

# 基于改进卷积神经网络的单幅图像物体重建方法

张玉麒 陈加\* 叶立志 田元 夏丹 陈亚松

(华中师范大学教育信息技术学院 湖北 武汉 430079)

**摘要** 为了提高基于图像的三维重建的重建效果,基于深度学习的方法已经成为近年来研究的重点。针对目前存在的方法中特征提取效果差、重建细节缺失且计算量巨大的问题,提出一种改进卷积神经网络的单个物体重建方法。通过加入改进的 Inception-resnet 模块来提升网络的特征提取能力,采用多种网络结构提取多特征,通过多特征依次输入 3D-LSTM 模块中以增强单幅图像的重建效果。实验结果表明,该方法不仅能够得到更好的重建效果,重建出更多的细节,同时在训练中花费更少的时间。

**关键词** 卷积神经网络 三维重建 单幅图像 计算机视觉

中图分类号 TP3

文献标识码 A

DOI:10.3969/j.issn.1000-386x.2019.06.036

## SINGLE IMAGE OBJECT RECONSTRUCTION METHOD BASED ON IMPROVED CONVOLUTIONAL NEURAL NETWORK

Zhang Yuqi Chen Jia\* Ye Lizhi Tian Yuan Xia Dan Chen Yasong

(College of Educational Information Technology, Central China Normal University, Wuhan 430079, Hubei, China)

**Abstract** To improve the performance of 3D reconstruction, methods based on deep learning have been the main topic of the research. Aiming at the problems of poor feature extraction effect, lack of reconstruction details and huge computational load, we proposed a 3D objects reconstruction method from a single image based on improved convolutional neural network. The feature extraction capability of the network was improved by adding modules that combine residual connections and Inception. We used multi-features extracted by multi-network structure, and input it into 3D-LSTM module in turn to enhance the reconstruction effect of a single image. The experimental results show that our method can not only perform better in reconstruction, but also spend less time in training.

**Keywords** Convolutional neural network 3D reconstruction Single image Computer vision

## 0 引言

从二维图像中获得三维信息并恢复三维模型是计算机视觉研究的主要方向之一。基于图像的三维重建在诸如商品展示、文物三维修复、智慧城市建设、医疗器官重建等领域也具有重要的应用价值<sup>[1-5]</sup>。基于图像的三维重建问题按照重建图像的数量可以分为基于多幅图像的三维重建方法<sup>[6-9]</sup>和基于单幅图像的重建方法,按照重建的内容可以分为对物体的重建和对场景的重建<sup>[10]</sup>。本文主要针对基于单幅图像的物体重

建方法展开研究。

传统方法按照重建方法的不同可以分为基于模型的重建方法和基于几何外形恢复的重建方法。基于模型重建的方法通过匹配输入图像和模型,找到模型的最佳参数来进行重建。基于 CAD 模型的方法<sup>[11-12]</sup>,能够大致地展现物体的近似外形,在找到一组对应点后,可以很好地确定相应实例的视点,但是其获得的模型和实际的模型仍然有很大偏差。形变模型(Morphable model)常用来重建人脸部分<sup>[13-14]</sup>,其主要为一些可以变形的线性组合模型,通常由一些三维扫描的设备获取。Cashman 等<sup>[15]</sup>找到了降低三维数据获取

门槛的方式,通过三维模型和辅助的二维信息学习到相应的形变模型来重建物体。Vicente 等<sup>[16]</sup>先在图像数据集中匹配一张和输入图像相同类型相似视角的图像,结合了可视外壳的方法,但是其无法应用于真实拍摄的图像。Kar 等<sup>[17]</sup>在 Vicente 等的工作基础上,通过物体的二维注释来学习相应的形变模型,不但可以重建真实拍摄的图像,在重建效果上也了一定的提升。基于模型的方法因为存在设计好的模型,对固定类别的物体能够取得相对较好的重建效果,但是无法具有较好的泛化性。基于几何外形恢复的方法主要包括从阴影中恢复外形(Shape from shading)<sup>[18-19]</sup>和从纹理中恢复外形(Shape from texture)<sup>[20-21]</sup>,基于几何外形恢复的方法能重建较多种类的物体,但其往往对灰度和光照等要求较高,对真实场景的物体图片的重建效果欠佳。

