

基于递阶辨识与交替方向乘子法的深度图像增强

张 跃,朱启兵,黄 敏,李 浩

(江南大学 轻工过程先进控制教育部重点实验室,江苏 无锡 214122)

摘 要: 针对主流传感器采集的深度图像存在深度信息区域缺失、噪声等图像质量问题,提出一种基于 SD 全局优化模型的深度图像增强算法。采用非凸函数对 SD 全局优化模型平滑项进行建模,使其对异常值具有较强的鲁棒性。使用基于递阶辨识(HI)的交替方向乘子法求解 SD 全局优化模型,将目标函数分解成多个子目标函数,并对每个子目标函数通过 HI 思想进行逐个求解,降低求解复杂度。实验结果表明,该算法在加快收敛速度的同时,能有效去除图像噪声及抑制深度伪影。

关键词: 彩色引导;深度图像增强;全局优化;非凸函数;递阶辨识;交替方向乘子法

中文引用格式:张跃,朱启兵,黄敏,等. 基于递阶辨识与交替方向乘子法的深度图像增强[J]. 计算机工程,2019,45(4): 228-234.

英文引用格式:ZHANG Yue, ZHU Qibing, HUANG Min, et al. Depth image enhancement based on hierarchical identification and alternating direction multiplier method[J]. Computer Engineering, 2019, 45(4): 228-234.

Depth Image Enhancement Based on Hierarchical Identification and Alternating Direction Multiplier Method

ZHANG Yue, ZHU Qibing, HUANG Min, LI Hao

(Key Laboratory of Advanced Process Control for Light Industry, Ministry of Education, Jiangnan University, Wuxi, Jiangsu 214122, China)

【Abstract】 Because the depth image acquired by the mainstream sensor has image quality problems such as missing depth information area and noise, a depth image enhancement algorithm based on Static/Dynamic(SD) global optimization model is proposed. The SD global optimization model smoothing term is modeled by non-convex functions, which makes it more robust to outliers. The Alternating Direction Multiplier Method (ADMM) based on Hierarchical Identification(HI) is used to solve the SD global optimization model. The method decomposes the objective function into multiple sub-objective functions, and solves each sub-objective function one by one through the HI idea to reduce the complexity of the solution. Experimental results show that the proposed algorithm can effectively remove image noise and suppress depth artifacts while speeding up convergence.

【Key words】 color guided; depth image enhancement; global optimization; non-convex function; Hierarchical Identification (HI); Alternating Direction Multiplier Method(ADMM)

DOI:10.19678/j.issn.1000-3428.0050656

0 概述

在深度图像中,深度值表示场景中物体到传感器的距离,场景中物体的三维结构信息在人体姿态估计、目标检测等领域都有广泛的应用前景。然而,通过飞行时间(Time of Flight, TOF)、结构光等深度传感器获得的深度图像通常存在干扰引起的噪声或空洞、大面积信息丢失等问题。因此,研究深度图像增强问题,即如何对深度图像通过一系列处理得到

一幅高质量的深度图像有着重要的意义^[1]。

近年来,深度图像的增强引起国内外研究学者的关注。如何快速获得高质量的深度图已成为深度图像研究领域的重要课题。为能获得高质量的深度图像,国内外研究者提出利用与深度图像校准的彩色图像作为引导以得到高质量深度图像的算法。现有基于彩色图像引导的深度图增强方法可分为2类^[2]。一类是基于局部滤波的图像增强方法,主要通过引导图像局部窗口内的权重函数对输入图像进行滤波,从

基金项目:国家自然科学基金(61772240);江苏省政策引导类计划(产学研合作)-前瞻性联合研究项目(BY2016022-32);江苏省研究生科研与实践创新计划项目(SJCX17_0508)。

