

加权 SIFT 流深度迁移的单幅图像 2D 转 3D

袁红星, 吴少群, 朱仁祥, 安 鹏

(宁波工程学院电子与信息工程学院, 浙江宁波 315016)

摘 要: 2D 视频转 3D 视频是解决 3D 片源不足的主要手段, 而单幅图像的深度估计是其中的关键步骤. 提出基于加权 SIFT 流深度迁移和能量模型优化的单幅图像深度提取方法. 首先利用图像的全局描述符从深度图数据库中检索出近邻图像; 其次通过 SIFT 流建立输入图像和近邻图像之间像素级稠密对应关系; 再次由 SIFT 流误差计算迁移权重, 将近邻图像对应像素点的深度乘以权重后迁移到输入图像上; 然后利用均值滤波对迁移后的近邻图像深度进行融合; 最后建立深度图优化能量模型, 在尽量接近迁移后近邻图像深度的前提下, 平滑梯度较小区域的深度. 实验结果表明, 该方法降低了估计深度图的平均相对误差, 增强了深度图的均匀性.

关键词: 2D 转 3D; 尺度不变特征变换流; 深度估计; 深度图优化; 能量模型

中图分类号: TN911. 73 **文献标识码:** A **文章编号:** 0372-2112 (2015)02-0242-06

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

DOI: 10.3969/j.issn.0372-2112.2015.02.006

Single Image 2D-to-3D Conversion via Weighted SIFT Flow

YUAN Hong-xing, WU Shao-qun, ZHU Ren-xiang, AN Peng

(School of Electronic and Information Engineering, Ningbo University of Technology, Ningbo, Zhejiang 315016, China)

Abstract: 2D-to-3D conversion is one of the important ways to alleviate the lack of 3D content, in which the key technique is depth estimation from a single image. A depth extraction method based on weighted SIFT flow depth transferring and energy model optimization is proposed. First, k -nearest neighbor images were retrieved by evaluating the global image descriptors between the target image and the images from the RGBD database. Then, pixels of the target image and pixels of its neighbors in the database were matched using SIFT flow, which also generated matching errors used to determine the transferring weights of the neighbors. Next, depth maps of neighboring images were transferred to the target image according to the pixel matching and the transferring weights. The final depth map was obtained by depth refinement based on an energy model. Experimental results show that our scheme can significantly reduce the average relative error and improve the uniformity of the depth map.

Key words: 2D-to-3D conversion; scale invariant feature transform flow; depth estimation; depth map refinement; energy model

1 引言

随着 3D 电影的大力推广, 3D 视频成为当前多媒体领域的研究热点. 虽然 3D 显示技术已获得突破性进展, 但制作一批具有较高品质和符合 3D 展示媒介需求的 3D 内容依然面临着诸多挑战. 3D 内容不足已成为制约 3D 视频产业发展的瓶颈^[1]. 2D 转 3D 技术通过各种深度线索从原始 2D 视频图像中提取场景的深度信息, 进而通过基于深度图的绘制技术 (Depth Map Based Rendering, DIBR) 合成各种格式的 3D 视频. 2D 转 3D 是解决当前 3D 片源不足的最有效手段之一, 其核心是单幅图像的深度估计. 然而, 图像包含的线索和深度间的关系

不是绝对的, 因而从线索恢复深度的方法容易发生误判的情况. 针对该问题, Saxena 等^[2]利用先验知识来训练模型, 得到各类景物特征与深度间的对应关系; 然后利用该模型来综合估计每个像素的深度信息. 该方法虽然可以得到较为准确的深度信息, 但更新场景时, 需要重新采集相应的深度数据进行训练. 为此, 文献^[3]假设相似的场景具有相似的深度, 提出基于尺度不变特征变换 (Scale Invariant Feature Transform, SIFT) 流的深度迁移方法, 直接由 SIFT 流建立相似场景间像素级对应关系, 然后将训练图像的深度迁移到输入图像上. 但是该方法没有考虑同一对象深度的均匀性^[4].

