

基于空间结构化推理深度融合网络的 RGB-D 场景解析

王泽宇¹, 吴艳霞¹, 张国印¹, 布树辉²

(1. 哈尔滨工程大学计算机科学与技术学院, 黑龙江哈尔滨 150001;

2. 西北工业大学航空学院, 陕西西安 710072)

摘要: 为了弥补 RGB-D 场景解析中卷积神经网络空间结构化学习能力的不足, 本文基于深度学习提出空间结构化推理深度融合网络, 内嵌的结构化推理层有机地结合条件随机场和空间结构化推理模型, 该层能够较为全面而准确地学习物体所处三维空间的物体分布以及物体间的三维空间位置关系. 在此基础上, 网络的特征融合层巧妙地利用深度置信网络和改进的条件随机场, 该层可以根据融合生成的物体综合语义信息和物体间语义相关性信息完成深度结构化学习. 实验结果表明, 在标准 RGB-D 数据集 NYUDv2 和 SUNRGBD 上, 空间结构化推理深度融合网络分别实现最优的平均准确率 53.8% 和 54.6%, 从而有助于实现机器人任务规划、车辆自动驾驶等智能计算机视觉任务.

关键词: RGB-D 场景解析; 深度学习; 卷积神经网络; 条件随机场; 空间结构化推理模型; 深度置信网络; 计算机视觉; 机器人任务规划; 车辆自动驾驶

中图分类号: TP391.413; TP18 **文献标识码:** A **文章编号:** 0372-2112 (2018)05-1253-06

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2018.05.035

RGB-D Scene Parsing Based on Spatial Structured Inference Deep Fusion Networks

WANG Ze-yu¹, WU Yan-xia¹, ZHANG Guo-yin¹, BU Shu-hui²

(1. College of Computer Science and Technology, Harbin Engineering University, Harbin, Heilongjiang 150001, China;

2. School of Aeronautics, Northwestern Polytechnical University, Xi'an, Shaanxi 710072, China)

Abstract: In order to make up the drawbacks that convolutional neural networks lack the ability of spatial structured learning in RGB-D scene parsing, we propose spatial structured inference deep fusion networks (SSIDFNs) on the basis of deep learning, the embedded structural inference layer organically combines conditional random fields (CRFs) and spatial structured inference model, which is able to learn the three-dimensional spatial distributions of objects and three-dimensional spatial relationships among objects in a more comprehensive and accurate way. Furthermore, the feature fusion layer takes both advantages of deep belief networks and improved CRFs, which is able to achieve deep structured learning according to the comprehensive semantic information of objects and semantic correlation information among objects. The experimental results demonstrate that the proposed SSIDFNs achieve the best mean accuracy 53.8% and 54.6% on the standard RGB-D datasets NYUDv2 and SUNRGBD respectively, which will be helpful to implement intelligent computer vision tasks, such as robot task planning and self-driving cars.

Key words: RGB-D scene parsing; deep learning; convolutional neural networks; conditional random fields; spatial structured inference model; deep belief networks; computer vision; robot task planning; self-driving cars

1 引言

场景解析的任务是在场景图像中逐像素地自动标

注类别^[1], 准确的场景解析有助于实现机器人任务规划^[2]、车辆自动驾驶^[3]等智能计算机视觉任务. 场景解析需要解决如下 2 个问题: (1) 如何有效地提取图像

收稿日期: 2017-05-19; 修回日期: 2018-01-10; 责任编辑: 覃怀银

基金项目: 国家重点研发计划 (No. 2016YFB1000400); 哈尔滨市杰出青年人才基金 (No. 2017RAYXJ016); 中央高校自由探索基金 (No. HEUCF170605); 国家自然科学基金 (No. 61573284)

中物体的视觉特征;(2)如何准确地学习物体的空间关系特征. 近些年,全卷积神经网络(Fully Convolutional Neural Networks, FCNNs)通过逐层的卷积和反卷积操作解析场景^[1,4],但是 FCNNs 较小的感知域使得提取的视觉特征缺少空间结构化信息. 为此,条件随机场^[5](Conditional Random Fields, CRFs)被用来根据相邻物体之间特征的相似度调优 FCNNs 分类概率^[6-8],但是 CRFs 不能显式地推理空间结构化信息. 为了进一步提升 FCNNs 准确率,长短期记忆网络(Long Short Term Memory, LSTM)通过逐像素地遍历图像特征显式地学习物体间空间依赖关系^[9,10],但是 LSTM 未能有效地

学习 RGB-D 图像信息描绘三维空间内物体间的结构化特性. 为了解决上述问题,本文提出空间结构化推理深度融合网络(Spatial Structured Inference Deep Fusion Networks, SSIDFNs),SSIDFNs 能够较为全面而准确地学习物体所处三维空间的物体分布和物体间的三维空间位置关系,从而调优分类结果和避免分类错误.

