络至关重要的恒等映射却没有人去提高改善。

本文提出了一种简单的卷积式编码-解码模块(Encoder-decoder, ED)来改善深度残差网络中的恒等映射。首先,恒等映射的作用是传递信息,它的输入合并了来自先前层的所有卷积响应,当然包括那些噪声响应,所以改善恒等映射是非常必要的;其次,由于编码-解码结构可以有效提取关键信息,通过纯粹的无监督学习能很好地恢复输入数据的结构^[11],那么就可以通过监督训练的方式从冗余和噪声信息中提取更多具有判别力的特征。本文在恒等映射的基础上并行增加了编码-解码模块来提高信息传递的质量。此模块能产生激活比较集中的特征图,这些激活往往突出了最具有判别力的地方而抑制了背景区域。通过元素级相加和激活后,恒等映射的输入(被传递的特征)被这些编码-解码模块产生的打分图(特征图)所修正。不仅如此,通过减少残差模块的通道数来降低整个模型的计算复杂度,但是装备了本文提出的信息修正模块的轻量级残差网络却没有明显的精度损失,甚至有些还比原来没有减通道数的残差网络高。本文将这个简单的即插即用模块集成到了一系列现在流行的性能最好的残差网络

结构中,包括ResNet^[2], ResNeXt^[12]以及它们的挤压与激励模块(Squeeze-and-excitation, SE)^[10]版本。本文在ImageNet^[6]和CIFAR^[13]数据集上进行了图像分类实验,在MS-COCO^[7]数据集上进行了目标检测任务。利用这个轻量的编码-解码模块,在各个任务上获得了性能的一致性提高。不仅如此,装备了信息过滤模块的轻量级ResNet-50比原来的ResNet-50少了近一半的每秒浮点运算次数(Floating-point operations per second, FLOPs),但是仍然在精度上优于原模型。

1 研究现状

自2012年以来,神经网络的发展得到了飞速提高,残差网络(ResNet)^[2]的出现使得跨层连接被普遍使用,本节将先介绍跨层连接,然后介绍编码-解码架构,最后介绍分组式卷积操作。(1)通过卷积神经网络的跨层连接来提高网络的性能已经有一段很长的发展历史,其旨在解决梯弥散和爆炸问题,并且使得信息能够在网络中直接流动。高速公路网络^[14]首次使用跨层连接方式来简化深层网络的训练,但是其门控机制带来了非常多的额外参数,导致了优化难度的上升。残差网络简化了高速公路网络的门控机制,直接使用恒等映射作为跨层连接,极大地简化了优化,从而很好地解决了更深层的网络退化问题。(2)编码-解码架构已经被广泛用于数据降维^[15]、无监督特征学习^[16]和语义分割^[17-18]中。在无监督学习领域,编码-解码架构已经能从原始输入中提取信息(甚至是噪声输入^[11])。例如,受限玻尔兹曼机(Restricted Boltzmann machine, RBM)可以恢复输入数据的结构^[15];卷积编码器提取的特征在高级识别任务中比手工特征更加具有判别力^[16]。最近,卷积编码-解码架构适用于解决语义分割任务^[17-18],堆叠的沙漏网络(Hourglass networks)^[19]已经在姿态估计领域表现惊人。(3)分组式卷积首次被使用是在AlexNet^[1]上,卷积神经网络架构设计中广泛采用了组卷积,比如追求高精度的Inception系列^[20-21]和ResNeXt^[12]等大型网络,还有追求高效率的Xception^[22], MobileNet^[23]和ShuffleNet^[24]等适合在计算能力非常有限的移动设备上部署的小型网络。

2 本文方法

文中所用符号说明如下: $F(\cdot)$ 为特征映射函数, x 为输入的卷积特征; $H(\cdot)$ 为特征修正函数; $A(\cdot)$ 为激励函数; $ED(\cdot)$ 为编-解码函数。