2 相关研究

全自动 2D 转 3D 方法试图通过图像包含的各种线索进行深度估计. Zhang 等^[5]对常用的深度线索进行了总结,主要包括模糊度、明暗度、相对高度和透视几何等.散焦图像的模糊度与摄像机内部参数以及景深间存在固定的映射关系^[6],因而可用模糊度估计景物的深度.史国凯等^[7]提出一种基于分割的单幅散焦图像深度估计方法. Zhuo 等^[8]利用散焦图像再模糊的梯度与模糊前梯度的幅值比例估计边缘处深度,并通过抠图拉普拉斯矩阵进行插值得到稠密的深度.这类线索假设图像模糊由散焦引起,但运动、大气散射和噪声等都会引起图像的模糊,因而它们只适用于低景深图像.

若物体表面满足朗伯表面的假设条件,则其表面灰度随着表面法向变化,因而物体表面的明暗度变化可作为深度估计线索.马吉权等^[9]通过表面形态分布检测镜面高光的方法改善了含镜面高光图像的表面恢复精度.王学梅等^[10]利用高阶局部 Lax-Friedrichs 提高了算法精度.这类线索的缺陷是需要准确估计光源的位置.深度图大多存在着自下至上递增的趋势,因而可利用相对高度推断景物深度. Jung 等^[11]利用边缘检测生成“等深线分布图”,并根据相对高度从分布图底部向上按递增的趋势对图像进行深度分配.这类方法的问题是需要一个预定义的深度模型为景物分配深度.

根据透视几何成像原理,图像沿着灭点(vanishing point)方向的深度逐渐增加. Battiato 等^[12]根据灭点方向生成初始估计深度,并通过场景分割改进深度估计的质量. Cheng 等^[13]进一步利用梯度方向和深度渐变性的关系改善估计深度的质量.这类线索仅适用于包含足够多规则几何外观的场景.上述线索仅适用于特定场景.因而,人们提出基于机器学习的深度估计方法. Saxena 等^[2]提出的 Make3D 方法推动了机器学习在 2D 转 3D 方面的应用. Liu 等^[14]通过语义分割提高了 Make3D 算法的精度.李乐等^[15]通过识别景物间的构图关系来估计深度. Make3D 的缺陷是模型训练的计算复杂耗时,更换新场景后,需重新进行学习训练.为此,文献^[3]假设相似的场景具有相似的深度,提出数据驱动的无参数深度估计方法.本文在此基础上,通过加权 SIFT 流深度迁移和基于能量模型的深度优化,进一步改善深度估计的质量,使之满足 2D 转 3D 对深度均匀性的要求^[4].

3 算法框架

本文算法流程如图 1 所示,主要分为 K 近邻(K -nearest neighbor, KNN)检索、加权 SIFT 流深度迁移、深度图融合和基于能量模型的深度图优化四个部分.

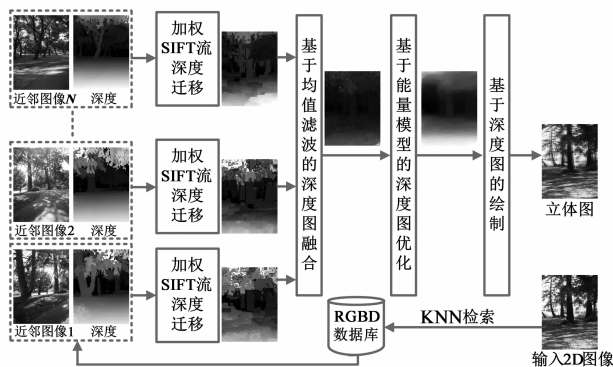


图1 本文算法框架

3.1 KNN 检索

本文采用全局 GIST 描述符^[16]作为图像间相似性的度量指标,通过比较 GIST 描述符从 RGBD 数据库中检索出输入图像的 KNN 图像及对应的深度图.假设 Q 为输入图像, C 为候选近邻图像, $G(\cdot)$ 为 GIST 描述符.用式(1)计算输入图像 Q 与近邻图像 C 的匹配误差,式中 $\|\cdot\|$ 表示欧氏距离.依次计算 Q 与 RGBD 数据库中每个图像的匹配误差;然后,将匹配误差从小到大进行排序;最后,从中选取 K 个最小匹配误差对应的图像作为 Q 的 KNN,其对应的深度作为 Q 的候选估计深度.