作者简介:张 跃(1992—),女,硕士研究生,主研方向为深度图像处理;朱启兵(通信作者)、黄 敏,教授;李 浩,硕士研究生。

收稿日期:2018-03-07 **修回日期:**2018-04-11 **E-mail:**zhangyue123q@163.com

而将引导图像的结构传送到输入图像。文献[3]提出联合双边滤波算法。该算法利用深度图像的空间距离权值和彩色图像的灰度权值进行深度像素估计。文献[4]提出滚动引导滤波器(Rolling Guidance Filter, RGF)算法,通过尺度空间滤波器控制细节平滑。文献[5]提出基于边缘保留算子的引导图像滤波(Guided Image Filtering, GIF)算法。该算法通过线性回归估计出线性关系的参数,最终得到滤波结果,解决了双边滤波中容易出现的梯度扭曲问题。虽然局部滤波能够快速增强图像,有效去除噪声,但鲁棒性较低且未考虑深度图像中物体边界的准确性问题。另一类基于全局优化的深度图像增强方法,主要是通过马尔科夫约束对图像进行整体求解,达到深度图像增强的效果。文献[6]提出将图像中像素点间的颜色相似性引申为马尔科夫随机场中的平滑项,最终通过求解马尔科夫随机场所构建的能量最优解得到深度图像增强的结果。文献[7]基于马尔科夫随机场模型引入更多约束,利用复杂先验模型克服传统马尔科夫随机场模型的不足,模型复杂化可以使深度图像增强效果变优,但对算法普适性有一定影响。虽然全局优化能有效提高深度图像质量,但是该方法对异常值不稳定,不能较好地处理浓度边缘的锯齿状伪影。

针对彩色引导深度图增强方法的全局优化问题,文献[8]提出一种彩色引导的SD(Static/Dynamic)全局优化模型。利用鲁棒非凸函数对模型平滑项进行建模,使该模型对于异常值和其他环境因素具有较强的鲁棒性,并且可以处理来自不同传感器的数据,但是利用优化最小化(Majorize Minimization, MM)算法求解该优化模型,存在收敛速度慢、复杂度高问题。因此,本文引入快速交替方向乘子法(Alternating Direction Multiplier Method, ADMM),并结合递阶辨识(Hierarchical Identification, HI)思想求解非凸优化问题^[9],使得该模型能够在快速收敛的同时获得高质量的深度图像。

1 基于 HI 与 ADMM 的深度图像增强

1.1 SD 全局优化模型

本文利用文献[8]中提出的 SD 非凸优化模型进行深度增强,其中静态引导是利用彩色图像权重函数调制输入图像。在优化期间,引导信号是固定的,可以反映输入图像本身的内部属性;动态引导是从增强的输入图像中重复获得加权函数,在每次迭代过程中都会被更新直到收敛。

设 f 是双线性插值输入的深度图像, g 是彩色图像, u 是输出的深度图像。深度图像增强的非凸优化目标函数模型定义如下:

$$\varepsilon(u) = \sum_{i \in \Omega} c_i (u_i - f_i)^2 + \lambda E(u) \quad (1)$$

其中, Ω 是输入图像的所有坐标。式(1)由平滑项参数 λ 平衡数据项和平滑项,等式右边第 1 项(数据项)有助于解决输出图像与输入图像之间的相似特征问题,其中 $c_i \geq 0$ 是输入图像的置信度,如果输入图像在 i 处的像素有效,则将 c_i 设置为 1;否则为 0。由于本文利用双线性差值的方法获得输入图像,因此 c_i 全为 1。等式右边第 2 项(平滑项)使得输出图像和引导图像具有相似结构。平滑项具体如下:

$$E(u) = \sum_{i \in \Omega} \sum_{j \in N_D(i)} \Phi_\mu(g_i - g_j) \Psi_\nu(u_i - u_j) \quad (2)$$

其中, i 或 j 是像素索引, $N_D(i)$ 是像素 i 的邻域,它是以 i 为中心、 $(2r_d + 1) \times (2r_d + 1)$ 的方块, Φ_μ 是彩色图像中相邻像素之间的强度差的权重函数, $\Phi_\mu(x) = \exp(-\mu x^2)$, Ψ_ν 是鲁棒非凸函数, $\Psi_\nu = (1 - \Phi_\nu(x))/\nu$, 该函数作为一个鲁棒调节器,使联合图像增强对异常值具有鲁棒性^[8], μ, ν 是控制平滑带宽。

1.2 基于 HI 与 ADMM 的模型求解

式(1)是一个全局非凸优化模型,可以利用 MM 算法求解^[8]。由于 MM 算法在求解过程中会产生一系列不均匀的病态拉普拉斯矩阵,因此导致 MM 算法求解过程收敛困难,且计算量大^[10]。为解决上述问题,本文引入 ADMM,并结合 HI 思想求解非凸优化问题。ADMM 是一种交替求解的方式,通过不断分解目标函数,进而逐个求解以降低计算复杂度,加快算法收敛性。