近年来,随着深度学习技术的不断发展,出现了基于深度学习的物体重建方法。Choy 等<sup>[22]</sup>提出了一套端到端的基于体素的重建网络结构(3D recurrent reconstruction neural network, 3D-R2N2),与传统方法通过匹配一个最近似的模型并不断优化其参数得到最佳模型不同,3D-R2N2 利用大量的训练去学习二维图像和三维模型之间的映射,其无需对图像加入分类标签。在以 IoU (Intersection-over-Union) 值作为评价指标的对比实验中,3D-R2N2 的重建效果优于效果最好的传统方法。但其在重建精度上仍无法达到可以使用的程度,且部分重建细节如桌腿等会存在缺失的问题,相较于二维领域也存在着计算量大、训练时间长的缺点。此外也出现了基于深度学习的点云重建方法<sup>[23-25]</sup>和网格重建方法<sup>[26-28]</sup>,与传统方法相比也取得了较好的重建效果。

本文采用与 3D-R2N2 相似的网络结构来做基于体素的单幅图像物体重建,并针对相应模块作出改进。本文方法具有如下特点:

(1) 针对 Encoder 模块进行了改进。本文的 Encoder 模块使用改进的 inception-resnet 网络结构,并使用全局平均池化来代替全连接层,与 3D-R2N2 的重建结果相比能够得到更高的 IoU 值,重建精度更高。

(2) 针对单幅图像信息量少的问题,采用多种网络结构提取多特征并依次输入 3D-LSTM 模块中,从而增强单幅图像的重建效果。

(3) 与 3D-R2N2 相比,本文提出的方法具有更低的计算开销。

## 1 3D-R2N2 网络模型

3D-R2N2 网络采用监督学习的方式,仅在边界框信息(Bounding boxes)的辅助下,就可以端到端地从单

幅或者多幅图像中重建出图像中物体的三维模型。其网络结构由三部分组成:卷积神经网络构成的编码器(Encoder)、三维卷积长短期记忆网络(3D convolutional LSTM)和解码器(Decoder)。

### 1.1 Encoder 模块

Encoder 模块将输入的图像转化为较低纬度的特征向量。其网络结构包含了 12 个卷积层,1 个全连接层和 5 条残余连接(Residual connection)。其中残余连接是在每两个卷积层间添加,为了匹配卷积操作后的通道数,残余连接使用  $1 \times 1$  卷积。Encoder 模块最终输出一个维度为 1 024 的特征向量。

### 1.2 3D convolutional LSTM 模块

3D convolutional LSTM 模块通过 Encoder 模块得到的特征向量去更新其中记忆单元的信息。该模块由  $n \times n \times n$  个 3D-LSTM 单元组成,其中  $n$  为 3D-LSTM 网络的空间分辨率。3D-LSTM 单元在空间上分布在 3D 网络结构中,每个单元负责重建特定部分的最终输出,其都对应最终重建输出矩阵的一个元素( $i, j, k$ ),单元中还伴随着一个独立的隐藏状态  $h_i$ 。

### 1.3 Decoder 模块

Decoder 模块接收 3D-LSTM 传来的隐藏状态  $h_i$ ,并将它们转化为体素块存在与否的概率,最终通过得到每个体素块概率的值为 0 或者 1 来确认是否重建该体素块。与 Encoder 模块相同,Decoder 模块也由卷积神经网络和相应的残余连接组成,但这里使用了  $3 \times 3 \times 3$  的卷积核进行三维卷积,同时在 Decoder 模块会进行三维上池化(3D unpooling)来对三维信息进行处理。

## 2 改进神经网络的单幅图像物体重建方法

### 2.1 对 Encoder 模块的优化

尽管 3D-R2N2 的 Encoder 模块使用了带有残余连接的卷积网络,但仍存在着特征提取效果差导致的重建精度问题。GooleNet<sup>[29]</sup>首次提出的 Inception 模块可以一次性使用多个不同尺寸的卷积核,能够让网络自己选择需要的特征,如选择大尺寸的卷积核可以抓取到像素与周边像素之间的关系。同时,Inception 模块增大了网络宽度,能够对有噪声的图片提取到更多的深度特征,让含噪声的图片具有更好的泛化能力。受到 Szegedy 等<sup>[30]</sup>提出的方法的启发,本文在保存残余连接的同时加入了 Inception 模块,既能够利用 Resnet 中的残余连接解决梯度消失的问题,又能够利用 Inception 模块提取更深更细节的图像特征。本文设计了两种改进的 Inception-resnet 模块,其中 Inception-resnet-A 结构如图 1 所示。