$$E_{\text{GIST}}(Q, C) = \|G(Q) - G(C)\| \quad (1)$$

3.2 加权 SIFT 流深度迁移

利用 SIFT 流可建立图像对之间的像素级稠密匹配关系^[17].进而根据该关系,可将匹配图像的深度信息迁移到目标图像的成像平面上,作为其估计的深度图.与文献^[3]不同的是,本文根据 SIFT 流误差计算迁移权重,不是将近邻图像对应位置的深度直接迁移到输入图像上,而是将深度乘以权重再进行迁移.这样做的原因是,各近邻图像对深度迁移的贡献不同,对其进行加权后再进行融合,可抑制因匹配误差造成的深度迁移误差. SIFT 流^[17]通过提取图像每个像素点的 SIFT 描述符,计算两幅图像间稠密匹配关系.假设像素点表示为 $p(m, n)$,其中 m 和 n 分别表示行号和列号; $S_Q(p)$ 为 Q 在位置 p 处的 SIFT 特征矢量;从输入图像 Q 到近邻图像 C 的 SIFT 流表示为 $F = (u, v)$,其中 u 和 v 分别表示水平和垂直方向上的流分量.则 SIFT 流的具体计算步骤如下:

步骤 1 SIFT 描述符提取.对图像上每个像素点 p ,提取 SIFT 局部描述符,得到 128 维的特征向量.

步骤 2 按照 SIFT 描述符的相似程度对 Q 和 C 的像素点进行匹配.通过最小化式(2)得到从 Q 到 C 的 SIFT 流.式(2)右侧由数据项、小位移项和空间平滑项构成,在保证 SIFT 描述符匹配的同时,对匹配点的范围进行约束并使空间相邻的像素点流场趋于一致.式(2)

中 ε 表示 4 邻域. 与文献[17]一样, 采用双平面序列置信度传播算法求解式(2).

$$E(F) = \sum_p \|S_Q(p) - S_C(p + F(p))\| + \eta \sum_p (|u(p)| + |v(p)|) + \alpha \sum_{(p,q) \in \varepsilon} (|u(p) - u(q)| + |v(p) - v(q)|) \quad (2)$$

用 SIFT 描述符匹配程度作为迁移权重, 以区分各近邻图像对深度迁移的贡献度. 第 k 个近邻图像 C_k 到输入图像 Q 的迁移权重计算方法如式(3)所示, 其中 K 表示总的近邻数目.

$$W_{C_k}(p) = e^{-\|S_Q(p) - S_{C_k}(p + F(p))\|} \quad (3)$$

SIFT 流建立了近邻图像和输入图像间稠密像素级对应关系. 深度迁移是指将近邻图像对应像素点处的深度变换到输入图像上. 本文根据式(4)将近邻图像 C 对应的深度图 Z_C 迁移到输入图像上, 作为候选的估计深度图. 式中 $\hat{Z}_Q(p)$ 为输入图像 Q 在像素点 p 处的估计深度值, $Z_C(p + F(p))$ 表示近邻图像 C 在像素点 $p + F(p)$ 处的深度值, W_C 为根据式(3)计算的迁移权重.

$$\hat{Z}_Q(p) = W_C(p) \times Z_C(p + F(p)) \quad (4)$$

3.3 基于均值滤波的深度图融合

深度图融合是指将输入图像的 KNN 迁移深度图进行整合, 作为输入图像的初始估计深度. 本文采用均值滤波融合方法, 具体计算如式(5)所示. 式中 \hat{Z}_{Q_k} 表示输入图像 Q 第 k 个近邻图像 C_k 的深度根据式(4)迁移后的结果; p 是像素点的位置; K 为总的近邻图像数目, 实验中设为 7; 式中分母的作用是对权重因子进行归一化.

$$\hat{Z}_Q(p) = \frac{1}{\sum_{k=1}^K e^{-\|S_Q(p) - S_{C_k}(p + F(p))\|}} \sum_{k=1}^K \hat{Z}_{Q_k}(p) \quad (5)$$

3.4 基于能量模型的深度图优化

假设图像的宽度和高度分别为 w 和 h , $N = w \times h$, 将优化后的深度图 Z 表示成 N 维的列矢量 z , 即 $z(m \times w + n) = Z(m, n)$. 建立如式(6)所示的深度图优化能量模型, 包括数据代价 E_D 和平滑代价 E_S .

