

图像引导的二阶总广义变分稀疏深度图的稠密重构

吴少群 袁红星 安鹏 程培红

(宁波工程学院电子与信息工程学院 宁波 315016)

摘要 利用图像颜色信息进行深度图重构,可以恢复对象边界处的深度不连续性,但无法保证对象内部的深度均匀性。为解决该问题,提出图像引导下总广义变分正则化的深度图重构模型。该模型利用扩散张量将图像提供的边缘信息引入二阶总广义变分正则项,使得重构深度在保持对象边缘的同时逼近分段仿射平面,从而保证恢复深度既保持对象边界处的不连续性,又具有对象内部的均匀性。通过 Legendre-Fenchel 变换将模型转换成等效的凸凹鞍点问题,从而得到高效的一阶原始对偶求解算法。实验结果表明,该方法能够恢复尖锐的对象边缘,同时保持对象内部的深度均匀性。与现有算法相比,所提方法具有更高的峰值信噪比、归一化互协方差和更低的平均绝对误差。

关键词 深度图重构,深度不连续性,深度均匀性,总广义变分

中图分类号 TN911.73 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2015.7.067

Dense Depth Map Reconstruction via Image Guided Second-order Total Generalized Variation

WU Shao-qun YUAN Hong-xing AN Peng CHENG Pei-hong

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

Abstract The depth map reconstruction using image colors may recovery the depth discontinuities at object boundaries, but will damage depth uniformities inside objects. In order to solve this problem, we formulated depth reconstruction as a convex optimization problem which is regularized by image guided total generalized variation. By incorporating image diffusion tensor into the variation regularizer, the proposed method generates piecewise smooth depth while preserving discontinuities at object boundaries. To efficiently solve the problem, a first-order primal-dual scheme was derived based on the Legendre-Fenchel transformation. Experimental results demonstrate that our method can preserve depth discontinuities at object boundaries and uniformities inside objects and outperform existing methods in terms of peak signal-to-noise ratio, normalized cross-covariance and mean absolute error.

Keywords Depth map reconstruction, Depth discontinuities, Depth uniformities, Total generalized variation

1 相关工作

深度图是 3D 视频绘制的关键,它可以通过计算机视觉算法得到^[1]。然而,在很多应用场景中,诸如视差、散焦、遮挡和运动等深度线索只能在图像的边缘或特征点处才能得到可靠的估计^[2]。因而需要借助深度图重构算法,从稀疏的深度图中恢复稠密的深度图。

从稀疏到稠密的深度图重构方法,目前主要分为 3 类,即:(1)基于压缩感知理论(Compressed Sensing, CS)的方法;(2)基于图像引导的方法(Image Guided Method);(3)基于三角剖分的插值方法。

近年来,随着 CS 研究的兴起^[3-5],涌现了大量基于 CS 理论的图像重构方法。这些方法通常将图像重构转换成总变分(Total Variation, TV)正则的最优化问题^[6]。针对 TV 正则化 CS 图像重构易出现过平滑结果的问题,Dong 等^[7]提出迭

代变权重的 TV 正则项,通过最大化图像梯度后验估计概率的方法计算空间自适应权重。为抑制 TV 正则化引入的阶梯效应,Hu 等^[8]提出高度(High Degree)TV 正则化方法。为克服 TV 正则化导致的重构图像边缘与纹理细节模糊、丢失的问题,费选等^[9]利用图像的梯度信息构建加权 TV 正则项。为弥补 TV 正则化的不足,Zhang 等^[10]利用图像的自我相似性,引入辅助的非局部正则项。然而,上述方法都是针对灰度图像的重构。与灰度图相比,深度图有着自身的统计特性,如深度的不连续过渡仅发生在对象边界处^[11]。因而,上述方法难以直接用于深度图的重构。针对深度图小波变换系数的稀疏性,Howe 等^[12]首先将 CS 理论引入深度图的重构方法中,但问题是该方法没有充分利用纹理图像提供的信息,在采样率较低的情况下难以保持深度图的对象边缘。

基于图像引导的方法根据颜色或亮度的相似性,将稀疏的深度通过邻域传递到整个图像平面。受 Levin 等^[13]提出

到稿日期:2014-07-18 返修日期:2014-08-22 本文受浙江省自然科学基金(LY12F01001, LQ12D01001, LQ12F03001),浙江省教育厅科研项目(Y201431834),宁波市自然科学基金(2012A610048)资助。