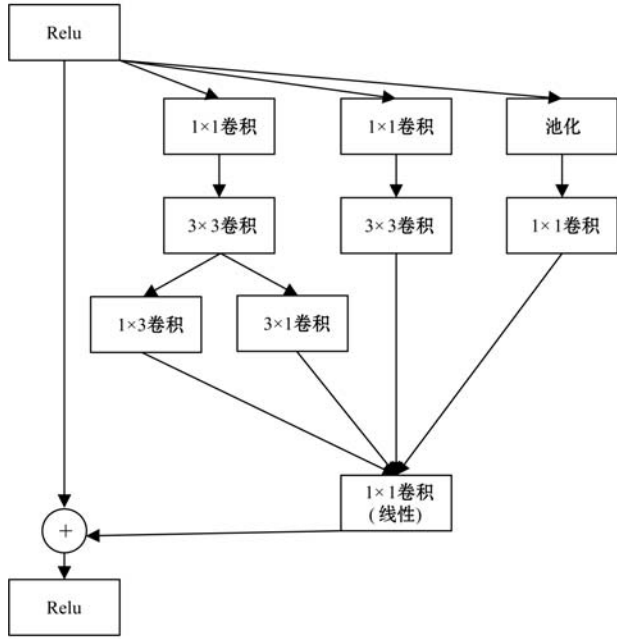


图1 Inception-resnet-A 的结构

Inception-resnet-A 模块包括 3 个卷积分支,在第一个卷积分支中将  $3 \times 3$  卷积替换为  $1 \times 3$  和  $3 \times 1$  两种大小的卷积核,这种非对称卷积核能够替代  $3 \times 3$  卷积核的同时节省计算量,并提取到更多图像的局部特征。放在  $3 \times 3$  卷积核前的  $1 \times 1$  卷积用于控制输入特征的通道数。第三个卷积分支使用池化来增加整体的非线性特征。同时模块仍保留着残余连接,整体模块使用较小的卷积核,但能够较好地提取局部特征。

Inception-resnet-B 模块采用了更大的卷积核尺寸,  $5 \times 1$  和  $1 \times 5$  两个卷积核由  $5 \times 5$  的卷积核拆分得到,中间分支仅采用了  $1 \times 1$  特征用来对不同通道的特征进行统一。该结构能够更好地抓取像素与像素之间的关系。其结构如图 2 所示。

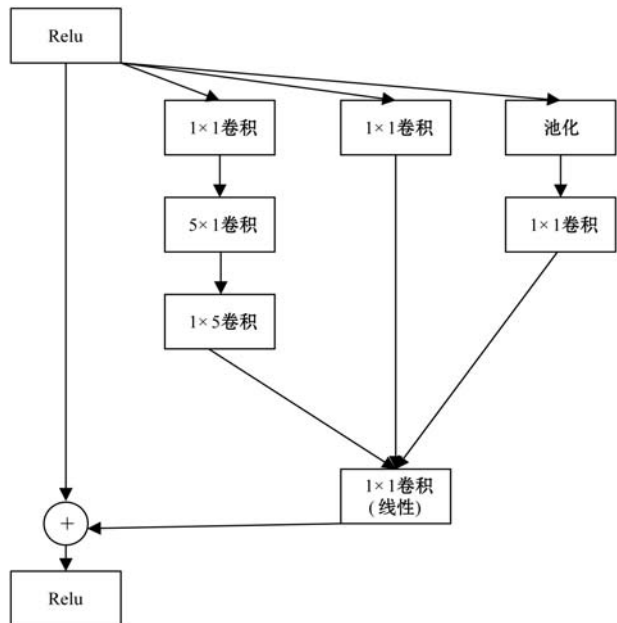


图2 Inception-resnet-B 的结构

3D-R2N2 的 Encoder 模块中的全连接层所含参数量较大,极大地增加了训练的计算量,占用了较多的时间。本文利用全局平均池化来替代全连接层,全局平均池化不但减少了参数的数量,同时也对整个模块起到正则化的作用。其主要思想是将卷积层的每个输出的特征图的值统一为一个值,建立起了特征图与类之间的对应关系。假设最终的特征图大小为  $a \times b$ ,第  $k$  张特征图的值为  $x_{ij}^{(k)}$ ,则该特征图对应的输出为:

$$y^{(k)} = \frac{1}{a \times b} \left[ \sum_{i=0}^a \sum_{j=0}^b x_{ij}^{(k)} \right] \quad (1)$$