2 空间结构化推理深度融合网络

SSIDFNs 由特征学习层,结构化推理层和特征融合层组成,如图 1 所示.

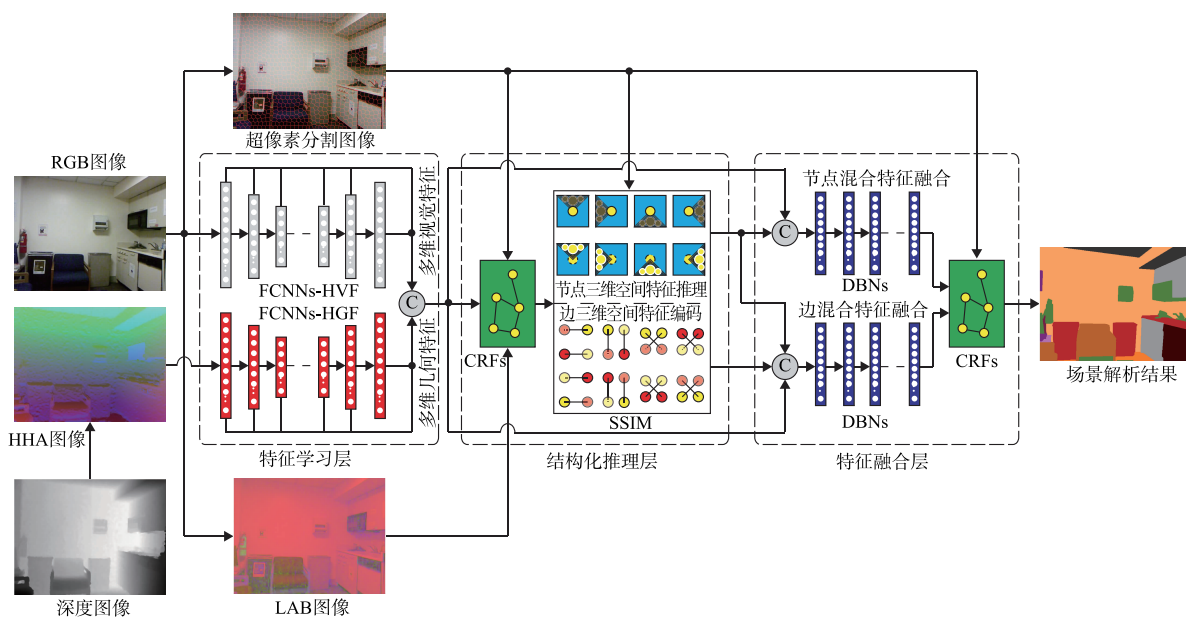


图1 空间结构化推理深度融合网络

2.1 特征学习层

特征学习层由两路并行的 FCNNs 组成,分别用来学习 RGB 图像的多维视觉特征(Hierarchical Visual Features, HVF)和 HHA 图像^[1]的多维几何特征(Hierarchical Geometric Features, HGF).

假设 FCNNs 由 L_c 个卷积层和 L_d 个反卷积层组成,则级联上采样的卷积和反卷积特征^[1,6]生成的 HVF 和 HGF 可以分别表示为 F^{HVF} 和 F^{HGF} :

$$F^Q = \begin{cases} I, & l=0 \\ \text{pool}(\text{relu}(\text{conv}(F_{l-1}^Q))), & 1 \leq l \leq L_c \\ \text{deconv}(F_{l-1}^Q), & L_c < l \leq L_c + L_d \end{cases} \quad (1)$$

$$F^{HVF} = [\text{up}(F_1^{HVF}), \dots, \text{up}(F_{L_c}^{HVF}), \dots, \text{up}(F_{L_c+L_d}^{HVF})] \in \mathbf{R}^{N \times H \times W},$$

$$F^{HGF} = [\text{up}(F_1^{HGF}), \dots, \text{up}(F_{L_c}^{HGF}), \dots, \text{up}(F_{L_c+L_d}^{HGF})] \in \mathbf{R}^{N \times H \times W} \quad (2)$$