2.1 动机、关键因素和选择

在残差网络中,关键的映射方式被定义为“ $F(x) + x$ ”^[2],现在存在的对残差网络的改进都是集中在残差映射 $F(x)$ 上面,比如使用多分支的ResNeXt^[12],使用注意力机制的残差注意力网络(Residual attention networks)^[9],使用通道重加权的SE-ResNet^[10]等。区别于之前的方法,本文专注于“如何重新定义恒等映射”来提升ResNet的分类性能。在ResNet中,跨层连接被简单地定义为恒等映射,这样会将前层产生的噪声响应也传到后层,甚至整个网络。因此改造恒等映射“ $+x$ ”也是一种提高网络性能的方式,这样的一种改造方式能够加强输入信号中富有判别力区域的响应,同时抑制不相关区域,它会有利于提高分类能力。

一个非常自然的方式是利用一个卷积编码-解码模块去修正跨层连接的输入 x ,将重新定义的跨层连接映射记为 $H(x)$ 。选择编码-解码架构的原因在于其两个性质:一方面可以从纯粹的无监督学习方式中分离有用信息^[15-16];另外一方面,在标准的监督学习中可以根据不同的任务提取具备相应特性的强大语义信息(例如语义分割)^[17-18]。

把卷积编码-解码模块作为恒等映射的并行连接,如图2(a)所示,因此最后的映射表示为

$$H(x) = A(x + ED(x)) \quad (1)$$

重新定义的跨层连接不会像高速公路网络一样带来非常多的额外参数,导致深层网络难以训练的后果。

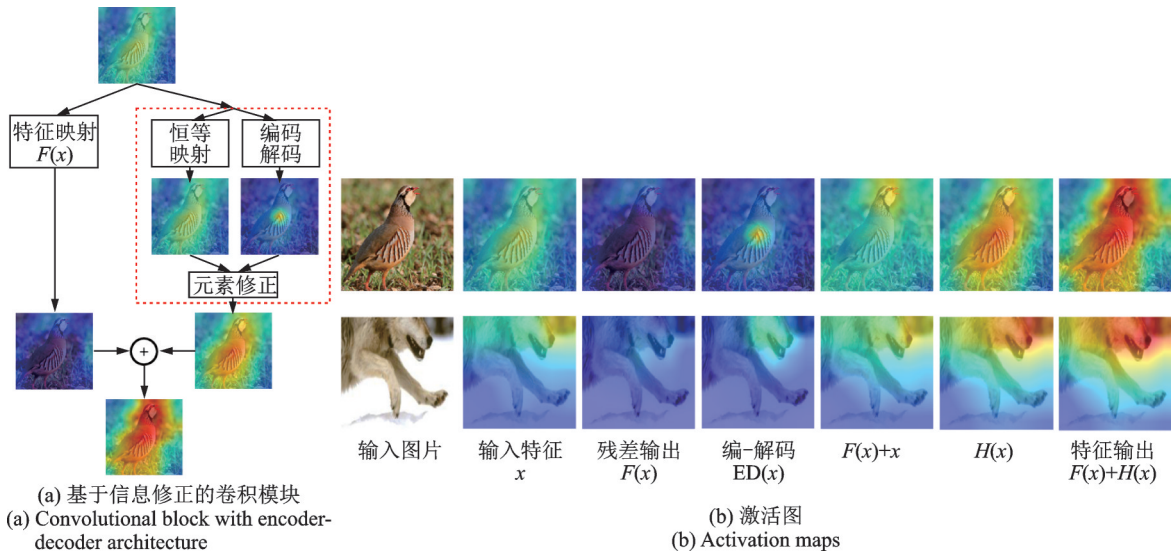


图2 基于信息修正的卷积模块及其激活图

Fig.2 Convolutional block with encoder-decoder architecture and activation maps

2.2 卷积编码-解码连接

编码-解码(ED)连接可以被集成到任意的残差网络中,比如 ResNet, ResNeXt 等。最后为了计算高效,本文又实现了它们的轻量版本。

(1) 对 ResNet 和 ResNeXt 的集成非常方便,把集成的模型称为“ED-ResNet”和“ED-ResNeXt”。将 ED 的卷积操作进行了分组(共 32 组),同时使用重构损失来指导 ED 模块的训练,图 3 给出了实现细节示意图。

