

基于特征级联卷积网络的双目立体匹配

吴俊劼¹, 陈震¹, 张聪炫^{1,2}, 江少锋¹, 尚璇¹

(1. 南昌航空大学无损检测技术教育部重点实验室, 江西南昌 330063; 2. 中国科学院自动化研究所, 北京 100190)

摘要: 针对图像序列病态区域匹配歧义性以及稠密视差图连通性的问题, 本文提出一种基于特征级联卷积神经网络的双目立体匹配计算方法. 构造特征重用的全卷积密集块, 利用“跳连接”机制将浅层提取的特征图级联到后续子层, 对深层卷积丢失的局部特征信息进行补偿. 引入指示函数划分一定大小的训练集, 将其批量输入特征级联卷积网络模型进行前向传播, 同时通过小批量梯度下降 (Mini-Batch Gradient Descent, MBGD) 策略更新初始权重和偏置参数. 根据负连接神经元对网络模型的输出进行初始匹配代价计算, 并利用交叉交叉域代价聚合 (Cross Based Cost Aggregation, CBCA) 和半全局立体匹配 (Semi-Global Matching, SGM) 等算法对代价函数进行优化, 求得精准稠密的视差图. 分别采用 Middlebury 数据库提供的训练和测试立体图像集对本文方法和深度学习方法 MC-CNN、CBMV、MC-CNN-WS 等具有代表性方法进行对比测试. 实验结果表明, 本文方法具有较高的视差计算精度和鲁棒性, 尤其对复杂场景、光照变化以及弱纹理等困难场景图像序列能有效提高匹配率和保持图像细节.

关键词: 图像序列; 稠密视差图; 双目立体匹配; 卷积神经网络; 全卷积密集块; 匹配代价; 前向传播
中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2021)04-0690-06
电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.12263/DZXB.20190135

Binocular Stereo Matching Based on Feature Cascade Convolutional Network

WU Jun-jie¹, CHEN Zhen¹, ZHANG Cong-xuan^{1,2}, JIANG Shao-feng¹, SHANG Xuan¹

(1. Key Laboratory of Nondestructive Testing, Ministry of Education, Nanchang Hangkong University, Nanchang, Jiangxi 330063, China;
2. Institute of Automation, Chinese Academy of Sciences, Beijing 100190, China)

Abstract: In order to overcome the ambiguity of ill-posed regions matching while enhancing the connectivity of dense disparity map, this paper proposes a binocular stereo matching method based on feature cascade convolutional neural network. We constructed a fully convolutional densely block with feature reuse to utilize the “skip-connection” mechanism to transmit the feature maps extracted from the previous layers to all subsequent layers, and compensated the local feature information of deep convolution losing. At the forward propagation stage, we designed an indicator function to divide a certain size of the training set as the input of the feature cascade convolutional network model, and applied the Mini-Batch Gradient Descent (MBGD) strategy to update the initial weight and bias parameters. We computed the initial matching cost according to the output of the presented network model, and used the Cross Based Cost Aggregation (CBCA) and Semi-Global Matching (SGM) pipeline to optimize the cost function for generating the accurate and dense disparity map. We used the published training and test sets of Middlebury database to evaluate our approach and other representative stereo matching methods, such as MC-CNN, CBMV and MC-CNN-WS. The experimental results prove that the proposed method has higher accuracy and better robustness of disparity estimation, and especially improves the matching rate and preserves image details in the regions of complex scene, illumination change and weakly textured.

Key words: image sequence; dense disparity map; binocular stereo matching; convolutional neural network; fully convolutional densely block; matching cost; forward propagation

收稿日期: 2019-01-23; 修回日期: 2019-08-29; 责任编辑: 王天慧

基金项目: 国家自然科学基金 (No. 61866026, No. 61772255, No. 61866025); 江西省优势科技创新团队计划 (No. 20152BCB24004, No. 20165BCB19007); 江西省科技创新杰出青年人才计划 (No. 20192BCB23011); 航空科学基金 (No. 2018ZC56008); 江西省青年科学基金项目 (No. 20202ACB214007); 中国博士后科学基金 (No. 2019M650894); 江西省研究生创新专项资金 (No. YC2018-S368)

1 引言

立体匹配技术是图像处理与计算机视觉领域的一项重要研究课题,旨在通过计算同一空间点在两个或多个视图中的视差,从而恢复其深度信息,重构场景的三维空间几何.研究成果已广泛应用于航空航天、机器视觉系统、医疗诊断等领域,例如航天摄影测量^[1]、医疗器械外观缺陷检测与识别^[2]等.