式(1)和(2)中: I 表示 RGB 或者 HHA 图像, F_l^Q 表示第

l 层的特征, Q 表示特征类型,conv、relu 和 pool 分别表示卷积、校正和池化操作,deconv 表示反卷积操作, N 、 H 和 W 分别表示特征的维数、高度和宽度,up 表示上采样操作^[1,6].

假设 I 中像素 p 的坐标为 (m, n) ,经超像素分割^[11],则 I 中超像素 S 的 HVF 和 HGF 可以分别表示为 f_S^{HVF} 和 f_S^{HGF} :

$$f_S^{HVF} = \left\| \sum_{p \in S} F^{HVF}(m, n) / N_S \right\|_2 \in \mathbf{R}^N, \quad (3)$$

$$f_S^{HGF} = \left\| \sum_{p \in S} F^{HGF}(m, n) / N_S \right\|_2 \in \mathbf{R}^N$$

式(3)中: N_S 表示超像素 S 内像素 p 的个数.

2.2 结构化推理层

在结构化推理层,如图 2(a)所示. 首先,CRFs 依据相邻超像素对 LAB 颜色特征的相似度调优分类结果^[5,8];然后,空间结构化推理模型(Spatial Structured Inference Model, SSIM)一方面通过 CRFs 分类概率推理节点三维空间特征^[8](Node Three-Dimensional Spatial

Features, 3D-NSF), 另一方面根据相邻超像素对 3D 质心^[5]的相对位置关系编码边三维空间特征 (Edge

Three-Dimensional Spatial Features, 3D-ESF).