(2) 轻量级版本的实现是为了比较的公平性。在原始的网络上增加 ED 模块会引起计算量的少量增加,相应减少了残差模块分支的通道数以保持计算量的相等,从而证明 ED 模块能够提高网络的分类能力。

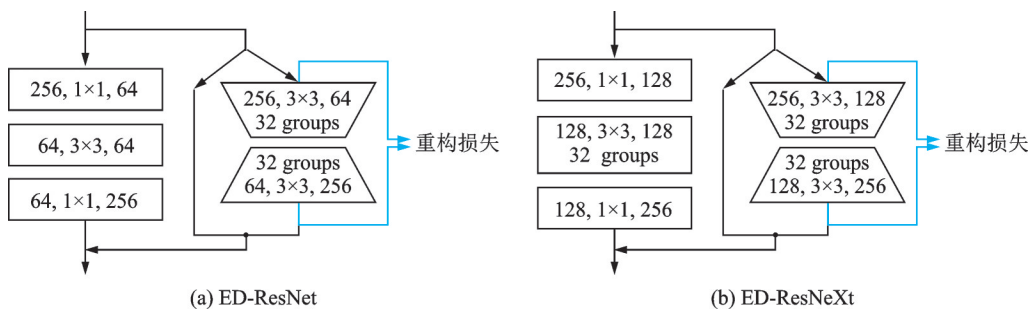


图3 组成 ED-ResNet 和 ED-ResNeXt 的卷积模块

Fig.3 Convolutional block of ED-ResNet and ED-ResNeXt

2.3 可视化和分析

编码-解码模块输出拥有集中激活的特征图,这些特征图保持了输入中正确激活的响应,同时抑制了错误激活的响应。图 2(b)中给出了输入特征图、残差映射特征图、ED 模块特征图以及它们的组合在原始输入图片上的响应。输入特征 x 有着非常多的激活点,这些激活点包含了很多无关的背景区域,但是 ED 模块提取信息后,通过元素级别的相加与非线性映射,原始输入被 ED 的输出特征图修正。

3 实验与分析

在ImageNet数据集上,参照了大家公认的 AlexNet^[1]和 ResNet^[2]的实验设定。图片被裁剪到 224 边长,每张图片都做 1 次标准的归一化后被随机的水平翻转作为输入。选择使用随机梯度下降(Stochastic gradient descent, SGD)作为优化器, Momentum 设置成 0.9, Weight decay 设置成 0.000 1, Batch size 设置成 256,并且利用 8 块 GPU 训练网络,初始化学率是 0.1,每次经过 30 轮训练后将学习率除以 10,一共进行 100 轮训练。在每次卷积后,利用了 Batch normalization^[25]来进行归一化,紧接着是 ReLU^[26]层。编码器由简单的 3 边长卷积层构成,步长设定为 2 来进行降维,编码器由 3 边长的反卷积组成,步长也设定为 2,重构损失使用 MSE。

在 CIFAR 数据集上进行了分析实验。训练时每张图片外面补充 4 排 0,使得图片尺寸变为 36,然后随机裁剪到 32 边长,测试时保持原图片不变。这些设定都是参考了目前大家公认的设置(ResNet^[2]),所有的模型都训练 300 轮,初始化学率为 0.1,在第 150 轮和第 225 轮将学习率除以 10, Batch size 设定为 128。本节给出了在 ImageNet 数据集上的图像分类实验、在 CIFAR 上的分析实验和在 MS-COCO 上的目标检测实验。