吴少群(1981-),女,硕士,实验师,主要研究方向为图像与信号处理,3D 视频处理,E-mail: vision101@163.com;袁红星(1980-),男,博士,副教授,CCF 会员,主要研究方向为图像与信号处理,3D 视频处理,2D 转 3D,E-mail: yuanhx@mail.ustc.edu.cn(通信作者);安鹏(1981-),男,博士,副教授,主要研究方向为信号处理;程培红(1979-),女,博士,副教授,主要研究方向为信号处理。

的抠图方法的启发, Zhuo 等^[14]利用抠图拉普拉斯插值(Mating Laplacian Interpolation, MLI)进行单幅离焦图的稠密散焦度估计。MLI 假设图像平面上一个小的窗内, 深度是颜色的线性函数。然而, 深度和颜色之间并不存在直接的线性关系, 使得 MLI 估计结果的均匀性较差。此外, MLI 的计算复杂度较高。为减少计算量, Vosters 等^[15]利用 Gauss-Seidel 松弛^[16]设计了稀疏到稠密的迭代插值算法, 通过扫描线上的局部滤波向邻域渐进传递深度。与 MLI 相比, 该方法显著降低了计算量, 但估计深度的质量有所下降。

基于 Delaunay 三角剖分的插值(Delaunay Triangulation Based Interpolation, DTI)是经典的稀疏到稠密的重组方法。Wu 等^[17]首先利用 Canny 边提取图像的可靠支撑点(Support Points), 然后估计支撑点处的深度, 最后通过 DTI 向邻域传递得到稠密的深度。Huang 等^[18]首先利用边缘检测辅助的尺度不变特征点匹配得到稀疏的深度图, 然后利用 DTI 获得稠密的深度图。DTI 的优势是计算复杂度低, 实现简单。但稀疏采样点的位置并不一定位于对象边界处, 因而 DTI 重组结果的边缘效果较差, 会在对象边界处产生虚假的深度。

为解决上述方法存在的问题, 根据灰度图对象边界一般也是深度图对象边界的事实^[19,20], 本文利用图像引导的二阶总广义变分(Image Guided Second Order Total Generalized Variation, ISOTGV)进行稀疏深度图的稠密重组, 具体框架如图 1 所示。与现有图像引导类算法不同的是, 本文假设灰度图的边缘对应了深度图的边缘, 而不是要求重组深度和图像颜色存在直接的线性关系。因而本文方法既能保持 MLI 结果的深度边缘, 又能避免 MLI 深度均匀性较差的问题。本文的主要贡献有: (1) 将稀疏到稠密的深度图重组问题转换成 ISOTGV 正则化的凸最优化问题, 既能保持深度图在对象边界处的不连续性, 又能增强深度图的均匀性; (2) 通过 Legendre-Fenchel 变换^[21]将上述凸最优化问题转换成等价的凸凹鞍点问题, 从而能够利用高效的一阶原始对偶算法进行求解。本文方法与文献^[19,20]的区别是代价函数的定义不同, 此外本文引入 DTI 用于加速算法收敛。

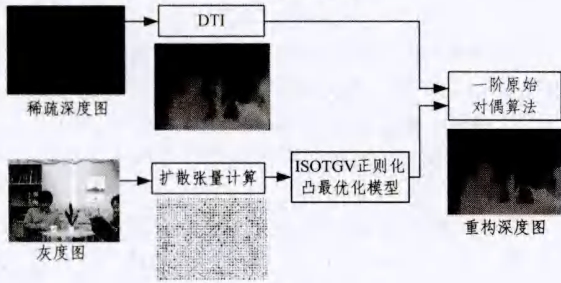


图 1 本文方法框架

2 算法概述

2.1 理论模型

不失一般性, 假设稀疏深度图 D_s 和对应的灰度图 I 分辨率相同, 都用 $M \times N$ 的 2D 矩阵表示; 用 0-1 指示矩阵 Ω 表示深度图的稀疏采样位置, 即 $D_s = D_T \circ \Omega$, 其中 D_T 为真实的稠密深度图, \circ 表示 Hadamard 积; 用 $X = \mathbb{R}^{M \times N}$ 表示一个内积空间, 其中内积的定义如式(1)所示, X 的笛卡尔积构成的空间表示为: $Y = X \times X$; $\| \cdot \|_F$ 表示矩阵的 Frobenius 范数, $\| \cdot \|_1$ 为 l_1 范数; ∇ 表示梯度算子。