$$E(z) = \sum_{i=1}^N E_D(z_i) + \beta E_S(z) \quad (6)$$

数据代价用于度量优化后深度与 KNN 图像迁移深度图的差异, 定义如式(7)所示, 其中 $z \in R^N$, $\delta_i \in R^N$, $\varphi(\cdot) = \sqrt{\cdot}$. δ_i 只有第 i 个元素为 1, 其余元素均为 0. z_{C_k} 为第 k 个近邻图像的深度图 Z_{C_k} 对应的列矢量, f_k 表示从 Q 到 C_k 的 SIFT 流 F_k 对应的列矢量, w_k 为 C_k 到 Q 的迁移权重 W_{C_k} 对应的列矢量. ∇_x 和 ∇_y 分别表示水

平和垂直方向上的梯度算子. $G_x \in R^{N \times N}$ 和 $G_y \in R^{N \times N}$ 分别表示水平和垂直方向梯度算子构成的矩阵.

$$E_D(z_i) = \sum_{k=1}^K w_k(i) \{ \varphi((\delta_i^T z - z_{C_k}(i + f_k(i)))^2) + \gamma [\varphi((\delta_i^T G_x z - \nabla_x z_{C_k}(i + f_k(i)))^2) + \varphi((\delta_i^T G_y z - \nabla_y z_{C_k}(i + f_k(i)))^2)] \} \quad (7)$$

平滑代价使深度图在梯度较小的区域趋于一致, 定义如式(8)所示, 其中 s_i^x 和 s_i^y 分别表示深度图在水平、垂直方向上梯度调制的 Sigmoidal 函数, 即 $s_i^x = (1 + e^{10|\nabla_x z_i|})^{-1}$, $s_i^y = (1 + e^{10|\nabla_y z_i|})^{-1}$.

$$E_S(z_i) = s_i^x \varphi((\delta_i^T G_x z)^2) + s_i^y \varphi((\delta_i^T G_y z)^2) \quad (8)$$

为得到式(6)的解, 将它对 z 求导并令其为 0, 结果如式(9)所示. 其中, 为减小代价函数的求解难度, 用上一次迭代的深度图计算 s_i^x 和 s_i^y , 即它们和当前迭代的深度变量无关, 因而在求导中被视为常数.

$$\begin{aligned} & \sum_{i=1}^N \sum_{k=1}^K w_k(i) \{ \varphi((\delta_i^T z - z_{C_k}(i + f_k(i)))^2) \\ & \quad \cdot (\delta_i^T z - z_{C_k}(i + f_k(i))) \delta_i \\ & \quad + \gamma [\varphi((\delta_i^T G_x z - \nabla_x z_{C_k}(i + f_k(i)))^2) \\ & \quad \cdot (\delta_i^T G_x z - \nabla_x z_{C_k}(i + f_k(i))) \delta_i \\ & \quad + \varphi((\delta_i^T G_y z - \nabla_y z_{C_k}(i + f_k(i)))^2) \\ & \quad \cdot (\delta_i^T G_y z - \nabla_y z_{C_k}(i + f_k(i))) \delta_i] \} \\ & \quad + \beta \sum_{i=1}^N \{ s_i^x \varphi'((\delta_i^T G_x z)^2) \delta_i^T G_x z G_x^T \delta_i \\ & \quad + s_i^y \varphi'((\delta_i^T G_y z)^2) \delta_i^T G_y z G_y^T \delta_i \} = 0 \end{aligned} \quad (9)$$

根据文献[18], 对于式(9), 可采用迭代变权重最小二乘法 (Iterative Reweighted Least Square, IRLS) 予以求解, 具体步骤如下所示:

步骤 1 根据上次迭代得到的深度图计算权重:

$$\begin{aligned} \lambda_1(i) &= \sum_{k=1}^K w_k(i) \varphi'((\delta_i^T z - z_{C_k}(i + f_k(i)))^2), \\ \lambda_2(i) &= \sum_{k=1}^K \gamma w_k(i) \varphi'((\delta_i^T G_x z - \nabla_x z_{C_k}(i + f_k(i)))^2), \\ \lambda_3(i) &= \sum_{k=1}^K \gamma w_k(i) \varphi'((\delta_i^T G_y z - \nabla_y z_{C_k}(i + f_k(i)))^2), \\ \lambda_4(i) &= \beta s_i^x \varphi'((\delta_i^T G_x z)^2), \\ \lambda_5(i) &= \beta s_i^y \varphi'((\delta_i^T G_y z)^2), \end{aligned}$$

其中 $i = 1, 2, \dots, N$. 第一次迭代时用式(5)的解对应的列矢量 \hat{z}_Q 作为上次迭代的深度图.