本文提出的 SD 全局优化模型结合 ADMM 求解算法(SD-ADMM)的具体步骤如下:1)找到目标函数的等效目标函数,将复杂单目标函数转化为简单多变量目标函数;2)将简单多变量目标函数分解为多个子目标函数;3)对多个子目标函数进行逐个优化求解并重复该步骤最终获得最优解。

将式(1)等效为带约束的全局目标函数:

$$\min_{u, z} \varepsilon(u, z) = \sum_{i \in \Omega} c_i (u_i - f_i)^2 + \lambda \sum_{i \in \Omega} \sum_{j \in N_D(i)} \Phi(g_i - g_j) \Psi_\nu(z_i) \quad (3)$$

其中,引入约束变量 $z_i = u_i - u_j$,再采用增强拉格朗日(Augmented Lagrangian, AL)方法近似式(3)中的问题:

$$\varepsilon_{AL}(u, z, \gamma) = \sum_{i \in \Omega} c_i (u_i - f_i)^2 + \lambda \sum_{i \in \Omega} \sum_{j \in N_D(i)} \left[\Phi(g_i - g_j) \Psi_\nu(z_i) + \frac{\beta}{2} (u_i - u_j - z_i - \gamma_i)^2 \right] \quad (4)$$

其中, γ 是增强拉格朗日乘数, β 是惩罚参数。基于 ADMM,式(4)可以分解成 3 个关于 u_i, z_i, γ_i 的子目标函数(式(5)),并通过 3 个子目标函数的迭代求解实现全局目标函数的优化求解。

$$\left\{ \begin{array}{l} \mathbf{u}_i^{t+1} = \operatorname{argmin}_u \sum_{i \in \Omega} c_i (\mathbf{u}_i - \mathbf{f}_i)^2 + \\ \quad \lambda \sum_{i \in \Omega} \sum_{j \in N_D(i)} \frac{\beta}{2} (\mathbf{u}_i - \mathbf{u}_j - \mathbf{z}'_i - \boldsymbol{\gamma}'_i)^2 \\ \mathbf{z}_i^{t+1} = \operatorname{argmin}_z \lambda \sum_{i \in \Omega} \sum_{j \in N_D(i)} [\Phi(\mathbf{g}_i - \mathbf{g}_j) \Psi_v(\mathbf{z}_i) + \\ \quad \frac{\beta}{2} (\mathbf{u}_i^{t+1} - \mathbf{u}_j^{t+1} - \mathbf{z}_i - \boldsymbol{\gamma}'_i)] \\ \boldsymbol{\gamma}'_i^{t+1} = \boldsymbol{\gamma}'_i^t - (\mathbf{u}_i^{t+1} - \mathbf{u}_j^{t+1} - \mathbf{z}'_i^{t+1}) \end{array} \right. \quad (5)$$

如式(5)中的第1个公式所示,在求解 $(t+1)$ 时刻的 \mathbf{u}_i 时,将 $\mathbf{z}_i, \boldsymbol{\gamma}_i$ 作为固定值(分别表示 t 时刻的迭代值)。然而,利用ADMM求解 \mathbf{u}_i 时,子目标函数中包含关联未知参数向量 \mathbf{u}_j ,使得迭代计算难以进行。因此,本文利用HI思想解决该问题,即在求解 $(t+1)$ 时刻的 \mathbf{u}_i 时,使用 t 时刻的求解值 \mathbf{u}_i 的邻域像素代替子目标函数的未知参数 $\mathbf{u}_j (j \neq i)^{[11]}$,使 \mathbf{u}_j 作为固定值,因此输出图像子目标函数(式(5)中的第1个公式)转化为:

$$\mathbf{u}_i^{t+1} = \operatorname{argmin}_u \sum_{i \in \Omega} c_i (\mathbf{u}_i - \mathbf{f}_i)^2 + \lambda \sum_{i \in \Omega} \sum_{j \in N_D(i)} \frac{\beta}{2} (\mathbf{u}_i - \mathbf{u}_j^t - \mathbf{z}'_i - \boldsymbol{\gamma}'_i)^2 \quad (6)$$