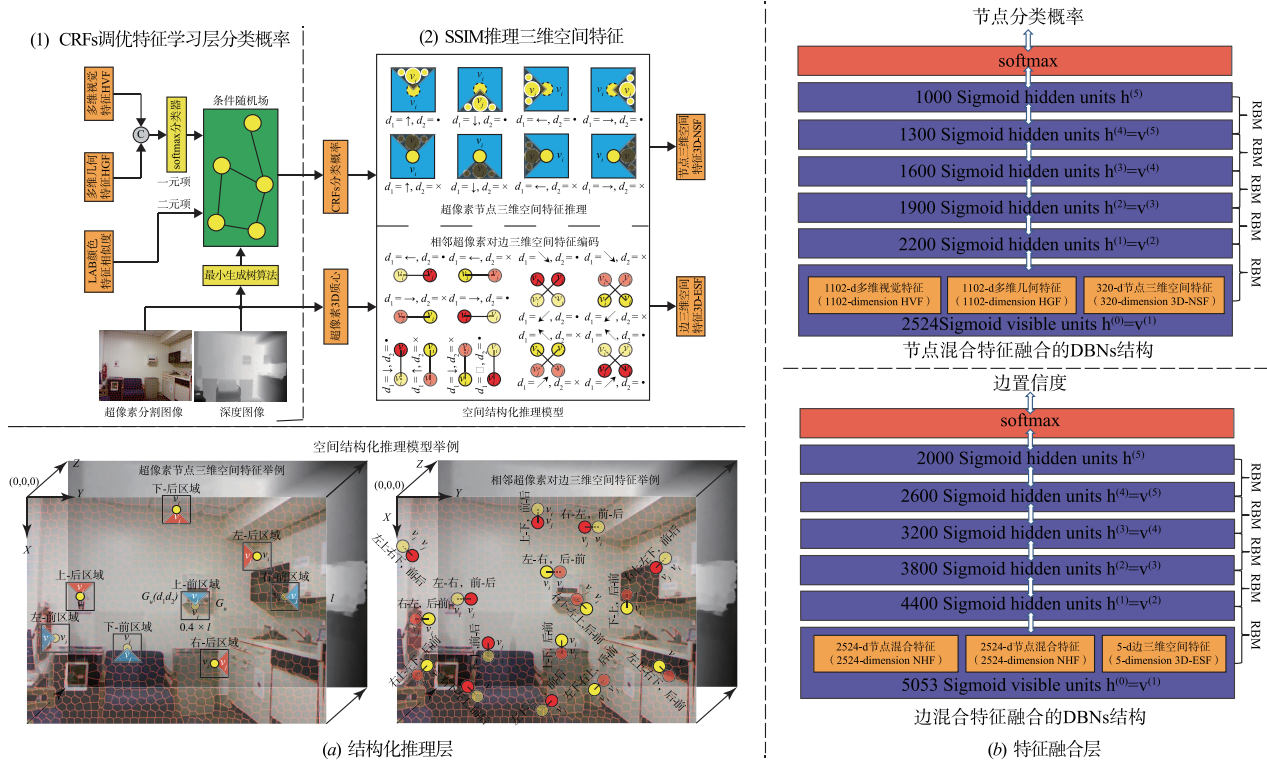


图2 结构化推理层和特征融合层

2.2.1 空间结构化推理模型

(1) 节点三维空间特征

假设超像素 v_i , 所处三维空间为 G_u , 则 v_i 的 3D-NSF 可以定义为 $f_{S_i}^{3D-NSF}$:

$$f_{S_i}^{3D-NSF}(d_1, d_2) = \sum_{v_j \in G_u(d_1, d_2)} \theta_j \times \exp(-\alpha_d \frac{d(v_i, v_j)}{\sigma_d}) \in \mathbf{R}^C, \quad (4)$$

式中: $d_1 \in [\uparrow, \downarrow, \leftarrow, \rightarrow], d_2 \in [\cdot, \times]$

$$f_{S_i}^{3D-NSF} = [f_{S_i}^{3D-NSF}(\uparrow, \cdot), f_{S_i}^{3D-NSF}(\uparrow, \times), f_{S_i}^{3D-NSF}(\downarrow, \cdot), f_{S_i}^{3D-NSF}(\downarrow, \times), f_{S_i}^{3D-NSF}(\leftarrow, \cdot), f_{S_i}^{3D-NSF}(\leftarrow, \times), f_{S_i}^{3D-NSF}(\rightarrow, \cdot), f_{S_i}^{3D-NSF}(\rightarrow, \times)] \in \mathbf{R}^{8 \times C} \quad (5)$$

式(4)和(5)中: $G_u(d_1, d_2)$ 表示 v_i 在水平 d_1 (坐标轴 X 和 Y) 和深度 d_2 (坐标轴 Z) 方向上的三维空间, $\uparrow, \downarrow, \leftarrow$ 和 \rightarrow 分别表示上、下、左和右, \cdot 和 \times 分别表示前和后, θ_j 表示 v_j 的 CRFs 分类概率, $d(v_i, v_j)$ 表示 v_j 到 v_i 的距离, σ_d 表示 $G_u(d_1, d_2)$ 内 v_j 到 v_i 距离的最大值, α_d 表示距离衰减率, C 表示类别数^[6,8].

(2) 边三维空间特征

假设相邻超像素对 v_i 和 v_j , 其边为 E_{ij} , 则 E_{ij} 的 3D-

ESF 可以定义为 $f_{E_{ij}}^{3D-ESF}$:

$$f_{E_{ij}}^{3D-ESF} = [f_{E_{ij}}^{3D-ESF}(d_1), f_{E_{ij}}^{3D-ESF}(d_2)] \quad (6)$$

式中: $d_1 \in [\uparrow, \downarrow, \leftarrow, \rightarrow, \nearrow, \searrow, \swarrow, \nwarrow], d_2 \in [\cdot, \times]$ 式(6)中: d_1 表示 v_i 和 v_j 在水平方向上 (坐标轴 X 和 Y) 的空间位置关系, $f_{E_{ij}}^{3D-ESF}(\uparrow), f_{E_{ij}}^{3D-ESF}(\downarrow), f_{E_{ij}}^{3D-ESF}(\leftarrow), f_{E_{ij}}^{3D-ESF}(\rightarrow), f_{E_{ij}}^{3D-ESF}(\nearrow), f_{E_{ij}}^{3D-ESF}(\searrow), f_{E_{ij}}^{3D-ESF}(\swarrow), f_{E_{ij}}^{3D-ESF}(\nwarrow)$ 分别表示上-下、下-上、左-右、右-左、左上-右下、右下-左上、右上-左下、左下-右上 8 类水平位置关系对应的 3D-ESF, 可以编码为 '000'、'001'、'010'、'011'、'100'、'101'、'110' 和 '111', d_2 表示 v_i 和 v_j 在深度方向上 (坐标轴 Z) 的空间位置关系, $f_{E_{ij}}^{3D-ESF}(\cdot), f_{E_{ij}}^{3D-ESF}(\times)$ 分别表示前-后、后-前 2 类深度位置关系对应的 3D-ESF, 可以编码为 '01' 和 '10'.