$$\langle U, V \rangle_X = \sum_{i=1}^M \sum_{j=1}^N U(i, j) V(i, j) \quad (1)$$

式中, $\langle \cdot, \cdot \rangle_X$ 表示定义在 X 上的内积; $U, V \in X$; $U(i, j)$ 为矩阵 U 第 i 行第 j 列的元素。本文利用灰度图提供的边缘信息, 提出 ISOTGV 正则化的深度图重组模型:

$$D = \arg \min_{D \in X} \{ \lambda E_d(D) + E_s(D) \} \quad (2)$$

式中, D 表示重组的深度图; E_d 为数据项, 用于度量重组的稠密深度和输入的稀疏深度之间的差异, 定义如式(3)所示; E_s 表示平滑项, 利用先验知识使重组的深度满足期望的属性, 定义如式(4)所示; 常数 λ 用于平衡数据项和平滑项对重组结果的影响。

$$E_d(D) = \frac{1}{2} \| \Omega \circ (D - D_s) \|_F^2 \quad (3)$$

$$E_s(D) = \alpha_1 \| T^{1/2} \nabla D - V \|_1 + \alpha_0 \| \nabla V \|_1 \quad (4)$$

式(3)定义的数据项保证重组的深度图在稀疏采样位置与输入的稀疏深度图尽量一致。式(4)为 ISOTGV 正则项, 其中 $T^{1/2}$ 表示图像 I 的扩散张量, 其定义如式(5)所示。式(5)中 N 为图像 I 的梯度方向, 即 $N = \nabla I / \| \nabla I \|_1$; N^\perp 表示与 N 相垂直的方向; 常数 β 和 γ 用于控制扩散张量的幅度和尖锐度^[19,20]。

$$T^{1/2} = e^{-\beta \| \nabla I \|_1} \gamma N N^T + N^\perp (N^\perp)^T \quad (5)$$

总广义变分(Total Generalized Variation, TGV)能够有效逼近任意阶多项式^[22]。根据文献^[22], 深度图的二阶 TGV 在离散域的定义为:

$$TGV_\alpha^2(D) = \arg \min_{V \in Y} \{ \alpha_1 \| \nabla D - V \|_1 + \alpha_0 \| \nabla V \|_1 \} \quad (6)$$

式中, V 表示有界变形(bounded deformation)向量场; α_0 和 α_1 为常数。二阶 TGV 能够逼近分段仿射平面。因而通过二阶 TGV 正则化, 可得到分段平滑的深度图。但仅仅根据二阶 TGV, 难以恢复对象边界处深度的不连续性。类似于文献^[19,20], 根据灰度图的边缘和深度图的边缘具有较高的重合度, 引入灰度图提供的边缘信息到二阶 TGV 中, 得到式(4)所示的 ISOTGV。

综上所述, 本文通过求解式(7)定义的凸最优化问题来恢复稠密的深度图:

$$[D, V] = \arg \min_{D \in X, V \in Y} \left\{ \frac{\lambda}{2} \| \Omega \circ (D - D_s) \|_F^2 + \alpha_1 \| T^{1/2} \nabla D - V \|_1 + \alpha_0 \| \nabla V \|_1 \right\} \quad (7)$$

2.2 模型求解

式(7)是一个非平滑的凸最优化问题, 本文通过 Legendre-Fenchel 变换^[21]将其转为等效的凸凹鞍点问题, 以便能够利用高效的原始对偶算法^[23]求解。

根据文献^[24], 空间 X 上范数 $f(D) = \| D \|$ 的共轭是其对偶范数单位球上的指示函数, 即 $f^*(U) = \sup_{D \in X} \{ \langle D, U \rangle_X - \| D \| \}$

$$\| D \| = \delta_{R_U}(U) = \begin{cases} 0, & \| U \|_* \leq 1 \\ +\infty, & \text{否则} \end{cases}, \text{其中 } R_U = \{ U \in X \mid \| U \|_* \leq 1 \}.$$

l_1 范数和 l_∞ 范数互为对偶范数^[24]。由此, 可以得到 $\| T^{1/2} \nabla D - V \|_1 = \max_{P \in Y} \{ \langle P, T^{1/2} \nabla D - V \rangle_Y - \delta_{R_P}(P) \}$, 其中 $R_P = \{ P \in Y \mid \| P \|_\infty \leq 1 \}$ 。由于 $P \in R_P$ 时, $\delta_{R_P}(P) = 0$; 否则 $\delta_{R_P}(P) = \infty$ 。因而对偶变量 P 必然属于集合 R_P 。从而, 可得到:

$$\| T^{1/2} \nabla D - V \|_1 = \max_{P \in R_P} \{ \langle P, T^{1/2} \nabla D - V \rangle_Y \} \quad (8)$$