最小化式(6)求得输出图像 \mathbf{u} 为:

$$(2\mathbf{C} + \lambda\beta\mathbf{A})\mathbf{u}^{t+1} = 2\mathbf{C}\mathbf{f} + \lambda\beta(\mathbf{u}^0 + \mathbf{z}' + \boldsymbol{\gamma}'^t) \quad (7)$$

其中, $\mathbf{u}^0 = [\sum_{j \in N_D(i)} \mathbf{u}_j^t]_{M \times 1}$ 是 t 时刻输出图像 \mathbf{u} 的邻域像素矩阵, $\mathbf{f} = [\mathbf{f}_i]_{M \times 1}, \mathbf{g} = [\mathbf{g}_i]_{M \times 1}, \mathbf{u} = [\mathbf{u}_i]_{M \times 1}$ 分别是输入图像、彩色图像、输出图像的向量, $\mathbf{z} = [\mathbf{z}_i]_{M \times 1}, \boldsymbol{\gamma} = [\boldsymbol{\gamma}_i]_{M \times 1}$ 分别是约束变量、增强拉格朗日乘数, M 是输出图像的像素总数, $\mathbf{C} = \operatorname{diag}([c_1, c_2, \dots, c_M])$, \mathbf{A} 是单位矩阵。

同理,如式(5)中的第2个公式所示,在求解 $(t+1)$ 时刻的 \mathbf{z}_i 时,将 $\mathbf{u}_i, \boldsymbol{\gamma}_i$ 作为固定值(分别表示为 $t+1, t$ 时刻的迭代值)。由于变量 \mathbf{u}_i 不是待求值,因此将 \mathbf{u}_i 也作为固定值($t+1$ 时刻的 \mathbf{u}_i 的邻域像素值)。然后利用ADMM求解约束变量子目标函数,令 $h(\mathbf{z}_i) = \sum_{i \in \Omega} \sum_{j \in N_D(i)} \Phi(\mathbf{g}_i - \mathbf{g}_j) \Psi_v(\mathbf{z}_i)$,在 $\boldsymbol{\tau}_i = \mathbf{u}_i^{t+1} - \mathbf{u}_j^{t+1} - \boldsymbol{\gamma}'_i$ 处对 $h(\mathbf{z}_i)$ 进行泰勒展开 $h(\mathbf{z}_i) = h(\boldsymbol{\tau}_i) + h'(\boldsymbol{\tau}_i)(\mathbf{z}_i - \boldsymbol{\tau}_i)$,并定义 $\boldsymbol{\tau}_i$ 处的近端算子 $^{[12]}$: $\operatorname{pro}_{x_h}(\boldsymbol{\tau}_i) = \operatorname{argmin}_{z_i} [\lambda h'(\boldsymbol{\tau}_i)\mathbf{z}_i + \frac{\lambda\beta}{2}(\mathbf{z}_i - \boldsymbol{\tau}_i)^2]$,由此求得约束变量 \mathbf{z} 为:

$$\mathbf{z}^{t+1} = \left(\mathbf{A} - \frac{2}{\beta} \mathbf{W} \right) \boldsymbol{\tau} \quad (8)$$

其中, $\boldsymbol{\tau} = [\boldsymbol{\tau}_i]_{M \times 1}$ 是近端算子向量, $\mathbf{W} = \mathbf{W}_g \circ \mathbf{W}_\tau$, $\mathbf{W}_g = [w_{i,j}^g]_{M \times M}$ 是彩色图像权重矩阵, $\mathbf{W}_\tau = [w_\tau^g]_{M \times M}$ 是图像在 $\boldsymbol{\tau}$ 处的亲和矩阵, \circ 是矩阵的点乘运算。 $w_{i,j}^g = \exp(-\mu(\mathbf{g}_i - \mathbf{g}_j)^2)$, $w_\tau = \exp(-\nu\boldsymbol{\tau}^2)$ 。

最后逐个对式(7)、式(8)、式(5)中的第3个公式进行迭代优化,直到达到迭代次数 t 或 $\|\mathbf{u}^{t+1} - \mathbf{u}^t\| \leq \theta$ 时停止迭代,输出高质量深度图像 \mathbf{u} ,其中 θ 是固定常数。

2 实验设计

2.1 实验数据

目前,深度图像可以通过2种途径获得:一种是基于TOF传感器采集的深度图像,此类图像存在大量随机噪声;另一种是基于Kinect传感器采集的深度图像,此类图像存在深度缺失等图像质量问题 $^{[2]}$ 。为证明本文算法可以处理来自不同传感器的数据,采用以下数据集进行算法验证:

1) Middlebury合成数据集 $^{[13]}$ 。Middlebury数据集提供6种彩色图像(Art、Books、Dolls、Laundry、Moebius、Reindeer)和地面真实深度图像(1376像素 \times 1088像素)。为模拟2种主流传感器的成像特点:(1)对Middlebury数据集提供的6种地面真实深度图像进行下采样($\times 8$),并添加方差为25的高斯噪声获得含噪低分辨率图像,即模拟TOF数据集。(2)将Middlebury数据集提供的6种地面真实深度图像沿深度不连续性产生结构缺失,在平坦区域产生随机缺失,即获得模拟的Kinect深度图(690像素 \times 555像素)。

2) GRAZ数据集。GRAZ数据集 $^{[14]}$ 由TOF传感器获得3种彩色图像(Books、Devil、Shark,810像素 \times 610像素)及其对应的低分辨率深度图像(160像素 \times 120像素)。该数据集还提供了来自高精度结构光扫描仪采集的地面真实深度图像并能进行定量评估。

3) 真实Kinect数据集。本文采用由NYU RGB-D数据集 $^{[14]}$ 提供的Kinect v1传感器采集的彩色图像(Bookcase、Table、Character)和深度图像(640像素 \times 480像素)以及由SUN RGBD数据集 $^{[15]}$ 提供的Kinect v2传感器采集的彩色图像(Desk、Office、Sofa)和深度图像(730像素 \times 530像素)。

2.2 性能指标与参数设置

SD-ADMM算法包含5个参数,其中,平滑带宽 $\mu = 10, \nu = 10$,惩罚参数 $\beta = 2$,邻域 $r_d = 10$,根据图像含噪声量进行适当调整平滑项参数 λ 。本文研究并比较多种算法,SD-MM算法的参数设置为平滑带宽 $\mu = 10, \nu = 10$,邻域 $r_d = 8$;滚动滤波算法的参数设置参照文献[4];引导图像滤波算法的参数设置参照文献[5];MRF算法参数设置参照文献[6];各向异性总广义变化(Anisotropic Total Generalized Variation, ATGV)滤波算法的参数设置参照文献[14];Shen算法参数设置参照文献[16]。

本文采用不良像素匹配率(Bad Matching Percentage, BMP)^[10]和峰值信噪比(Peak Signal to Noise Ratio, PSNR)进行定量评估。BMP和PSNR分别定义为:

$$BMP = \frac{1}{M} \sum_i [|u_i - o_i| > \delta] \quad (9)$$

$$PSNR = 10 \lg \left(\frac{255^2}{\frac{1}{M} \sum_i (u_i - o_i)^2} \right) \quad (10)$$

其中, u_i 和 o_i 分别表示滤波后的深度图像和地面真实深度图像在 i 处的像素值, δ 是深度误差的阈值, 合成数据集中阈值 $\delta = 2$, 真实数据集中阈值 $\delta = 10$, $[\cdot]$ 表示若条件为真, 则为 1; 否则为 0。

3 实验结果与分析

3.1 Middlebury 合成数据集

Middlebury 合成数据集主要包括:

1) 模拟 TOF 数据集。本文利用模拟 TOF 数据集测试彩色引导深度增强算法。表 1 给出以 BMP 和 PSNR 表示的增强深度图的定量评估结果, 表明 MM 和 ADMM 求解该优化模型具有较低的 BMP 和较高的 PSNR, 证明了彩色引导深度增强非凸优化模型的可行性。如图 1 所示, 虽然 MM 具有较好的 PSNR 定量评估结果, 但 MM 在迭代过程中会出现边缘模糊而无法精确定位的问题。相反地, ADMM 能有效去除图像噪声并保持深度连续性。