改进后的 Encoder 模块的网络结构如图 3 所示。与 3D-R2N2 相比,网络在层数上没有增加,网络的前四层没有变化,仍使用带有残余连接的卷积神经网络。但是从第五层开始使用了改进的 Inception-resnet 模块替换了单纯带有残余连接的卷积网络,每个 Inception 的分支后连接有  $1 \times 1$  的线性卷积核,其主要用来统一跳跃连接后的通道维度。输入的图片经过 Inception-resnet 模块后,再经过全局平均池化的处理,最终输出一个维度为 1 024 的特征向量。

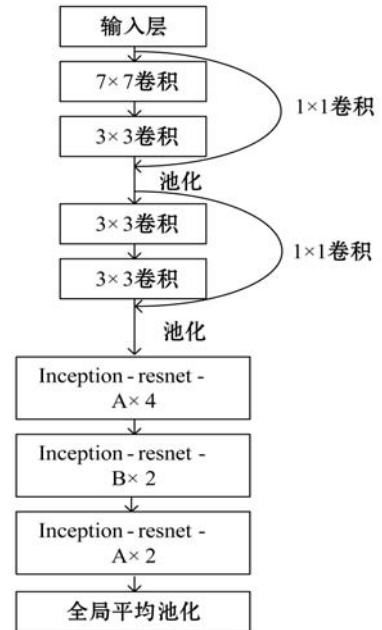


图3 改进的 Encoder 模块网络结构

### 2.2 多特征重建网络

使用不同的 Encoder 网络结构会得到不同的重建结果,原因在于不同的网络结构的特征提取能力不同,某一种网络结构在特定的特征上表现出较好的能力,但可能在其他特征上表现较差。单幅图像本身就包含较少的信息,如果只使用一种网络结构用作特征提取,则会限制重建的性能。

本文在 Encoder 模块中使用多种网络结构进行特征提取,采用的网络结构有 AlexNet<sup>[31]</sup>、ResNet<sup>[32]</sup>、DenseNet<sup>[33]</sup> 以及本文中改进的 Inception-resnet, 几种

网络结构均为现有方法中具有开创性且效果较好的网络结构。在本文提出的多特征重建网络框架中,四种网络结构对同一张图像提取到四种不同的特征,所提取的四种特征分别依次输入 3D-LSTM 中并进行整合,从而达到模拟多幅图像的重建的过程,进而增强单幅图像的重建效果。多特征重建网络的整体结构如图 4 所示。




图 4 多特征重建网络结构框架

### 3 实验与结果分析

本文使用 Theano 框架来实现相应的网络模型。实验在配置有 Intel Xeon E3 1230 V5 CPU(3.40 Ghz),Nvidia GeForce 1080 Ti GPU(11 GB)的硬件平台上进行。

#### 3.1 实验数据集与评价标准

本文采用 ShapeNet 数据集<sup>[34]</sup>作为网络训练和测试所使用的数据集。该数据集包括了 13 个种类共 43 783 个 CAD 模型,本文采用数据集中的 37 192 个 CAD 模型作为训练集,6 591 个剩余的 CAD 模型作为测试集。

本文采用 IoU 值,也即网络输出结果与对应真实模型的交叠率作为评价三维重建精度的评判标准。

#### 3.2 网络模型及训练

网络输入的图像大小为  $127 \times 127$ ,输出体素大小为  $32 \times 32 \times 32$ ,在网络模型中使用了 Adam 算法<sup>[35]</sup>来优化梯度下降过程,加速网络的训练速度,其中的超参数  $\beta_1$  值为 0.9, $\beta_2$  值为 0.999,权重衰减值为  $5 \times 10^{-6}$ 。LeakyReLU 中斜率设置为 0.1,初始的学习率设置为了  $10^{-5}$ 。为了实现实验的公平对照,本文网络的初始超参数值采用了和 3D-R2N2 一样的设置。多特征重建网络的四种网络结构均采用与 3D-R2N2 相同的 12 层。