3.1 ImageNet 上的对比实验

在 ImageNet 上进行了 3 个系列的实验来证明本文提出的 ED 模块的有效性。为了记号的简单,把装备了 ED 模块的网络记为 ED-Net,为了保证公平性,所有的实验都将复现。

(1) 与原模型的对比实验。ResNet 和 ResNeXt 是当今最流行且有效的两个残差网络的代表,将它们作为本文的对比实验。如表 1 所示,本文的 ED 模块能够帮助其进一步提高精度。

表 1 原模型与 ED 版本对比
Table 1 Comparison between baseline and ED-Nets

模型	原始模型 Nets		本文提出的 ED-Nets	
	Top-1 error	Top-5 error	Top-1 error	Top-5 error
ResNet-50	24.41	7.36	23.14	6.58
ResNet-101	23.22	6.57	22.19	6.19
ResNeXt-50	22.61	6.43	22.07	6.16
ResNeXt-101	21.37	5.70	20.89	5.28

(2) 与 SE-Net 的对比实验。Squeeze-and-Excitation 模块(SE)^[10]获得了最后一届 ImageNet 大规模图像分类大赛的冠军。本文比较了装备 ED 模块的 SE-Net 与原始网络的性能,表 2 的结果显示本文的 ED 模块得到了一致性的精度提升。

(3) 轻量级版本模型的实验。因为本文的 ED 模块轻微增加了模型的计算复杂度,所以为了公平

表 2 SE 版本与 ED 版本对比
Table 2 Comparison between SE-Nets and ED-Nets

模型	原始模型		本文提出的 ED 版本	
	Top-1 error	Top-5 error	Top-1 error	Top-5 error
SE-ResNet-50	23.25	6.56	22.40	6.21
SE-ResNet-101	22.39	6.17	21.68	6.01
SE-ResNeXt-50	21.55	5.68	21.16	5.58
SE-ResNeXt-101	21.35	5.56	20.81	5.24

比较,通过减少残差分支的通道数实现了轻量级模型比较,以此来证明ED模块的精度提升能力。对于ED-ResNet-50,本文依次减少了其4,8,16和32个残差分支的通道数,把它记为ED-ResNet-50-A;为了进一步探索其模型压缩能力,本文直接减少了残差分支一半的通道数,把它记为ED-ResNet-50-B。对于ED-ResNeXt-50,本文依次减少了其20,40,80和160个残差分支的通道数,同时配合相应的分组,将它记为ED-ResNeXt-50-A;本文又进一步减少了残差分支一半的通道数,将其记为ED-ResNeXt-50-B。实验结果如表3所示,结果表明ED有助于降低模型的计算复杂度,且可能在模型压缩领域得到利用。

表3 基于计算量的公平性比较
Table 3 Apple-to-apple comparison

模型	Top-1 error/%	Top-5 error/%	GFLOPs/10 ⁹ 次
ResNet-50	24.41	7.36	4.1
ED-ResNet-50-A	23.10	6.49	4.0
ED-ResNet-50-B	23.97	6.97	2.1
ResNet-101	23.22	6.57	7.9
ED-ResNet-101-A	22.24	6.25	7.8
ED-ResNet-101-B	23.19	6.53	3.9
ResNeXt-50	22.61	6.43	4.2
ED-ResNeXt-50-A	22.13	6.20	4.2
ED-ResNeXt-50-B	22.67	6.45	2.9
ResNeXt-101	21.37	5.70	8.0
ED-ResNeXt-101-A	20.95	5.34	7.9
ED-ResNeXt-101-B	21.61	5.73	5.4