根据特征学习策略的不同,立体匹配技术研究可大致分为两个方面.一方面是基于传统人工特征的方法^[3],通过手工设计具体的图像特征进行学习,进而提高特定场景图像序列下的视差计算精度,但该方法往往依赖于设计者的先验知识,存在较大的局限性.另一方面,随着卷积神经网络的提出,基于深度学习的方法逐渐成为计算深度信息的重要手段^[4].通过构建多层非线性映射的深度卷积神经网络从大样本中自适应学习大量的图像特征,以提高视差计算的精度.针对双目图像中弱纹理区域的匹配准确性问题,Zbontar 等人^[5]首次提出基于块相似性比较的网络模型,该模型通过比较图像块间的相似度寻找对应的像素点,能较好地保持图像边缘.针对复杂场景下的深度不连续性问题,Park 等人^[6]采用逐像素金字塔池化策略以扩大感受野,能够有效提高深度不连续区域的匹配精度.

现阶段,虽然基于深度学习的方法已获得较高的视差估计精度,但当图像序列中存在复杂场景、光照变化以及弱纹理等困难场景时,视差结果中通常包含较多的误匹配点.针对以上问题,本文提出一种基于特征级联卷积网络的双目立体匹配方法,能够提高复杂场景、光照变化以及弱纹理等困难场景下视差估计精度和鲁棒性.

2 全卷积密集块

假设标准卷积神经网络(Convolutional Neural Networks, CNN)模型中第 l 层的输出 \mathbf{x}_l 通过密集连接机制^[7],以前馈方式迭代地级联所有前层的特征图,则输出结果 \mathbf{x}_l 可定义如下:

$$\mathbf{x}_l = H_l[\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_{l-1}] \quad (1)$$

式(1)中, H_l 表示四次连续操作,依次是批归一化(Batch Normalization, BN)、线性整流函数(Rectified Linear Unit, ReLU)、卷积(Convolution, Conv)、随机丢失率为 θ 的丢弃层 Dropout, $\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_{l-1}$ 表示第 $0, 1, \dots, l-1$ 层生成的特征图.本文采用该密集连接方式构建立体匹配模型,可以有效降低网络模型的空间复杂度,并增强图像纹理细节信息.

同时,为更好地控制特征图尺寸同时抑制误差敏感度的削弱,以确保一定维度大小的特征张量传递到

后续隐藏层,本文在标准密集块的尾部引入过渡层,构建全卷积密集块,即选择性地丢失空间池化层,依次执行三次连续操作: $3 \times 3 \text{Conv}$ 、ReLU 激活以及 $3 \times 3 \text{Conv}$.

3 基于特征级联卷积网络的立体匹配

3.1 初始匹配代价模型

针对传统代价函数计算过度依赖单一灰度信息易在图像像素灰度变化细微甚至不变化的弱纹理区域产生错误匹配问题,本文采用图像块相似比较策略计算初始匹配代价.

如图 1 所示,为更合理地构造足够大的训练样本集进行网络参数学习,以增强网络性能的表现能力,本文首先引入指示函数划分各图像块,则块尺寸 φ 定义如下:

$$\varphi = \sum_{i \in M} 1 \{l_i = \text{Conv}_{\text{valid}}\} \cdot (ks - 1) + 1 \quad (2)$$

式(2)中, M 表示网络模型的总层数, ks 表示第 l_i 卷积层的卷积核尺寸, $1 \{ \cdot \}$ 表示指示函数.当第 l_i 层为不进行零填充的卷积 $\text{Conv}_{\text{valid}}$ 时,对其卷积核 ks 进行式(2)操作;反之,跳过该层并指向下一层直至遍历整个网络结构.因此根据本文构建的网络模型,输入样本集均是尺寸为 11×11 ,通道数为 3 的图像块.