表 1 模拟 TOF 数据集的定量评估结果

算法	不良像素匹配率 ($\delta = 2$)/%						峰值信噪比/dB					
	Art	Books	Dolls	Laund	Moebi	Reind	Art	Books	Dolls	Laund	Moebi	Reind
Bilinear	52.118	47.145	17.405	49.197	47.709	47.747	31.383	35.811	36.466	34.237	36.102	33.492
GIF	47.955	42.145	42.568	44.406	42.700	42.872	31.549	36.541	37.147	34.709	36.880	33.898
RGF	45.209	38.537	39.269	41.531	39.325	37.693	31.441	36.835	37.482	34.640	37.192	34.011
ATGV	45.930	40.206	40.821	42.080	40.862	41.248	31.942	36.891	37.466	35.110	37.233	34.009
MRF	45.693	38.953	39.670	41.954	39.765	40.005	31.196	36.711	37.416	34.640	37.114	33.695
Shen	48.406	42.896	43.253	44.909	43.523	43.550	31.746	36.502	37.098	34.804	36.811	34.057
SD-MM	37.217	22.577	24.320	28.884	24.749	24.858	30.206	37.498	38.660	34.372	37.820	33.479
SD-ADMM	36.633	21.385	26.116	27.130	24.406	23.254	30.704	37.589	38.258	34.618	37.821	34.061




图 1 模拟 TOF 数据集的实验结果

2) 模拟 Kinect 数据集。本文利用模拟 Kinect 数据集测试了深度图像增强算法。表 2 显示了本文深度图像增强算法与现有算法的定量评估结

果, 由此可知本文深度图像增强算法获得了最低的不匹配像素率, 验证了其对于 Kinect 深度图像增强的有效性。图 2 显示引导图像滤波算法 GIF 算

法^[5]和 Shen 联合结构滤波算法^[16]只适用于小区域深度不连续,而对于大面积的深度丢失效果不佳。虽然 ATGV^[14]、MRF^[6]算法能正确恢复缺失区域,但过增强造成了深度模糊。由表 2 可知,

SD-MM 具有更好的 PSNR 定量评估结果,同样过增强造成了深度边缘的模糊和缺失,相反地,本文提出的 SD-ADMM 算法能较好处理深度缺失和深度连续性问题。

表 2 模拟 Kinect 数据集的定量评估结果

算法	不良像素匹配率($\delta=2$)/%						峰值信噪比/dB					
	Art	Books	Dolls	Laund	Moebi	Reind	Art	Books	Dolls	Laund	Moebi	Reind
GIF	8.282	9.901	12.450	12.427	12.752	11.657	21.182	20.757	20.930	21.554	20.833	20.055
RGF	7.415	7.590	9.628	10.073	9.249	7.818	19.088	19.242	19.200	19.950	19.215	18.588
ATGV	8.283	7.710	8.480	9.390	9.383	8.635	28.265	25.662	26.434	25.128	26.556	25.608
MRF	19.080	7.994	9.833	13.455	10.757	11.150	28.920	26.677	28.174	28.304	27.190	26.887
Shen	6.535	6.884	9.161	8.259	8.886	7.870	19.465	19.385	19.407	20.064	19.449	18.723
SD-MM	6.070	6.413	6.274	6.828	7.755	7.310	29.027	26.735	28.248	28.732	27.282	27.078
SD-ADMM	4.599	4.501	6.259	6.482	6.510	6.184	29.266	26.627	28.122	29.122	27.136	26.631