步骤 2 将式(9)表示成如式(10)所示的矩阵形式, 然后利用加权最小二乘法求解 z . 式(10)中, \mathbf{A}_1 表示由 $\lambda_1(i)$, $i = 1, 2, \dots, N$ 构成的 $N \times N$ 对角矩阵, 即 $\mathbf{A}_1(i, i) = \lambda_1(i)$, \mathbf{A}_2 、 \mathbf{A}_3 、 \mathbf{A}_4 和 \mathbf{A}_5 的定义与此类似; \mathbf{b}

$\in R^N$, 其第 i 个元素定义为: $\mathbf{b}_i = \sum_{k=1}^K \{ \lambda_1(i) \mathbf{z}_{C_k}(i + \mathbf{f}_k(i)) + \lambda_2(i) \nabla_x \mathbf{z}_{C_k}(i + \mathbf{f}_k(i)) + \lambda_3(i) \nabla_y \mathbf{z}_{C_k}(i + \mathbf{f}_k(i)) \}$.

$$(\mathbf{A}_1 + \mathbf{G}_x^T \mathbf{A}_2 \mathbf{G}_x + \mathbf{G}_y^T \mathbf{A}_3 \mathbf{G}_y + \mathbf{G}_x^T \mathbf{A}_4 \mathbf{G}_x + \mathbf{G}_y^T \mathbf{A}_5 \mathbf{G}_y) \mathbf{z} = \mathbf{b} \quad (10)$$

步骤 3 若迭代到达设定次数(实验中设为 10), 退出; 否则跳到步骤 1.

4 实验结果与分析

在 Liu 等^[14]提供的改进 Make3D 测试数据上进行实验比较. 该数据由 134 个测试 RGBD 图像和 400 个训练 RGBD 图像构成, 图像和深度的分辨率均为 240×320 . 实验中参数均设为: $K = 7$, $\alpha = 10$, $\beta = 10$, $\gamma = 10$, $\eta = 0.255$. 和 Make3D 算法一样^[2], 定量比较采用平均相对误差, 定义如式(11)所示, 其中 \mathbf{z}_{Q_i} 和 \mathbf{z}_{G_i} 分别表示第 i 个测试图像的估计深度和真实深度对应的 N 维列矢量. 实验中, 和 Make3D 算法中基于像素点 MRF 模型方法(Pointwise MRF)、基于超像素 MRF 模型方法(Superpixel MRF)^[2], 文献[3]和文献[14]进行了比较.

$$e_{\text{REL}} = \frac{1}{134N} \sum_{i=1}^{134} \sum_{j=1}^N \frac{|z_{Q_i}(j) - z_{G_i}(j)|}{z_{G_i}(j)} \quad (11)$$



(a) 输入图像 (b) 真实深度 (c) SIFT流中值滤波 (d) 原始SIFT流 (e) 加权SIFT流中值滤波 (f) 加权SIFT流 (g) 最优化SIFT流
图2 加权SIFT流和深度优化实验

由图 2 可知, 加权 SIFT 流深度迁移可较好的保持原始图像中目标的边界, 如图 2 的第 1 行中, 图 2(c) 的 SIFT 流中值滤波已看不出建筑物的轮廓, 且天空区域的深度估计发生了较大偏差; 而图 2(e) 的加权 SIFT 流

4.1 加权 SIFT 流迁移和深度图优化实验

为验证加权 SIFT 流迁移和深度图优化对深度估计的影响, 将加权 SIFT 流深度迁移并经过均值滤波融合、交叉双边滤波(称为“加权 SIFT 流深度迁移”); SIFT 流深度迁移并经过中值滤波、基于能量模型的深度图优化(称为“最优化 SIFT 流深度迁移”)分别和文献[3]进行比较. 表 1 是在 Make3D 测试数据上进行深度估计得到的平均相对误差. 表 1 表明, 加权 SIFT 流深度迁移和基于能量模型的深度图优化都明显降低了估计深度图的平均相对误差.