然后,本文采用前向和反向传播策略对网络权重和偏置参数进行迭代更新,具体描述见算法 1 和算法 2.

算法 1 前向传播

1.1 批量输入 128 对左、右图像块集,其中左图像块为参考图像块,右图像块为待匹配图像块;

1.2 串联三个 3×3 小卷积核的 $\text{Conv}_{\text{valid}}$ 初始化 7×7 感受野 Receptive Field,并且每个 $\text{Conv}_{\text{valid}}$ 随后紧跟一个 ReLU,对图像块进行角点、边缘等信息的提取,得到维度大小为 $256 \times 5 \times 5 \times 88$ 的初始特征图;

1.3 利用全卷积密集块中的密集连接层 BN + ReLU + Conv + Dropout 进行特征重用,以增强高频信息,并采用过渡层对特征图进行有效缩放,得到维度大小为 $256 \times 1 \times 1 \times 124$ 的特征张量;

1.4 通过重塑操作对特征张量进行联结,不改变具体数值仅调整维度,得到维度大小为 128×248 的特征向量;

1.5 堆叠多个全连接层(Fully Connected, FC)和 ReLU,对特征向量进行分类和重组,得到维度大小为 384×1 的特征列向量;

1.6 通过激活函数 Sigmoid 对特征列向量进行非线性变化,预测得到最终的相似数 S .

最后,本文利用负连接神经元对网络预测的相似数 s 进行初始匹配代价 $C(\mathbf{p}, d)$ 转化:

$$C(\mathbf{p}, d) = w' \cdot s \quad (3)$$

式(3)中, $\mathbf{p} = (x, y)^T$ 表示图像像素, d 表示所有可能的视差值, w' 表示权值,本文设置为 -1 . 当输入为一对完整的左、右立体图像时,通过训练得到的具体网络模型 R ,即可得到本文方法计算的参考图像初始匹配代价结果.