3.2 CIFAR上的分析实验

在CIFAR上进行了分析实验,从两个方面证明了ED模块的有效性。(1)卷积编码-解码模块与2个卷积层的对比是为了进一步证明ED模块对模型精度提升的有效性,2个卷积层指把ED模块的编码器和解码器都用普通的3边长卷积层替换。表4的结果表明ED模块一致优于2个卷积层。不仅如此,在ResNeXt的实验中,发现2个卷积层不仅不能带来精度提升,还会损害原模型的判别能力,但是本文的ED模块仍然可能帮助模型提高精度。(2)为了探索组卷积带来的影响进一步进行了实验研究。表5的结果表明,组卷积只会带来性能的降低,当计算资源有限时,建议使用卷积分组。

表4 CIFAR上的双卷积版本与ED版本错误率对比
Table 4 Comparison between two-convolution and ED-Nets on CIFAR

模型	原始版本	ED版本	双卷积版本
ResNet-20	7.81	7.33	7.57
ResNet-32	7.32	6.67	6.83
ResNet-44	6.95	6.21	6.36
ResNet-56	6.47	5.93	6.27
ResNet-110	5.78	5.63	6.15
ResNeXt-29	3.66	3.57	3.79

表5 卷积分组对性能和计算效率的权衡

Table 5 Trade-off between accuracy and complexity with and without grouped convolutions

模型	原始版本		不分组的ED版本		卷积分组的ED版本	
	错误率/%	参数量/ 10^6 次	错误率/%	参数量/ 10^6 次	错误率/%	参数量/ 10^6 次
ResNet-20	7.81	0.27	6.77	0.56	7.33	0.30
ResNet-32	7.32	0.46	6.46	0.94	6.67	0.51
ResNet-44	6.95	0.66	5.97	1.34	6.21	0.72
ResNet-56	6.47	0.85	5.79	1.73	5.93	0.92
ResNet-110	5.78	1.70	5.53	3.40	5.63	1.84

3.3 MS-COCO上的目标检测实验

为了评估ED模块的泛化能力,本文还在MS-COCO的目标检测任务上进行了实验,本文使用官方给定的8万张图片训练,4万张图片测试。本文使用的算法是Faster R-CNN^[4],将基础模型ResNet改成ED-ResNet后,表6的结果表明本文的ED模块能够很好地泛化到目标检测任务中。

表6 用Faster R-CNN在MS-COCO上的目标检测实验

Table 6 Object detection on MS-COCO using faster R-CNN

%

模型	mmAP	AP@0.50	AP@0.75	AR100
ResNet-50	31.2	50.8	33.4	43.8
ED-ResNet-50	33.0	53.2	35.6	45.9
ResNet-101	32.3	52.1	35.0	45.6
ED-ResNet-101	35.2	55.2	37.7	48.1

4 结束语

本文提出了一种新颖的、简单又有效的方法来处理深度残差学习中的恒等映射问题。尽管恒等映射是当前残差学习成功的关键因素,它使得反向传播的梯度信息能够在非常深的网络中流动,但是它也可以看做一种信息聚合,将底层就产生的噪声信息进行传递,使之充满整个网络。这些噪声信息会严重干扰最后的分类结果,本文提出的ED模块表现出了优秀的信息选择能力,而且带来的计算复杂度非常小。轻量级版本的结果表明本文的ED模块可能在模型压缩领域得到运用。在当下流行的大型图像数据集上的大量实验表明,本文方法始终有利于提升残差网络的性能,有效降低噪声信号的传输并提高其高级语义表示能力。

参考文献:

- [1] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Image classification with deep convolutional neural networks[C]//Proceedings of Annual Conference on Neural Information Processing Systems.[S.l.]: MIT Press, 2012: 1097-1105.
- [2] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition.[S.l.]: IEEE, 2016: 770-778.
- [3] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition.[S.l.]: IEEE, 2014: 580-587.
- [4] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks. [C]//Proceedings of Annual Conference on Neural Information Processing Systems.[S.l.]:MIT Press, 2015: 91-99.
- [5] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//Proceedings of