2.3 特征融合层

特征融合层巧妙地利用了深度置信网络^[12] (Deep Belief Networks, DBNs) 和改进的 CRFs, 首先, 两路并行的 DBNs 分别对节点混合特征 (Node Hybrid Features, NHF) 和边混合特征 (Edge Hybrid Features, EHF) 做融合, 如图 2(b) 所示; 然后, 改进的 CRFs 根据融合生成的超像素综合语义信息和相邻超像素对语义相关性信息

完成深度结构化学习。

假设超像素 v_i , 相邻超像素对 v_i 和 v_j 的边 E_{ij} , 则 v_i 的 NHF 和 E_{ij} 的 EHF 可以分别定义为 $f_{S_i}^{\text{NHF}}$ 和 $f_{E_{ij}}^{\text{EHF}}$:

$$\begin{aligned} f_{S_i}^{\text{NHF}} &= [f_{S_i}^{\text{HVF}}, f_{S_i}^{\text{HGF}}, f_{S_i}^{\text{D-NSF}}] \in \mathbf{R}^{2 \times N + 8 \times C}, \\ f_{E_{ij}}^{\text{EHF}} &= [f_{S_i}^{\text{NHF}}, f_{S_j}^{\text{NHF}}, f_{E_{ij}}^{\text{D-ESF}}] \in \mathbf{R}^{2 \times [2 \times N + 8 \times C] + 5} \end{aligned} \quad (7)$$

NHF 和 EHF 的多模态特征融合过程可以分别表示为:

$$\begin{aligned} \lambda_i &= \text{fusion}(f_{S_i}^{\text{NHF}}) \in \mathbf{R}^C, \\ \eta_{ij} &= \text{fusion}(f_{E_{ij}}^{\text{EHF}}) \in \mathbf{R}^{C \times C} \end{aligned} \quad (8)$$

式(8)中: fusion 表示 DBNs 的融合操作, λ_i 表示 v_i 的节点分类概率, η_{ij} 表示 E_{ij} 的边置信度。

为了完成深度结构化学习, 本文以节点分类概率和边置信度定义 CRFs 的一元势能函数 U 和二元势能函数 P , U 和 P 可以分别定义为:

$$\begin{aligned} U(l_i, \mathbf{I}_i) &= \exp(-\alpha_u \lambda_i), \\ P(l_i, l_j, \mathbf{I}_{ij}) &= \exp(-\alpha_p \eta_{ij}) \end{aligned} \quad (9)$$

式(9)中: \mathbf{I} 表示超像素分割^[11]的 RGB 图像, l 表示图像的标签. 改进的 CRFs 全局最优化分类概率过程^[5]如下:

$$\begin{aligned} \min_{\mathbf{w}} \left\{ \frac{\beta}{2} \|\mathbf{w}\|_2^2 + \sum_{n=1}^{I_n} \left[\sum_{i \in V} \mathbf{w}_U^T U(l_i^{(n)}, \mathbf{I}_i^{(n)}) + \sum_{(i,j) \in E} \mathbf{w}_P^T P(l_i^{(n)}, l_j^{(n)}, \mathbf{I}_{ij}^{(n)}) + \log Z(\mathbf{I}^{(n)}; \mathbf{w}) \right] \right\} \end{aligned} \quad (10)$$

式(10)中: β 表示权重衰减参数, I_n 表示训练图像数量, V 表示超像素集合, E 表示相邻超像素对集合, Z 表示归一化因子, \mathbf{w} 表示 CRFs 网络参数。