#### 3.3 ShapeNet 数据集实验结果分析

本文针对 ShapeNet 数据集中 13 个种类的物体分别进行了实验,并且针对 Encoder 模块的改动以及多特征重建网络分别做了单一的对照实验,仅使用改进后的 Inception-resnet 模块的网络称为 New encoder 3D-R2N2,使用多种网络结构作为 Encoder 的多特征网络结构称为 Multi-feature 3D-R2N2。表 1 显示 New encoder 3D-R2N2 在 13 个主要类别中有 7 类的重建效果优于

3D-R2N2,Multi-feature 3D-R2N2 在 13 个主要类别中有 10 类优于 3D-R2N2,且两者整体平均重建表现均优于 3D-R2N2,该结果证明了本文方法的有效性。实验分析可知,引入改进后的 Inception-resnet 结构的 Encoder 模块能够更好地提取图像的细部特征及深度特征,在面对灯、电话等重建细节较多的物体时有相对较大的效果提升。但在面对诸如桌子、橱柜等结构相对简单的物体,其表现反而不如 3D-R2N2,这也印证了本文提到的使用不同的网络结构提取特征,会对不同的特征产生不同的表现。而使用了多种网络结构来提取多特征的多特征重建网络,对重建效果的提升则是全面的,仅在飞机、灯和步枪三类上 IoU 值与 3D-R2N2 近乎持平,其余 10 类均优于 3D-R2N2。本文将多特征重建网络的重建模型与 3D-R2N2 进行了对比,其重建模型对比如图 5 所示。通过模型对比可以看出,本文的重建结果拥有更多细节,重建效果更好。

表 1 不同重建方法的 IoU 值对比

种类	3D-R2N2	New encoder 3D-R2N2	Multi-feature 3D-R2N2
飞机	0.513	0.530	0.510
长凳	0.421	0.547	0.450
橱柜	0.716	0.638	0.740
车	0.798	0.695	0.804
椅子	0.466	0.695	0.497
监视器	0.468	0.548	0.497
灯	0.381	0.496	0.350
扬声器	0.662	0.642	0.687
步枪	0.544	0.510	0.509
沙发	0.628	0.642	0.661
桌子	0.513	0.497	0.512
电话	0.661	0.557	0.669
船舶	0.513	0.559	0.569
均值	0.560	0.571	0.580




图 5 多特征重建网络与 3D-R2N2 的重建效果对比

### 3.4 改进的 Encoder 模块对计算开销的提升

为了验证改进 Inception-resnet 后的 Encoder 模块对计算开销的提升,本文仍使用 ShapeNet 数据集对模型的训练时间及训练模型的参数数量进行对比,其结果如表 2 所示。

表 2 不同重建方法训练时间及参数数量比较

算法	训练时间/小时	参数数量/个
3D-R2N2	7.5	1 697 219
New encoder 3D-R2N2	4.5	723 121

其中,由于全局平均池化取代了全连接层大量的参数,使得参数数量减掉了 60%,同时参数的减少也加快了训练的时长,Inception-resnet 模块中加入的非对称卷积核也能省去该模块近 1/3 的训练时间,最终改进的网络结构在训练时间上也有了较大的改善。实验结果也证明了本文所提方法对计算开销的提升。

## 4 结 语

本文采用类似于 3D-R2N2 的网络结构,通过使用改进的 Encoder 模块及结合多特征的重建网络结构,进一步提高了特征的表达能力和网络的优化能力。通过实验对重建的输出模型的 IoU 值计算,得到的结果证明了本文方法在重建精度上和计算开销上的提升。下一步的工作是添加一些人为设计的结构信息和几何信息作为网络的辅助信息,从而提高该类物体的重建精度。