- IEEE Conference on Computer Vision and Pattern Recognition.[S.l.]: IEEE, 2015: 3431-3440.
- [6] RUSSAKOVSKY O, DENG J, SU H, et al. Imagenet large scale visual recognition challenge[J]. *International Journal of Computer Vision*. [S.l.]: Springer, 2015, 115(3): 211-252.
- [7] LIN T Y, MAIRE M, BELONGIE S, et al. Microsoft COCO: Common objects in context[C]//*Proceedings of European Conference on Computer Vision*. [S.l.]: Springer, 2014: 740-755.
- [8] BENGIO Y, COURVILLE A, VINCENT P. Representation learning: A review and new perspectives[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. [S.l.]: IEEE, 2013, 35(8): 1798-1828.
- [9] WANG F, JIANG M, QIAN C, et al. Residual attention network for image classification[C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.]: IEEE, 2017: 3156-3164.
- [10] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.]: IEEE, 2018: 7132-7141.
- [11] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion[J]. *Journal of Machine Learning Research*. [S.l.]: MIT Press, 2010, 11: 3371-3408.
- [12] XIE S, GIRSHICK S, DOLLAR P, et al. Aggregated residual transformations for deep neural networks[C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.]: IEEE, 2017: 5987-5995.
- [13] KRIZHEVSKY A, HINTON G. Learning multiple layers of features from tiny images[R]. Citeseer: [s.n.], 2009.
- [14] SRIVASTAVA R K, GREFF K, SCHMIDHUBER J. Highway networks[J]. *arXiv preprint arXiv: 1505.00387*, 2019.
- [15] HINTON G E, SALAKHUTDINOV R. Reducing the dimensionality of data with neural networks[J]. *Science*, 2006, 313(5786): 504-507.
- [16] HUANG F J, BOUREAU Y L, LECUN Y. Unsupervised learning of invariant feature hierarchies with applications to object recognition[C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.]: IEEE, 2007: 1-8.
- [17] BADRINARAYANAN V, KENDALL A, CIPOLLA R. Segnet: A deep convolutional encoder-decoder architecture for image segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. [S.l.]: IEEE, 2017, 39(12): 2481-2495.
- [18] NOH H, HONG S, HAN B. Learning deconvolution network for semantic segmentation[C]//*Proceedings of International Conference on Computer Vision*. [S.l.]: IEEE, 2015: 1520-1528.
- [19] NEWELL A, YANG K, DENG J F. Stacked hourglass networks for human pose estimation[C]//*Proceedings of European Conference on Computer Vision*. [S.l.]: Springer, 2016: 483-499.
- [20] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions[C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.]: IEEE, 2015: 1-9.
- [21] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.]: IEEE, 2016: 2818-2826.
- [22] CHOLLET F. Xception: Deep learning with depthwise separable convolutions[C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.]: IEEE, 2017: 1251-1258.
- [23] HOWARD A G, ZHU M, CHEN B, et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications [J]. *arXiv preprint arXiv: 1704.04861*, 2017.
- [24] ZHANG X Y, ZHOU X, LI M, et al. Shufflenet: An extremely efficient convolutional neural network for mobile devices[C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.]: IEEE, 2018: 6848-6856.
- [25] IOFFE S, SZEGEDY C. Batch Normalization: Accelerating deep network training by reducing internal covariate shift[C]//*Proceedings of International Conference on Machine Learning*. [S.l.]: ACM, 2015, 448-456.
- [26] NAIR V, HINTON G E. Rectified linear units improve restricted boltzmann machines[C]//*Proceedings of International Conference on Machine Learning*. [S.l.]: ACM, 2010: 807-814.

作者简介:



谢烟平(1994-),男,硕士研究生,研究方向:计算机视觉方向研究,E-mail:nuaaxyp@nuaa.edu.cn。



谭晓阳(1971-),男,教授,研究方向:人工智能方向研究,E-mail:x.tan@nuaa.edu.cn。

(编辑:刘彦东)