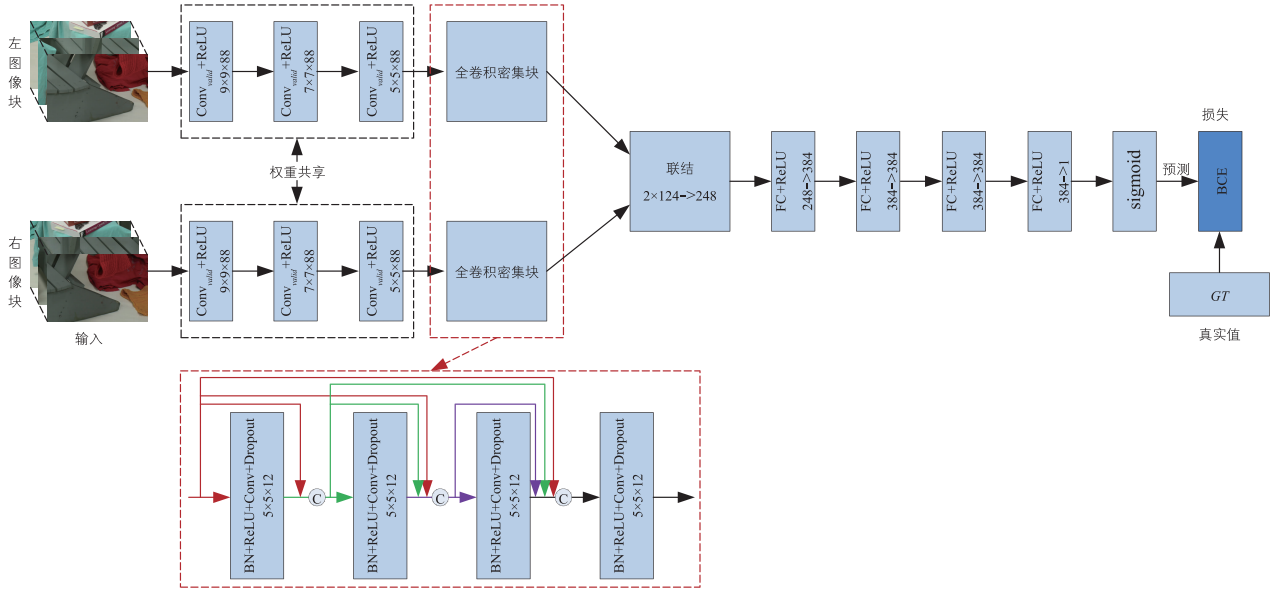


图1 特征级联卷积神经网络模型示意图

算法2 反向传播

2.1 利用二元交叉熵 (Binary Cross Entropy, BCE) 损失函数值, 对网络模型性能进行衡量, 具体公式如下:

$$L(w, b) = -\frac{1}{n} \sum_{j=1}^n [GT \cdot \log(P(x_j)) + (1 - GT) \cdot \log(1 - P(x_j))] \quad (4)$$

式(4)中, w 和 b 分别表示网络模型的权重和偏置参数, GT 表示真实值, P 表示期望值, $\mathbf{x} = [x_1, x_2, \dots, x_j]^T$ 表示训练样本, $j=1, 2, \dots, t$ 表示批尺寸, 本文设置 t 为 128. 当一个批量样本前馈结束, 通过式(4)即可求得一个用于描述真实值与预测值之间偏差的损失值.

2.2 采用小批量梯度下降 MBGD 策略, 对式(4)进行链式求导, 以更新网络的初始权重和偏置参数, 获得最终的神经网络模型 R .

3.2 立体优化模型

为进一步消除初始匹配代价结果中可能包含的噪点, 本文首先利用 CBCA 算法^[8] 对图像深度不连续区域的相邻像素进行合并, 并通过 SGM 算法^[9] 对 2D 视差图进行强制平滑约束, 得到最终代价:

$$\begin{cases} C_{CBCA}^{i'}(\mathbf{p}, d) = \frac{1}{\|U_d(\mathbf{p})\|} \sum_{\mathbf{q} \in U_d(\mathbf{p})} C_{CBCA}^{i'-1}(\mathbf{q}, d), \\ C_{CBCA}^0(\mathbf{p}, d) = C(\mathbf{p}, d) \\ C'(\mathbf{p}, d) = \sum_r (C_{CBCA}^4(\mathbf{p}, d) + \min_k \{C'(\mathbf{p} - \mathbf{r}, k) + p\}) \\ \text{s. t. } k \in \{d-1, d, d+1, \text{other}\} \end{cases} \quad (5)$$

式(5)中, $U_d(\mathbf{p})$ 表示支持窗口, i' 表示迭代次数, \mathbf{r} 表示方向矢量, $\mathbf{p} - \mathbf{r}$ 表示左相邻像素, p 表示惩罚系数.

根据式(5)求得的代价结果 $C'(\mathbf{p}, d)$, 利用赢者通吃 (Winner Takes All, WTA) 策略寻找到图像像素代价

最小时的视差值:

$$d' = \arg \min_d C'(\mathbf{p}, d) \quad (6)$$

式(6)中, d' 表示本文方法计算得到的视差值.

3.3 计算步骤

Step1 输入左、右立体图像对, 其中左图像为参考图像, 右图像为待匹配图像;

Step2 根据网络模型 R , 对输入样本进行预测, 进而求得匹配代价 $C(\mathbf{p}, d)$;

Step3 通过式(5)对初始代价进行优化, 得到最终代价 $C'(\mathbf{p}, d)$;

Step4 利用 WTA 策略遍历整个视差空间寻找到参考图像中像素点 \mathbf{p} 的最优视差值 d' .

经过以上具体步骤, 即可得到本文方法计算的精准稠密视差图.