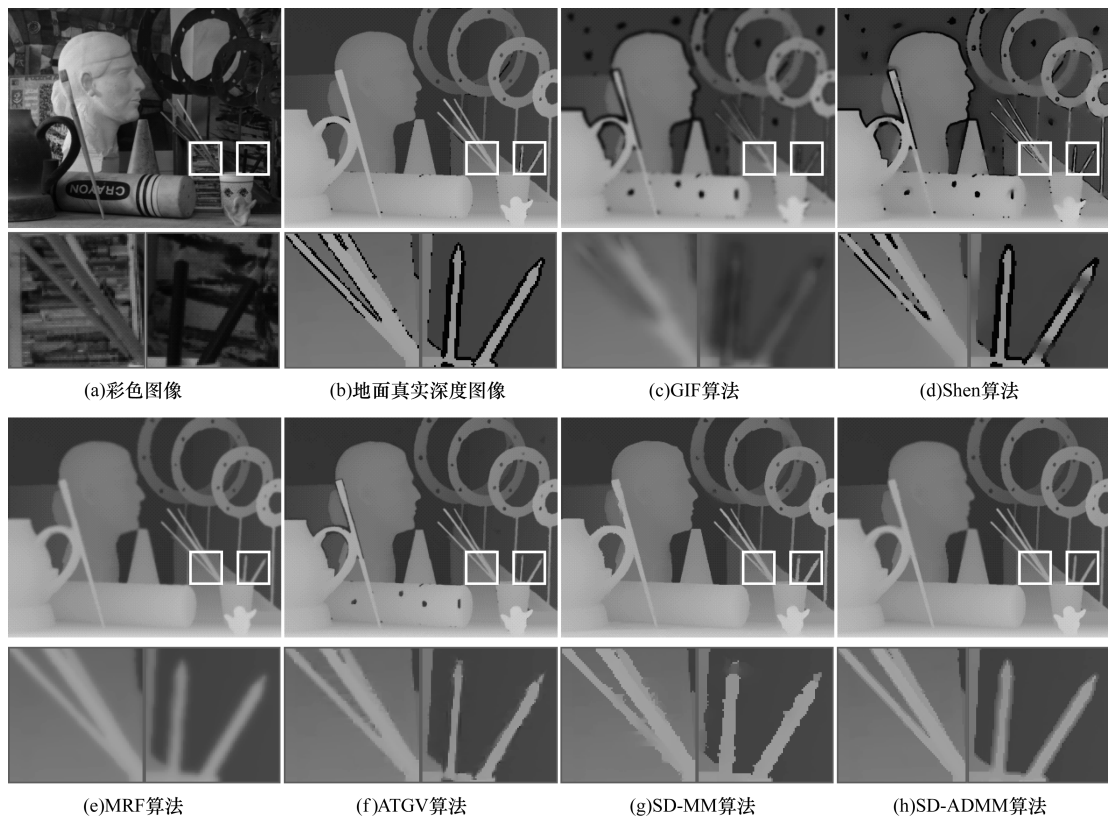


图 2 模拟 Kinect 数据集的实验结果

3.2 GRAZ 数据集

本文在 GRAZ 数据集上测试了深度图增强算法。表 3 显示了本文算法与其他算法在不良像素匹配率和峰值信噪比方面的定量比较结果。由此可知,多数算法都能较好地增强深度图像,但由图 3 可以看出多数算法不能有效去除均匀区域的噪声。ATGV^[14]算法在相关彩色图像纹理丰富的区域(例如杯子的底部、书的边缘)引入了深度伪影。相比之下,SD-ADMM 算法可抑制传感器噪声,并保持深度不连续性,避免了 MM 求解算法造成的深度边缘模糊问题。

表 3 GRAZ 数据集的定量评估结果

算法	不良像素匹配率($\delta=10$)/%			峰值信噪比/dB		
	Books	Devil	Shark	Books	Devil	Shark
Bilinear	28.285	26.562	30.503	12.465	13.053	11.966
GIF	27.806	25.317	29.545	12.484	13.066	11.986
RGF	28.006	24.071	30.321	12.496	13.072	11.970
ATGV	27.627	24.649	28.673	12.478	13.066	11.982
MRF	28.035	25.890	30.042	12.476	13.060	11.977
Shen	27.525	25.269	28.972	12.479	13.065	11.976
SD-MM	27.845	25.189	29.611	12.489	13.067	11.990
SD-ADMM	27.477	24.716	28.668	12.491	13.078	12.015




图 3 GRAZ 数据集的实验结果

3.3 真实 Kinect 数据集

本文采用 Kinect v1 和 Kinect v2 数据集捕获的 2 种深度图进行定性分析,如图 4 所示。由于原始深度图像包含许多噪声,并且不完全对准相应的彩色图像,因此多数算法不适合处理配准滤波。SD-MM

算法能有效去除图像噪声但过度的平滑导致图像边缘模糊,不利于边界的提取。ATGV^[14] 算法不能恢复深度图像中存在边缘大面积深度缺失的情况。相比之下,即使存在异常值和丢失数据的现象,SD-ADMM 算法仍能有效去除噪声且保持边缘平滑。



图 4 真实 Kinect 数据集的实验结果

3.4 算法复杂性分析

实验发现 SD-MM 通常需要 10 次迭代进行深度图像增强,SD-ADMM 需要 30 次迭代进行深度图像增强。可见,SD-MM 比 SD-ADMM 的迭代次数更

少,但是 SD-ADMM 迭代的总体计算时间小于 SD-MM 迭代的总体计算时间。表 4 中给出了 SD-MM、SD-ADMM 这 2 种深度增强算法的平均计算时间。