3 实验与分析

3.1 实验数据集和性能评价标准

本文在标准 RGB-D 场景解析数据集 NYUDv2^[13] 和 SUNRGBD^[14] 上对 SSIDFNs 进行实验, 并使用像素准确率 (Pixel Acc)、平均准确率 (Mean Acc) 和平均交叉准确率 (Mean IoU)^[1] 评价 SSIDFNs 的性能。

3.2 实验环境和参数设置

SSIDFNs 在一台 2.3 GHz Intel Xeon Gold 6140 CPU

(18 Cores)、12 GB NVIDIA GeForce GTX TITAN X GPU 以及 128 GB 内存的计算机上进行训练和测试。

在训练阶段, 本文对 SSIDFNs 各层分离训练. 在特征学习层, 首先, 本文通过网络参数模型 VGG-16 初始化两路 FCN-8s, 并通过随机梯度下降算法调优 FCN-8s 的网络参数^[1], 其训练参数为: batch_size = 100、learning_rate = 10^{-4} 、momentum = 0.99、weight_decay = 5^{-4} 和 epoch = 500; 然后, 分别级联两路 FCN-8s 内 conv2_2、conv3_3、conv4_3 和 deconv_3 层的上采样特征生成 HVF 和 HGF; 最后, 在超像素尺寸为 15 的条件下利用 SLIC 算法分割图像^[11], 并计算超像素的 HVF 和 HGF. 在结构化推理层, 首先, 使用无向图模型工具包^[15] 初始化 CRFs 的一元项为多维特征分类概率, 二元项为 LAB 颜色特征相似度, 并通过循环置信传播算法和 L-BFGS 优化算法训练 CRFs 网络参数^[5,8]; 然后, 在距离衰减率为 0.5 的条件下, SSIM 分别推理超像素的 3D-NSF 和编码相邻超像素对的 3D-ESF. 在特征融合层, 首先, 使用深度学习工具包^[16] 初始化两路 DBNs 的结构 (隐藏层数和各层节点数) 以及网络的初始参数, 并采用贪心算法和对比散度算法训练 DBNs 的参数^[12], 其训练参数为: batch_size = 100、learning_rate = 0.1、momentum = 0.8 和 epoch = 15000; 然后, 再次初始化 CRFs 的一元项为节点分类概率 (超像素综合语义信息), 二元项为边置信度 (相邻超像素对语义相关性信息), 网络初始参数为结构化推理层的训练所得, 并进一步调优 CRFs^[5].

在测试阶段, 将测试图像依次输入 SSIDFNs, 并在 SSIDFNs 参数的指导下依次输出场景解析结果。

3.3 实验结果

3.3.1 NYUDv2 数据集

在表 1 中, ‘FCNNs’ 表示特征学习层的场景解析准确率, ‘FCNNs + CRFs’ 表示 CRFs 联合特征学习层的准确率, ‘SSIDFNs’ 表示所提结构化推理深度融合网络的准确率. 从实验结果中可以发现: 第一, 无论 NYUDv2 数据集包含深度图像与否, 场景解析的准确率随着各层网络逐层集成到 SSIDFNs 而逐渐提升; 第二, 无论 SSIDFNs 处于何种配置, 基于 RGB-D 图像训练得到的场景解析准确率均优于基于 RGB 图像的结果。

表 1 NYUDv2 数据集上 SSIDFNs 自身对比实验结果 (%)

RGB 图像				RGB-D 图像			
Methods	Pixel Acc	Mean Acc	Mean IoU	Methods	Pixel Acc	Mean Acc	Mean IoU
FCNNs	62.8	44.3	31.7	FCNNs	66.4	47.1	35.6
FCNNs + CRFs	64.3	45.2	33.4	FCNNs + CRFs	68.5	48.2	36.9
SSIDFNs	71.5	50.4	39.3	SSIDFNs	76.4	53.8	43.7