同理,可得到式(9),其中 $\mathbf{Z}=\mathbf{Y}\times\mathbf{Y}$, $\mathbf{R}_Q=\{Q\in\mathbf{Z}|\|Q\|_\infty\leq 1\}$ 。

$$\|\nabla\mathbf{V}\|_1=\max_{Q\in\mathbf{R}_Q}\{\langle Q,\nabla\mathbf{V}\rangle_{\mathbf{Z}}\} \quad (9)$$

将式(8)和式(9)代入式(7),可得到式(10)所示的凸凹鞍点最优化问题。式(10)中 \mathbf{P} 和 \mathbf{Q} 为对偶变量; \mathbf{D} 和 \mathbf{V} 表示原始变量,其中 \mathbf{D} 为重构的深度。

$$[\mathbf{D},\mathbf{V},\mathbf{P},\mathbf{Q}]=\arg\min_{\mathbf{D}\in\mathbf{X},\mathbf{V}\in\mathbf{Y},\mathbf{P}\in\mathbf{R}_P,\mathbf{Q}\in\mathbf{R}_Q}\{\alpha_1\langle\mathbf{P},\mathbf{T}^{1/2}\nabla\mathbf{D}-\mathbf{V}\rangle_{\mathbf{Y}}+\alpha_0\langle\mathbf{Q},\nabla\mathbf{V}\rangle_{\mathbf{Z}}+\frac{\lambda}{2}\|\Omega_s\circ(\mathbf{D}-\mathbf{D}_s)\|_{\mathbf{F}}^2\} \quad (10)$$

文献[23]的研究表明,可通过梯度上升和梯度下降的迭代分别得到式(10)中的对偶变量和原始变量的解。用于更新对偶变量 \mathbf{P} 的算式如式(11)所示^[23],其中 $\sigma,\theta>0$ 为更新步长; \mathbf{P}^n 表示第 n 次迭代后变量 \mathbf{P} 的解; $\bar{\mathbf{D}}^n=\mathbf{D}^n+\theta(\mathbf{D}^n-\mathbf{D}^{n-1})$; $\bar{\mathbf{V}}^n=\mathbf{V}^n+\theta(\mathbf{V}^n-\mathbf{V}^{n-1})$ 。

$$\mathbf{P}^{n+1}=\arg\min_{\mathbf{P}\in\mathbf{R}_P}\frac{1}{2}\|\mathbf{P}^n+\sigma\alpha_1(\mathbf{T}^{1/2}\nabla\bar{\mathbf{D}}^n-\bar{\mathbf{V}}^n)-\mathbf{P}\|_{\mathbf{F}}^2 \quad (11)$$

为获得式(11)的解,将其对 \mathbf{P} 求导,并令之为 0,得到 $\mathbf{P}^{n+1}=\mathbf{P}^n+\sigma\alpha_1(\mathbf{T}^{1/2}\nabla\bar{\mathbf{D}}^n-\bar{\mathbf{V}}^n)$ 。进一步,为满足条件 $\mathbf{P}^{n+1}\in\mathbf{R}_P$,根据逐点欧氏距离将其投影到 \mathbf{R}_P 上,得到如式(12)所示的最终解,其中 $\Pi_{\mathbf{R}_P}$ 表示逐个元素向 \mathbf{R}_P 投影的算子,即 $\Pi_{\mathbf{R}_P}(\mathbf{P})$ 就是对 \mathbf{P} 中的每个元素进行投影运算: $\Pi_{\mathbf{R}_P}\{\cdot\}=\cdot/\max(1,|\cdot|)$ 。

$$\mathbf{P}^{n+1}=\Pi_{\mathbf{R}_P}\{\mathbf{P}^n+\sigma\alpha_1(\mathbf{T}^{1/2}\nabla\bar{\mathbf{D}}^n-\bar{\mathbf{V}}^n)\} \quad (12)$$

同样根据文献[23],可得到对偶变量 \mathbf{Q} 的更新算式,具体如式(13)所示。

$$\mathbf{Q}^{n+1}=\arg\min_{\mathbf{Q}\in\mathbf{R}_Q}\frac{1}{2}\|\mathbf{Q}^n+\sigma\alpha_0\nabla\bar{\mathbf{V}}^n-\mathbf{Q}\|_{\mathbf{F}}^2 \quad (13)$$