4 实验与分析

4.1 评估指标

本文采用误差比例 (Percentage of Disparity Error, PODE) 和平均误差 (Average Error, Avgerr) 对视差结果进行量化评估. 其中, PODE 表示视差误差大于设定阈值的图像像素点占整幅图像中所有像素点的比例; Avgerr 表示整幅图像中所有像素点视差误差的平均值:

$$\text{PODE} = \frac{1}{N} \sum_{(x,y)} (|d_e(x,y) - d_r(x,y)| > \delta) \quad (7)$$

$$\text{Avgerr} = \frac{1}{N} \sum_{(x,y)} |d_e(x,y) - d_r(x,y)| \quad (8)$$

式(7)和(8)中, $d_r(x,y)$ 表示视差真实值, $d_e(x,y)$ 表示视差估计值, N 表示整幅图像中像素点数, δ 表示误差阈值, 本文设置 δ 为 2.0.

4.2 参数设置

本文以 Middlebury 数据库^[10]的训练集为例,进一步将整个训练集的 80% 划分为用于网络学习的训练样本,剩余的 20% 作为验证样本. 本文设定动量为 0.9, 迭代次数为 14, 初始学习率为 0.003, 当第 12 次迭代结束时将其学习率削减为 0.0003, 进而讨论网络模型中密集连接层数设置对本文方法视差估计性能表现的影响. 从图 2 可以看出, 随着密集连接层数的增加, 本文方法视差误差呈现先减小后增加的趋势, 当层数为 3 时误差最低, 因此本文设置密集连接层数为 3.




图2 密集连接层数对视差估计的影响

4.3 对比方法

本文分别选取 MC-CNN^[5]、MC-CNN-WS^[11]、CBMV^[12]、JMR^[13] 和 MeshStereo^[14] 进行综合对比分析. 其中 MC-CNN 是基于数据驱动的深度学习方法, 能够较好地保持图像边缘信息; MC-CNN-WS 是一种弱监督的深度度量学习方法, 有效改善图像序列视差结果的噪点; CBMV 利用随机森林分类器合并多个匹配代价函数和双向置信度特征消除视差结果中的异常值; JMR 是基于 CNN 与条件随机场 (Conditional Random Field, CRF) 相结合的立体匹配模型, 视差计算过程中使用

CRF 模型融合相关卷和边缘权重以提高视差估计精度; MeshStereo 算法采用的是基于三角网格约束的全局匹配模型, 通过在视差细化过程中利用 3D 三角剖分对视差图进行插值, 优化匹配结果.

4.4 Middlebury 训练集实验

本文首先采用 Middlebury 数据库提供的含有真实视差值的训练集图像序列验证本文方法在困难场景下视差估计的准确性和鲁棒性. 图 3 分别展示了 Middlebury 训练集图像序列的参考图像、视差真实值以及各对比方法的视差结果. 其中, Adirondack 存在弱纹理区域, Piano 包含较为剧烈的光照变化现象, Pipes 为复杂场景, Teddy 属于遮挡类型.

从图 3 中可以看出, MC-CNN-WS 算法整体视差效果相比其他对比方法较差; MeshStereo 算法在不同场景图像物体边缘区域视差估计均存在一定的信息丢失; MC-CNN 算法能较好地保护边缘, 但视差估计中包含大量的噪点; CBMV 算法视差估计边界更接近真实值, 但存在明显的过度平滑现象; JMR 算法整体视差估计效果较好, 能够较准确地估计图像物体轮廓, 但在弱纹理和遮挡区域存在一定误差; 本文方法针对弱纹理、光照变化和遮挡场景图像序列视差估计效果均优于其他方法, 并在复杂场景视差效果仅次于 JMR 算法, 但其细节保护方面优于 JMR.

为定量分析本文方法的视差估计性能, 表 1 分别展示了各对比方法针对以上四种场景图像序列的视差误差与时间消耗统计结果. 从表 1 中可以看出, 本文方法在 Adirondack、Piano 和 Teddy 序列各项客观指标均是最低, 说明本文方法针对弱纹理、光照变化以及遮挡场景视差估计具有较好的精度, 仅在 Pipes 序列的 Avgerr 指标略高于 JMR, 但其视差图的细节表现效果较好. 在时间消耗方面, 本文方法由于代价计算过程中密集连接层多次重用特征进行图像高频信息的补偿, 导致时间消耗略大.