## 参 考 文 献

- [1] Kemelmacher-Shlizerman I, Basri R. 3D face reconstruction from a single image using a single reference face shape[J]. IEEE transactions on pattern analysis and machine intelligence, 2011, 33(2): 394-405.
- [2] Baka N, Kaptein B L, De Bruijne M, et al. 2D-3D shape reconstruction of the distal femur from stereo X-ray imaging using statistical shape models[J]. Medical image analysis, 2011, 15(6): 840-850.
- [3] Dworzak J, Lamecker H, Von Berg J, et al. 3D reconstruction of the human rib cage from 2D projection images using a statistical shape model[J]. International journal of computer assisted radiology and surgery, 2010, 5(2): 111-124.
- [4] 陈加, 张玉麒, 宋鹏, 等. 深度学习在基于单幅图像的物体三维重建中的应用[J]. 自动化学报, 2019, 45(4): 657-668.
- [5] 陈加, 吴晓军. 联合 LBS 和 Snake 的 3D 人体外形和运动跟踪方法[J]. 计算机辅助设计与图形学学报, 2012, 24(3): 357-363.
- [6] Chen J, Wu X, Wang M Y, et al. Human Body Shape and Motion Tracking by Hierarchical Weighted ICP[C]//Proceedings of the 7th international conference on Advances in visual computing—Volume Part II. Springer-Verlag, 2011: 408-417.
- [7] Häming K, Peters G. The structure-from-motion reconstruction pipeline—a survey with focus on short image sequences[J]. Kybernetika, 2010, 46(5): 926-937.
- [8] Lhuillier M, Quan L. A quasi-dense approach to surface reconstruction from uncalibrated images[J]. IEEE transactions on pattern analysis and machine intelligence, 2005, 27(3): 418-433.
- [9] Kar A, Häne C, Malik J. Learning a multi-view stereo machine[C]//Advances in neural information processing systems, 2017: 365-376.
- [10] Oswald M R, Töppe E, Nieuwenhuis C, et al. A review of geometry recovery from a single image focusing on curved object reconstruction[M]//Innovations for Shape Analysis, Models and Algorithms, Springer, 2013: 343-378.
- [11] Lim J J, Pirsiavash H, Torralba A. Parsing ikea objects: Fine pose estimation[C]//Proceedings of the IEEE International Conference on Computer Vision, 2013: 2992-2999.
- [12] Satkin S, Rashid M, Lin J, et al. 3dmn: 3d nearest neighbor[J]. International Journal of Computer Vision, 2015, 111(1): 69-97.
- [13] Blanz V, Vetter T. A morphable model for the synthesis of 3D faces[C]//Proceedings of the 26th annual conference on Computer graphics and interactive techniques, 1999: 187-194.
- [14] Blanz V, Vetter T. Face recognition based on fitting a 3D morphable model[J]. IEEE Transactions on pattern analysis and machine intelligence, 2003, 25(9): 1063-1074.
- [15] Cashman T J, Fitzgibbon A W. What shape are dolphins? building 3d morphable models from 2d images[J]. IEEE transactions on pattern analysis and machine intelligence, 2013, 35(1): 232-244.
- [16] Vicente S, Carreira J, Agapito L, et al. Reconstructing pascal voc[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014: 41-48.
- [17] Kar A, Tulsiani S, Carreira J, et al. Category-specific object reconstruction from a single image[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1966-1974.
- [18] Pentland A. Shape information from shading: a theory about human perception[J]. Spatial vision, 1989, 4(2): 165-182.
- [19] Robles-Kelly A, Hancock E R. A graph-spectral approach to shape-from-shading[J]. IEEE Transactions on Image Processing, 2004, 13(7): 912-926.