表 1 平均相对误差

算法	平均相对误差
文献[3]	0.391
加权 SIFT 流深度迁移	0.378
最优化 SIFT 流深度迁移	0.368

图 2 是表 1 中 3 种方法的几个实验结果. 图 2 中深度图采用如式(12)所示的通用格式^[19], 其中 z 为像素值 d 对应的实际深度; $[z_{\text{near}}, z_{\text{far}}]$ 表示场景的实际深度范围.

$$d = 255 \frac{\frac{1}{z} - \frac{1}{z_{\text{far}}}}{\frac{1}{z_{\text{near}}} - \frac{1}{z_{\text{far}}}} \quad (12)$$

深度迁移可区分出天空区域与建筑物的边界, 且天空区域的深度估计接近真实情况. 图 2(g) 的最优化 SIFT 流估计的深度图具有最佳的深度均匀性, 但深度的不连续性较差. 本文将加权 SIFT 流均值滤波和基于能量

模型的深度图优化结合起来,可充分利用二者的优势.

4.2 与现有算法比较


表 2 给出了本文方法和其他算法在 Make3D 测试数据上的平均相对误差.从表 2 可看出,文献[3]的平均相对误差高于 Superpixel MRF 方法和文献[14].本文通过加权 SIFT 流深度迁移和基于能量模型深度优化后,明显降低了估计深度图的平均相对误差.

图 3 给出了不同算法的深度估计结果.图 3 中, Pointwise MRF 算法和文献[3]估计的深度图均匀性较差.本文方法估计深度图的均匀性与 Superpixel MRF 算

法类似,但边界效果要更好.这是因为本文采用的能量模型在尽量接近迁移后 KNN 图像深度的前提下,仅对梯度较小区域进行平滑,因而在改善深度图均匀性的同时能够保留边界区域的信息.

表 2 平均相对误差

算法	平均相对误差
Pointwise MRF ^[2]	0.458
Superpixel MRF ^[2]	0.370
语义增强 Make3D 算法 ^[14]	0.375
文献[3]	0.391
本文方法	0.355



(a) 输入图像 (b) 真实深度 (c) Pointwise MRF (d) Superpixel MRF (e) 文献[14] (f) 文献[3] (g) 本文方法

图3 深度估计定性比较

5 总结

针对 SIFT 流深度迁移算法估计深度的均匀性问题,提出基于加权 SIFT 流的深度迁移方法,并建立深度

图优化的能量模型,以改善估计深度的均匀性.首先根据 SIFT 流计算迁移权重,将近邻图像匹配像素点的深度乘以权重后迁移到输入图像;然后建立能量模型,在尽量逼近迁移后近邻图像深度的前提下,平滑梯度较

小区域的深度.实验表明,与 Make3D 算法和原始 SIFT 流深度迁移算法相比,本文方法降低了估计深度的平均相对误差.目前,我们仅考虑静态图像,需要进一步将这种方法应用到视频中.