同理,令式(13)对 \mathbf{Q} 的导数为 0,并将其投影到 \mathbf{R}_Q 得到 \mathbf{Q} 的第 $n+1$ 次迭代解,具体如式(14)所示,其中 $\Pi_{\mathbf{R}_Q}$ 表示逐个元素向 \mathbf{R}_Q 投影的算子,令 $\tilde{\mathbf{Q}}=\mathbf{Q}^n+\sigma\alpha_0\nabla\bar{\mathbf{V}}^n$,则 $\Pi_{\mathbf{R}_Q}(\tilde{\mathbf{Q}})$ 即为对 $\tilde{\mathbf{Q}}$ 中每个元素进行投影运算: $\Pi_{\mathbf{R}_Q}\{\cdot\}=\cdot/\max(1,|\cdot|)$ 。

$$\mathbf{Q}^{n+1}=\Pi_{\mathbf{R}_Q}\{\mathbf{Q}^n+\sigma\alpha_0\nabla\bar{\mathbf{V}}^n\} \quad (14)$$

原始变量的更新算式则采用梯度下降算法。根据文献[23], \mathbf{D} 的迭代更新方程如式(15)所示,其中 $\nabla^*=-\text{div}$ 表示梯度算子 ∇ 的伴随算子, div 为散度算子。

$$\mathbf{D}^{n+1}=\arg\min_{\mathbf{D}\in\mathbf{X}}\{\frac{1}{2}\|\mathbf{D}^n-\tau\alpha_1\nabla^*(\mathbf{T}^{1/2}\mathbf{P}^{n+1})-\mathbf{D}\|_{\mathbf{F}}^2+\frac{\tau\lambda}{2}\|\Omega_s\circ(\mathbf{D}-\mathbf{D}_s)\|_{\mathbf{F}}^2\} \quad (15)$$

令式(15)对 \mathbf{D} 的导数为 0,得到 \mathbf{D} 的第 $n+1$ 次迭代解,如式(16)所示,其中 $/$ 表示 Hadamard 除,即逐个元素的除法运算。

$$\mathbf{D}^{n+1}=\{\mathbf{D}^n+\tau\alpha_1\text{div}(\mathbf{T}^{1/2}\mathbf{P}^{n+1})+\tau\lambda\Omega_s\circ\mathbf{D}_s\}./(1+\tau\lambda\Omega_s) \quad (16)$$

同样由文献[23]得到原始变量 \mathbf{V} 的更新方程,如式(17)所示。

$$\mathbf{V}^{n+1}=\arg\min_{\mathbf{V}\in\mathbf{Y}}\{\frac{1}{2}\|\mathbf{V}^n+\tau(\alpha_1\mathbf{T}^{1/2}\mathbf{P}^{n+1}+\alpha_0\text{div}(\mathbf{Q}^{n+1}))-\mathbf{V}\|_{\mathbf{F}}^2\} \quad (17)$$

同理,将式(17)对 \mathbf{V} 求导并令其为 0,得到 \mathbf{V} 的第 $n+1$ 次迭代解:

$$\mathbf{V}^{n+1}=\mathbf{V}^n+\tau(\alpha_1\mathbf{T}^{1/2}\mathbf{P}^{n+1}+\alpha_0\text{div}(\mathbf{Q}^{n+1})) \quad (18)$$

2.3 算法实现

根据式(12)、式(14)、式(16)和式(18),可得到式(7)的一阶原始对偶求解算法。下面给出其实现的具体步骤:

步骤 1 输入稀疏深度图 \mathbf{D}_s 、对应的灰度图 \mathbf{I} 和稀疏采样位置 0-1 指示矩阵 Ω_s 。

步骤 2 初始化。在稀疏深度图 \mathbf{D}_s 上进行 DTI 运算得到 \mathbf{D}_{DT} 用于初始化重构深度 \mathbf{D} ,即 $\mathbf{D}^0=\mathbf{D}_{DT}$;初始化其他变量: $\mathbf{V}^0=0$, $\bar{\mathbf{D}}^0=\mathbf{D}^0$, $\bar{\mathbf{V}}^0=\mathbf{V}^0$, $\mathbf{P}^0=0$, $\mathbf{Q}^0=0$;选择合适的非负步长 $\theta_D,\theta_V,\sigma_P,\sigma_Q,\tau_D,\tau_V$;设置二阶 TGV 参数 α_0,α_1 ;初始化图像张量参数 β,γ ;选择数据项权重 λ ;设置最大的迭代次数,令迭代计数器 n 为 0。