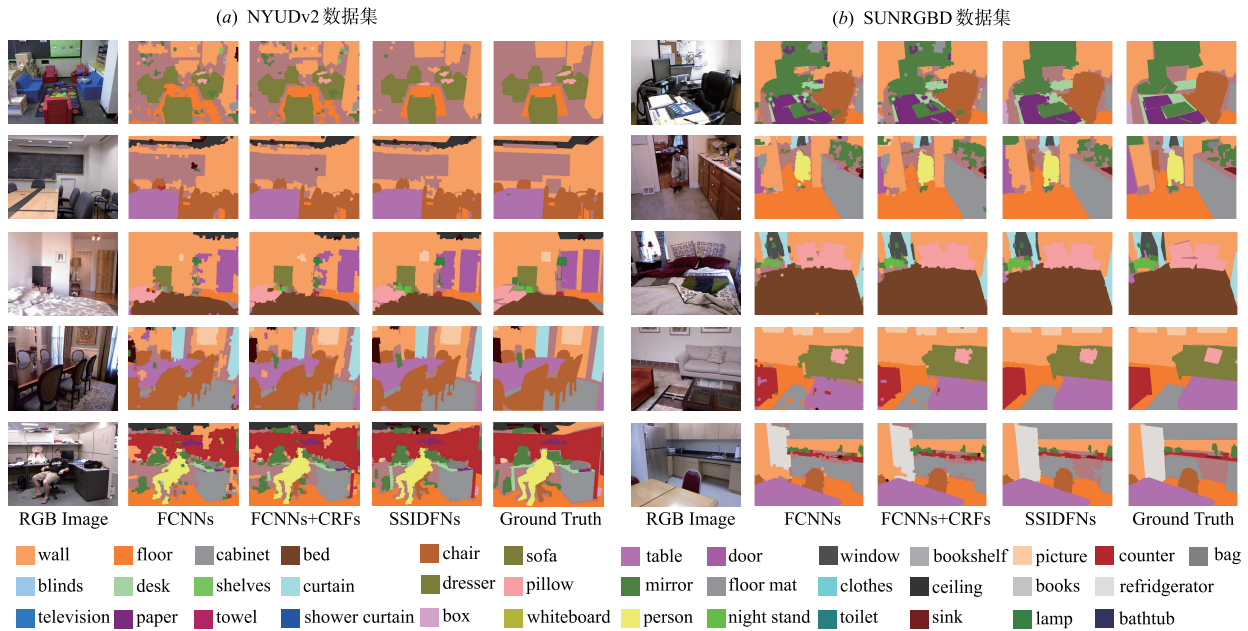


图3 NYUDv2和SUNRGBD数据集 (RGB-D图像) 上场景解析视觉效果

在表 2 中, SSIDFNs 的平均准确率达到 53.8%, 较现有先进方法^[7,8,10]取得最优的结果. 从图 3(a) 中可以发现 SSIDFNs 能够较为准确地解析室内场景. SSIDFNs 的训练时间大约为 36h, 平均测试时间大约为 3s, 说明 SSIDFNs 满足实时性的需求.

表 2 NYUDv2 数据集 (RGB-D 图像) 上 SSIDFNs 与当前先进方法对比实验结果 (%)

Methods	Mean Acc
文献[7]	43.9
文献[10]	49.4
文献[8]	51.8
SSIDFNs	53.8

3.3.2 SUNRGBD 数据集

SUNRGBD 数据集的视觉效果如图 3 (b) 所示, SSIDFNs 解析的场景与 Ground Truth 的轮廓外观更为接近. 在表 3 中, SSIDFNs 取得最优的平均准确率 54.6%.

表 3 SUNRGBD 数据集 (RGB-D 图像) 上 SSIDFNs 与当前先进方法对比实验结果 (%)

Methods	Mean Acc
文献[4]	45.9
文献[10]	48.1
文献[8]	52.3
SSIDFNs	54.6

3.4 实验结果分析

综上所述, SSIDFNs 取得的成功可以归纳为如下 5

点: (1) FCNNs 生成的多维特征可以包含丰富的视觉信息; (2) 级联 HGF 与 HVF 能够加强物体的视觉外观; (3) SSIM 可以较为全面而准确地学习物体所处三维空间的物体分布和相邻物体间的三维空间位置关系; (4) DNBs 能够挖掘多模态特征间复杂的非线性关系; (5) CRFs 可以根据融合生成的物体综合语义信息和物体间语义相关性信息完成深度结构化学习.

4 结论

本文提出的 SSIDFNs 具有较强的三维空间结构化学习能力. 实验结果表明, SSIDFNs 可以准确而快速地解析 RGB-D 场景. 但是, 分离训练的 SSIDFNs 可能出现特征信息的损失, 因此本文准备研究集成上述 3 层网络的端到端架构.