参考文献

- [1] 王平,安平,王奎,等.基于区域融合的单视点图像深度信息提取[J].电视技术,2011,35(19):11-13.
Wang P, An P, Wang K, et al. Depth extraction of single-view image using region merging[J]. Video Engineering, 2011, 35(19):11-13. (in Chinese)
- [2] Saxena A, et al. Make3D: Learning 3-D scene structure from a single still image[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(5):824-840.
- [3] Konrad J, Brown G, Wang M, et al. Automatic 2D-to-3D image conversion using 3D examples from the internet[A]. Proceedings of SPIE[C]. Beningham: Society of Photo-Optical Instrumentation Engineers, 2012. 82880F.
- [4] Bharathi S, Vasuki A. 2D-to-3D conversion of images using edge information[A]. IJCA Proceedings on International Conference in Recent trends in Computational Methods, Communication and Controls[C]. New York: Foundation of Computer Science, 2012. 27-32.
- [5] Zhang L, Vazquez C, Knorr S. 3D-TV content creation automatic 2D-to-3D video conversion[J]. IEEE Transactions on Broadcasting, 2011, 57(2):372-383.
- [6] 苏庆华,等.单幅散焦图像深度计算方法[J].红外,2013, 34(5):16-22.
Su Q, et al. Calculation method of depth in single defocused image[J]. Infrared, 2013, 34(5):16-22. (in Chinese)
- [7] 史国凯,等.基于分割的离焦图像深度图提取方法[J].液晶与显示,2012,27(2):229-234.
Shi G, et al. Method for depth map extraction of defocused image based on segmentation[J]. Chinese Journal of Liquid Crystals and Displays, 2012, 27(2):229-234. (in Chinese)
- [8] Zhuo S, Sim T. Defocus map estimation from a single image[J]. Pattern Recognition, 2011, 44(9):1852-1858.
- [9] 马吉权,马培军,苏小红.基于镜面高光检测的明暗恢复形状新方法[J].电子学报,2010,5(5):1084-1088.
Ma Ji, Ma P, Su X. New method of shape from shading based on specular highlights detection[J]. Acta Electronica Sinica, 2010, 5(5):1084-1088. (in Chinese)
- [10] 王学梅,孙即祥.基于高阶 LLF 和 WENO 算法的透视 SFS[J].中国图象图形学报,2011,16(2):300-304.
Wang X, Sun J. Perspective shape from shading based on high-order LLF and WENO[J]. Journal of Image and Graphics, 2011, 16(2):300-304. (in Chinese)
- [11] Jung Y J, Baik A, Kim J, et al. A novel 2D-to-3D conversion technique based on relative height depth cue[A]. Proceedings

of SPIE[C]. Beningham: Society of Photo-Optical Instrumentation Engineers, 2009. 7237-7244.

- [12] Battiato S, et al. Depth map generation by image classification [A]. Proceedings of SPIE[C]. Beningham: Society of Photo-Optical Instrumentation Engineers, 2004. 95-104.
- [13] Cheng C C, Li C T, Chen L G. A 2D-to-3D conversion system using edge information[A]. Proceedings of International Conference on Consumer Electronics[C]. Los Alamitos: IEEE Computer Society Press, 2010. 377-378.
- [14] Liu B Y, Gould S, Koller D. Single image depth estimation from predicted semantic labels[A]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition[C]. Los Alamitos: IEEE Computer Society Press, 2010. 1253-1260.
- [15] 李乐,张茂军,李永乐,等.前景时空域分析和背景理解相结合的 2D/3D 视频转换方法[J].计算机辅助设计与图形学学报,2011,23(5):899-908.
Li L, Zhang M, Li Y, et al. 2D/3D video conversion method based on foreground temporal-spatial analyzing and background understanding[J]. Journal of Computer-Aided Design & Computer Graphics, 2011, 23(5):899-908. (in Chinese)
- [16] 杨昭,高隽,谢昭,等.局部 Gist 特征匹配核的场景分类[J].中国图象图形学报,2013,18(3):264-270.
Yang Z, Gao J, Xie Z, et al. Scene categorization of local Gist feature match kernel[J]. Journal of Image and Graphics, 2013, 18(3):264-270. (in Chinese)
- [17] Liu C, et al. SIFT flow: dense correspondence across scenes and its applications[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(5):978-994.
- [18] Liu C. Beyond pixels: exploring new representations and applications for motion analysis[D]. Cambridge: Dept of Electrical Engineering and Computer Science, Massachusetts Institute of Technology, 2009. 144-146.
- [19] Tian D, et al. View synthesis techniques for 3D video[A]. Proceedings of SPIE[C]. Beningham: Society of Photo-Optical Instrumentation Engineers, 2009. 74430T-74430T-11.

作者简介



袁红星(通信作者) 男,1980年10月出生
于安徽安庆,宁波工程学院电子与信息工程学院
副教授、系统分析师.2010年毕业于中国科学技术
大学信息科学技术学院,获工学博士学位.主要
从事信号与信息处理、3D 视频信号处理和高
性能计算等领域的研究开发工作.
E-mail: yuanhx@mail.ustc.edu.cn

吴少群 女,1981年12月出生于安徽安庆,宁波工程学院电子与信息工程学院讲师.2011年毕业于华东师范大学职成教研究所,获教育学硕士学位.主要从事信号与信息处理、3D 视觉等领域的研究开发工作.

E-mail: vison101@163.com