- [20] Aloimonos J. Shape from texture [J]. *Biological cybernetics*, 1988, 58(5): 345 – 360.
- [21] Marinos C, Blake A. Shape from texture: The homogeneity hypothesis [C]//*Proceedings Third International Conference on Computer Vision*, 1990: 350 – 353.
- [22] Choy C B, Xu D, Gwak J, et al. 3d-r2n2: A unified approach for single and multi-view 3d object reconstruction [C]//*European conference on computer vision*, 2016: 628 – 644.
- [23] Fan H, Su H, Guibas L J. A point set generation network for 3d object reconstruction from a single image [C]//*Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017: 605 – 613.
- [24] Lin C-H, Kong C, Lucey S. Learning efficient point cloud generation for dense 3D object reconstruction [C]//*Thirty-Second AAAI Conference on Artificial Intelligence*, 2018.
- [25] Mandikal P, Murthy N, Agarwal M, et al. 3D-LMNet: Latent Embedding Matching for Accurate and Diverse 3D Point Cloud Reconstruction from a Single Image [EB]. *arXiv preprint arXiv:1807.07796*, 2018.
- [26] Kato H, Ushiku Y, Harada T. Neural 3d mesh renderer [C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 3907 – 3916.
- [27] Pontes J K, Kong C, Sridharan S, et al. Image2Mesh: A Learning Framework for Single Image 3D Reconstruction [EB]. *arXiv preprint arXiv:1711.10669*, 2017.
- [28] Wang N, Zhang Y, Li Z, et al. Pixel2Mesh: Generating 3D Mesh Models from Single RGB Images [EB]. *arXiv preprint arXiv:1804.01654*, 2018.
- [29] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions [C]//*Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015: 1 – 9.
- [30] Szegedy C, Ioffe S, Vanhoucke V, et al. Inception-v4, inception-resnet and the impact of residual connections on learning [EB]. *arXiv:1602.07261*, 2016.
- [31] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks [C]//*Advances in neural information processing systems*. 2012:1097 – 1105.
- [32] 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*. 2016:770 – 778.
- [33] Huang G, Liu Z, Van Der Maaten L, et al. Densely connected convolutional networks [C]//*Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017: 4700 – 4708.
- [34] Chang A X, Funkhouser T, Guibas L, et al. Shapenet: An information-rich 3d model repository [EB]. *arXiv preprint arXiv: 1512.03012*, 2015.
- [35] Kingma D P, Ba J. Adam: A method for stochastic optimization [EB]. *arXiv preprint arXiv:1412.6980*, 2014.
- (上接第 183 页)
- [ 6 ] Li H Z, Jin Y H. A CRF Method of Identifying Prepositional Phrases in Chinese Patent Texts [ C ]//*Proceedings of the Eighth SIGHAN Workshop on Chinese Language Processing (SIGHAN-8)*, 2015: 86 – 90.
- [ 7 ] Kokkinakis D, Ighe A, Malm M. Gender-Based Vocation Identification in Swedish 19th Century Prose Fiction using Linguistic Patterns, NER and CRF Learning [ C ]//*Proceedings of NAACL-HLT Fourth Workshop on Computational Linguistics for Literature*, Denver, Colorado, 2015: 89 – 97.
- [ 8 ] Kim Y B, Stratos K, Sarikaya R. Pre-training of Hidden-UnitCRFs [ C ]//*Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Short Papers)*, Beijing, China, 2015: 192 – 198.
- [ 9 ] Lavergne T, Yvon F. Learning the Structure of Variable-Order CRFs: a Finite-State Perspective [ C ]//*Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing*, Copenhagen, Denmark, 2017: 433 – 439.
- [10] Stevenson M, Greenwood M. A semantic approach to IE pattern induction [ C ]//*Proceedings of the 43rd Meeting of the Association for Computational Linguistics*, 2005: 379 – 386.
- [11] Das A, Garain U. CRF-based Named Entity Recognition @ ICON 2013 [ EB ]. *arXiv:1409.8008*, 2014.
- [12] Hacioglu K, Chen Y, Douglas B. Automatic time expression labelling for english and chinese text [ C ]//*Proceedings of the 6th International Conference on Intelligent Text Processing and Computational Linguistics*, 2005: 548 – 559.
- [13] Jochim C, Deleris L. Named Entity Recognition in the Medical Domain with Constrained CRF Models [ C ]//*Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics, Volume 1, Long Papers*, Valencia, Spain, 2017: 839 – 849.
- [14] Caselli T, Morante R. VUACLTL at SemEval 2016 Task12: A CRF Pipeline to Clinical TempEval [ C ]//*Proceedings of SemEval-2016*, San Diego, California, 2016: 1241 – 1247.
- [15] Li H Z, Jin Y H. Identifying Prepositional Phrases in Chinese Patent Texts with Rule-based and CRF Methods [ C ]//*Proceedings of the 29th Pacific Asia Conference on Language, Information and Computation*, Shanghai, China, 2015: 143 – 149.
- [16] Hansart C, De Meyere D, Watrin P, et al. CENTAL at SemEval-2016 Task12: A linguistically fed CRF model for medical and temporal information extraction [ C ]//*Proceedings of SemEval-2016*, San Diego, California, 2016: 1286 – 1291.
- [17] Cai J, Jiang Y, Tu K W. CRF Autoencoder for Unsupervised Dependency Parsing [ C ]//*Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing*, 2017: 1638 – 1643.