参考文献

- [1] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation [A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. Piscataway, NJ: IEEE Service Center, 2015. 3431 - 3440.
- [2] Bojarski M, Del Testa D, Dworakowski D, et al. End to end learning for self-driving cars [J]. Computer Science, 2016, arXiv preprint arXiv:1604.07316.
- [3] Sharma S, Kiros R, Salakhutdinov R. Action recognition using visual attention [J]. Computer Science, 2015, arXiv preprint arXiv:1511.04119.
- [4] Kendall A, Badrinarayanan V, Cipolla R. Bayesian segnet;

- Model uncertainty in deep convolutional encoder-decoder architectures for scene understanding [J]. Computer Science, 2015, arXiv preprint arXiv:1511.02680.
- [5] Cadena C, Košecká J. Semantic segmentation with heterogeneous sensor coverages [A]. Robotics and Automation [C]. Piscataway, NJ: IEEE Service Center, 2014. 2639 – 2645.
- [6] Bu S, Han P, Liu Z, et al. Scene parsing using inference embedded deep networks [J]. Pattern Recognition, 2016, 59 (11): 188 – 198.
- [7] Khan S H, Bennamoun M, Sohel F, et al. Integrating geometrical context for semantic labeling of indoor scenes using RGB-D images [J]. International Journal of Computer Vision, 2016, 117(1): 1 – 20.
- [8] Wang Z, Wu Y, Zhang G, et al. Three-dimensional spatial structured encoding deep network for RGB-D scene parsing [J]. Journal of Computer Applications, 2017, 37 (12): 3458 – 3466.
- [9] Liang X, Shen X, Feng J, et al. Semantic object parsing with graph lstm [A]. European Conference on Computer Vision [C]. Berlin: Springer International Publishing, 2016. 125 – 143.
- [10] Li Z, Gan Y, Liang X, et al. LSTM-CF: Unifying context modeling and fusion with LSTMs for RGB-D scene labeling [A]. European Conference on Computer Vision [C]. Berlin: Springer International Publishing, 2016. 541 – 557.
- [11] Achanta R, Shaji A, Smith K, et al. SLIC superpixels compared to state-of-the-art superpixel methods [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(11): 2274 – 2282.
- [12] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks [J]. Science, 2006, 313 (5786): 504 – 507.
- [13] Silberman N, Hoiem D, Kohli P, et al. Indoor segmentation and support inference from RGB-D images [A]. European Conference on Computer Vision [C]. Berlin: Springer International Publishing, 2012. 746 – 760.
- [14] Song S, Lichtenberg S P, Xiao J. Sun RGB-D: A RGB-D scene understanding benchmark suite [A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. Piscataway, NJ: IEEE Service Center, 2015. 567 – 576.
- [15] Schmidt M. UGM: A Matlab Toolbox for Probabilistic Undirected Graphical Models [EB/OL]. <http://www.cs.ubc.ca/~schmidtm/Software/UGM.html>, 2017.
- [16] Perceptron M. DeepLearning 0.1 Documentation [EB/OL]. <http://deeplearning.net/tutorial/>, 2014 – 11 – 06.

作者简介



王泽宇 男, 1989年3月出生于河南省郑州市, 哈尔滨工程大学计算机科学与技术学院博士研究生, 主要研究方向为机器学习、计算机视觉。

E-mail: wangzeyu2011@hrbeu.edu.cn



吴艳霞(通信作者) 女, 1979年9月出生于黑龙江省哈尔滨市, 哈尔滨工程大学计算机科学与技术学院副教授, 博士生导师, 主要研究方向为机器学习、计算机视觉。

E-mail: wuyanxia@hrbeu.edu.cn



张国印 男, 1962年9月出生于黑龙江省齐齐哈尔市, 哈尔滨工程大学计算机科学与技术学院教授, 博士生导师, 主要研究方向为机器学习、计算机视觉。

E-mail: zhangguoyin@hrbeu.edu.cn



布树辉 男, 1978年11月出生于河南省洛阳市, 西北工业大学航空学院教授, 博士生导师, 主要研究方向为机器学习、计算机视觉。

E-mail: bushuhui@nwpu.edu.cn