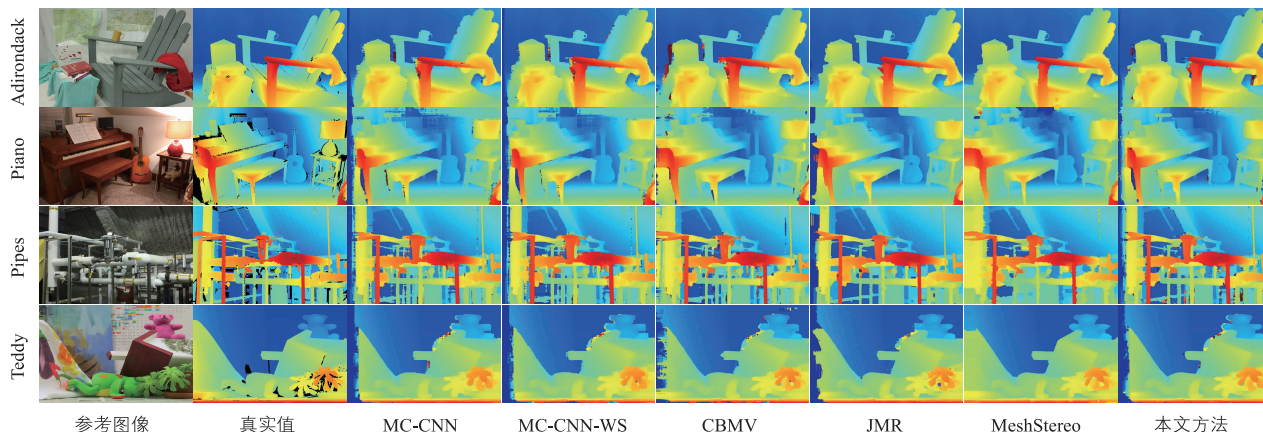


图3 Middlebury训练集图像序列视差估计结果

表 1 Middlebury 训练集图像序列视差估计误差与时间消耗对比(时间单位:s)

对比方法	平均时耗	Adirondack	Piano	Pipes	Teddy
		Bad2. 0/Avgerr	Bad2. 0/Avgerr	Bad2. 0/Avgerr	Bad2. 0/Avgerr
MC-CNN	1.26	5.15/1.21	16.6/3.17	6.2/3.2	3.91/1.12
MC-CNN-WS	2.41	7.29/1.66	18.9/3.21	9.23/4.27	6.36/2
CBMV	1360	6.06/1.09	15.1/2.26	5.65/2.45	4.48/1.84
JMR	4.28	5.34/0.92	14.2/2.21	5.44/2.12	5.12/1.15
MeshStereo	62	7.14/1.55	15.4/2.71	12.8/6.03	6.08/1.05
本文方法	56.7	3.32/0.77	12.4/1.84	4.22/2.27	3.57/0.92

4.5 Middlebury 测试集实验

为了进一步验证本文方法在不可见数据下视差估计的泛化性能,本实验选取未知真实值的 Middlebury 测试集中的 Bicycle2、Livingroom、Plants 和 Computer 序列为例,它们分别对应包含弱纹理、光照变化、复杂场景以及遮挡等困难场景,图 4 分别展示了 Middlebury 测试集图像序列的参考图像和各对比方法的视差估计结果。

从图 4 中可以看出,MC-CNN-WS 算法对不同场景细节保护效果较差;MeshStereo 算法在不同场景下均存在不同程度的拉伸现象;MC-CNN 算法具有较多的图像噪点;CBMV 算法由于受到中值滤波的影响,视差估计结果中存在较严重的过度平滑问题;JMR 算法受限于 CNN 对不可见数据的拟合能力,视差效果并不佳;本文

方法整体视差效果较好,尤其在在不同场景下均具有较好的细节保持效果,说明本文方法针对弱纹理、光照变化、复杂场景以及遮挡等困难场景图像序列具有较高的视差估计精度和鲁棒性。

为了量化比较不同方法的视差结果,表 2 分别列出了本文方法与各对比方法的视差误差和时耗统计。从表 2 中可以看出,本文方法在 Bicycle2、Livingroom、Plants 和 Computer 序列各客观评价指标均是最低,说明本文方法具有较好的视差估计精度和鲁棒性。在时间消耗方面,本文方法在测试集序列的运行时间相比测试集序列增加,由于测试集图像序列尺寸的增大,在遍历整个视差空间搜索最优视差的时间消耗增加,进而增加了运行时耗。