表 4 SD-MM 和 SD-ADMM 算法的综合性能比较结果

算法	数据集	迭代次数	时间/s	不良像素匹配率/%	峰值信噪比/dB
SD-MM	模拟 TOF 数据集(1 088 像素 × 1 376 像素)	10	194.596	27.101	35.343
	模拟 Kinect 数据集(690 像素 × 555 像素)		56.252	6.775	27.850
	GRAZ 数据集(810 像素 × 610 像素)		75.281	27.548	12.515
SD-ADMM	模拟 TOF 数据集(1 088 像素 × 1 376 像素)	30	38.998	26.487	35.508
	模拟 Kinect 数据集(690 像素 × 555 像素)		16.138	5.755	27.817
	GRAZ 数据集(810 像素 × 610 像素)		20.272	26.954	12.528

4 结束语

由于深度传感器受硬件条件限制和周围环境的影响,其获得的深度图像存在较多图像质量问题。本文提出彩色引导深度增强全局优化模型。该模型可以处理彩色和深度图像之间的结构差异,解决深度渗色和纹理复制伪像问题。通过结合递阶辨识思想并引入快速交替方向乘法求解该优化模型,加快求解速度。实验结果表明,SD-ADMM 算法能够在快速收敛的同时有效去除噪声及保持良好的边缘平滑特性。下一步将对 SD-ADMM 算法中的参数进行精确设置,以提升其在真实 TOF 深度数据集中的视觉效果。

参考文献

- [1] 谭志国,欧建平,张军,等.一种层析深度图像去噪算法[J].光学学报,2017,37(5):94-100.
- [2] 刘俊毅.彩色引导的深度图像增强[D].杭州:浙江大学,2014.
- [3] 刘金荣,李淳其,欧阳建权,等.基于联合双边滤波的深度图像增强算法[J].计算机工程,2014,40(3):249-252.
- [4] ZHANG Q, SHEN X, XU L, et al. Rolling guidance filter[C]//Proceedings of European Conference on Computer Vision. Berlin, Germany: Springer, 2014: 815-830.
- [5] HE K, SUN J, TANG X. Guided image filtering[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(6): 1397-1409.
- [6] DIEBEL J, THRUN S. An application of Markov random fields to range sensing[EB/OL]. (2006-07-11) [2018-02-17]. <https://arxiv.org/abs/1302.5589>.
- [7] GONG X J, LIU J Y, ZHOU W H, et al. Guided depth enhancement via a fast marching method[J]. Image and Vision Computing, 2013, 31(10): 695-703.

- [8] HAM B, CHO M, PONCE J. Robust image filtering using joint static and dynamic guidance [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2015: 4823-4831.
- [9] XIAO J, NG M K P, YANG Y F. On the convergence of nonconvex minimization methods for image recovery[J]. IEEE Transactions on Image Processing, 2015, 24(5): 1587-1598.
- [10] KIM Y, HAM B, OH C, et al. Structure selective depth superresolution for RGB-D cameras[J]. IEEE Transactions on Image Processing, 2016, 25(11): 5227-5238.
- [11] 丁锋,杨家本.大系统的递阶辨识[J].自动化学报,1999,25(5):647-654.
- [12] PARIKH N, BOYD S. Proximal algorithms[J]. Foundations and Trends in Optimization, 2013, 1(3): 127-239.
- [13] YANG J, YE X, LI K, et al. Color-guided depth recovery from RGB-D data using an adaptive autoregressive model[J]. IEEE Transactions on Image Processing, 2014, 23(8): 3443-3458.
- [14] FERSTL D, REINBACHER C, RANFTL R, et al. Image guided depth upsampling using anisotropic total generalized variation[C]//Proceedings of IEEE International Conference on Computer Vision. Washington D. C., USA: IEEE Press, 2013: 993-1000.
- [15] SONG S, LICHTENBERG S P, XIAO J A. RGB-D: a RGB-D scene understanding benchmark suite [C]//Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2015: 1-6.
- [16] SHEN X, ZHOU C, XU L, et al. Mutual-structure for joint filtering [C]//Proceedings of IEEE International Conference on Computer Vision. Washington D. C., USA: IEEE Press, 2015: 3406-3414.

编辑 陆燕菲