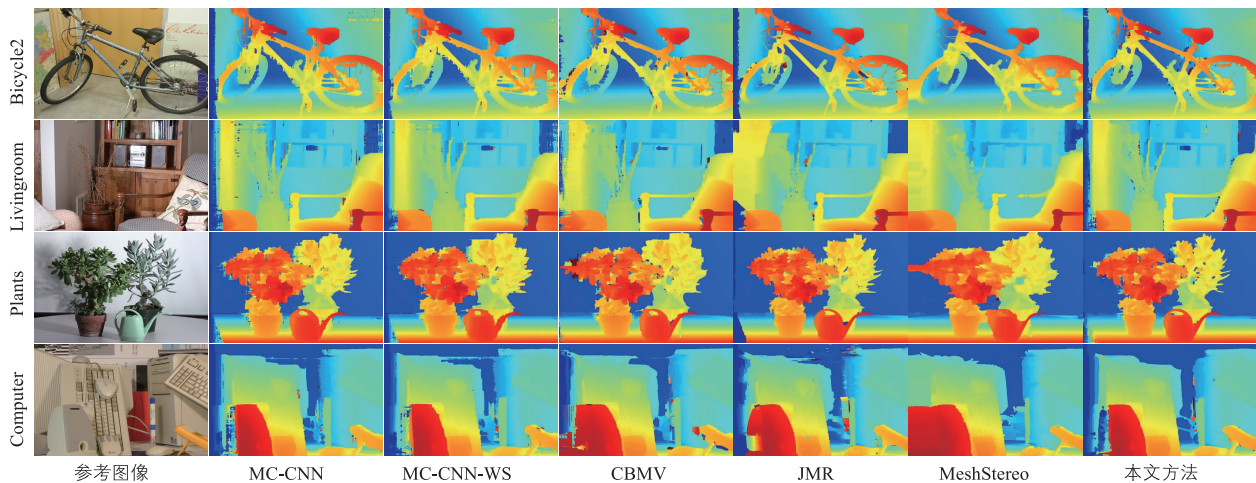


图 4 测试集图像序列视差估计结果

表 2 Middlebury 测试集图像序列视差估计误差与时间消耗对比(时间单位:s)

对比方法	平均时耗	Bicycle2	Livingroom	Plants	Computer
		Bad2. 0/Avgerr	Bad2. 0/Avgerr	Bad2. 0/Avgerr	Bad2. 0/Avgerr
MC-CNN	1.69	7.18/2.6	15.4/4.56	7.9/5.34	8.47/2.42
MC-CNN-WS	3.19	11.1/4.99	16.3/4.79	12.1/7.62	11.8/3.54
CBMV	1001	8.09/2.87	17.5/3.57	10.1/6.96	9.31/2.88
JMR	4.46	8.44/2.42	18/3.99	7.29/3.91	13.8/3.42
MeshStereo	65.3	10.8/4.2	17.7/4.38	15.4/8.3	11/2.26
本文方法	81.2	5.83/1.7	13.2/3.57	6.3/3.13	5.78/1.64

5 结论

本文提出了一种基于特征级联卷积网络的立体匹配估计模型. 首先构造特征级联卷积网络模型计算出初始匹配代价, 然后利用立体优化约束策略对其进行迭代计算, 最后得到本文方法的视差估计结果. 通过采用 Middlebury 数据库提供的已知真实值的训练集和未知真实值的测试集图像序列进行综合性实验对比分析, 实验结果表明了本文方法具有较好的视差估计精度和鲁棒性, 尤其针对弱纹理、复杂场景以及光照变化等困难场景具有较好的图像细节保护效果.

参考文献

- [1] 马宁, 门宇博, 门朝光, 等. 基于扩展相位相关的小基高比立体匹配方法[J]. 电子学报, 2017, 45(8): 1827 - 1835.
MA Ning, MEN Yu-bo, MEN Chao-guang, et al. A small baseline stereo matching method based on extended phase correlation[J]. Acta Electronica Sinica, 2017, 45(8): 1827 - 1835. (in Chinese)
- [2] Fakhry A, Zeng T, Ji S. Residual deconvolutional networks for brain electron microscopy image segmentation [J]. IEEE Transactions on Medical Imaging, 2016, 36(2): 447 - 456.
- [3] 肖进胜, 田红, 邹文涛, 等. 基于斜平面平滑优化的半全局立体匹配[J]. 电子学报, 2018, 46(8): 1835 - 1841.
XIAO Jin-sheng, TIAN Hong, ZOU Wen-tao, et al. Semi-global matching algorithm based on improved slanted plane smoothing[J]. Acta Electronica Sinica, 2018, 46(8): 1835 - 1841. (in Chinese)
- [4] Haeusler R, Nair R, Kondermann D. Ensemble learning for confidence measures in stereo vision[A]. IEEE Conference on Computer Vision and Pattern Recognition [C]. Portland; IEEE, 2013. 305 - 312.
- [5] Zbontar J, LeCun Y. Stereo matching by training a convolutional neural network to compare image patches[J]. Journal of Machine Learning Research, 2016, 17(1): 2287 - 2318.
- [6] Park H, Lee K M. Look wider to match image patches with convolutional neural networks[J]. IEEE Signal Processing Letters, 2016, 24(12): 1788 - 1792.
- [7] Huang G, Liu Z, Van Der Maaten L, et al. Densely connected convolutional networks[A]. IEEE Conference on Computer Vision and Pattern Recognition [C]. Honolulu, USA; IEEE, 2017. 4700 - 4708.
- [8] Zhang K, Lu J, Lafruit G. Cross-based local stereo matching using orthogonal integral images[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2009, 19(7): 1073 - 1079.
- [9] Hirschmuller H. Stereo processing by semiglobal matching and mutual information [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 30(2): 328 - 341.
- [10] Scharstein D, Hirschmuller H, Kitajima Y, et al. High-resolution stereo datasets with subpixel-accurate ground truth [A]. German Conference on Pattern Recognition [C]. Cham, Swit; Springer, 2014. 31 - 42.
- [11] Tulyakov S, Ivanov A, Fleuret F. Weakly supervised learning of deep metrics for stereo reconstruction [A]. International Conference on Computer Vision [C]. Venice, Italy; IEEE, 2017. 1339 - 1348.
- [12] Batsos K, Cai C, Mordohai P. CbmV: A coalesced bidirectional matching volume for disparity estimation [A]. IEEE Conference on Computer Vision and Pattern Recognition [C]. Salt Lake City, USA; IEEE, 2018. 2060 - 2069.
- [13] Knobelreiter P, Reinbacher C, Shekhovtsov A, et al. End-to-end training of hybrid CNN-CRF models for stereo [A]. IEEE Conference on Computer Vision and Pattern Recognition [C]. Honolulu, USA; IEEE, 2017. 2339 - 2348.
- [14] Zhang C, Li Z, Cheng Y, et al. Meshstereo: A global stereo model with mesh alignment regularization for view interpolation [A]. IEEE International Conference on Computer Vision [C]. Santiago, Chile; IEEE, 2015. 2057 - 2065.

作者简介



吴俊劼 男, 1995年8月出生于江苏南京. 现为南昌航空大学信息工程学院硕士研究生. 主要研究方向为图像检测与智能识别.
E-mail: junjiuwu1023@163.com



陈震 男, 1969年11月生于江西九江. 分别于1993、2000和2003年在西北工业大学获得学士、硕士和博士学位. 现为南昌航空大学教授, 博士生导师. 主要研究方向为计算机视觉、图像处理与模式识别.
E-mail: dr_chenzhen@163.com



张聪炫 (通讯作者) 男, 1984年7月出生, 于河南焦作. 分别于2007和2014年在南昌航空大学和南京航空航天大学获得学士和博士学位. 现为南昌航空大学副教授, 硕士生导师, 中国科学院自动化研究所博士后. 主要研究方向为图像检测与智能识别.
E-mail: zcxdsq@163.com