步骤 3 更新第 $(n+1)$ 次迭代后对偶变量 \mathbf{P},\mathbf{Q} 和原始变量 \mathbf{D},\mathbf{V} 的解,具体更新算式为:

$$\mathbf{P}^{n+1}=\Pi_{\mathbf{R}_P}\{\mathbf{P}^n+\sigma_P\alpha_1(\mathbf{T}^{1/2}\nabla\bar{\mathbf{D}}^n-\bar{\mathbf{V}}^n)\}$$

$$\mathbf{Q}^{n+1}=\Pi_{\mathbf{R}_Q}\{\mathbf{Q}^n+\sigma_Q\alpha_0\nabla\bar{\mathbf{V}}^n\}$$

$$\mathbf{V}^{n+1}=\mathbf{V}^n+\tau_V(\alpha_1\mathbf{T}^{1/2}\mathbf{P}^{n+1}+\alpha_0\text{div}(\mathbf{Q}^{n+1}))$$

$$\mathbf{D}^{n+1}=\{\mathbf{D}^n+\tau_D\alpha_1\text{div}(\mathbf{T}^{1/2}\mathbf{P}^{n+1})+\tau_D\lambda\Omega_s\circ\mathbf{D}_s\}./(1+\tau_D\lambda\Omega_s)$$

$$\bar{\mathbf{D}}^{n+1}=\mathbf{D}^{n+1}+\theta_D(\mathbf{D}^{n+1}-\mathbf{D}^n)$$

$$\bar{\mathbf{V}}^{n+1}=\mathbf{V}^{n+1}+\theta_V(\mathbf{V}^{n+1}-\mathbf{V}^n)$$

步骤 4 令 $n=n+1$,若 n 大于或等于最大的迭代数或相邻两次迭代 \mathbf{D} 的解的差异小于预定阈值,返回 \mathbf{D} 的解并退出程序,否则跳到步骤 3。

与文献[19,20]类似,本文采用对角预条件的方法^[25]确定步长 $\theta_D,\theta_V,\sigma_P,\sigma_Q,\tau_D,\tau_V$ 的初始值,并在迭代过程中更新这些步长,以加快算法的迭代速度。此外,为减少迭代次数,用 DTI 恢复结果作为重构深度 \mathbf{D} 的初始解。

3 实验与分析

测试数据来自清华大学宽带网数字媒体技术实验室^[26],重点比较了其中 4 个有代表性的测试场景:Initon-2d3d-Showrell-2(无纹理区域、颜色歧义性),HeadRotete(遮挡、颜色歧义性),Philips-the-3D-experience(无纹理区域)和 Philips-the-3D-experience-2(无纹理区域、尖锐边缘)。

实验中定量比较的指标有 PSNR、真实深度图和重构深度图之间的归一化互协方差(Normalized Cross-Covariance, NCC)^[19]和平均绝对误差(Mean Absolute Error, MAE)。本文算法的参数设置在所有实验中均相同,具体为: $\lambda=40$, $\alpha_0=1$, $\alpha_1=0.03$, $\beta=9$, $\gamma=1$ 。

实验中,将本文算法与基于 CS 理论的重构方法(CS Based Reconstruction, CSR)^[12]、MLI^[14]和 DTI^[17]进行定量和定性的比较。为得到稀疏深度图,与文献[12]类似,采用 Canny 边采样的方式,用灰度图上的 Canny 边作为深度图的稀疏采样位置。此外,为获得指定的采样率,将图像划分成若干个不重叠的区域,如果所有 Canny 边上的采样数仍少于指定的采样数,将离 Canny 边最近但未检测到边缘的区域中心也纳入采样位置。

3.1 DTI 初始化对算法迭代效率的影响

式(7)是一个凸最优化问题,只要迭代次数足够多总能找到全局最优解,但接近最优解的初始化能够加快算法收敛速率。DTI 结果虽然在对象边界处效果较差,但在其他区域已较为接近真实深度。鉴于 DTI 计算复杂度低、实现简单,将其结果作为本文算法的起点是合适的。为验证 DTI 初始化

对算法收敛速率的影响,分别将初始解设为 0 和 DTI 重构结果,让算法迭代固定的次数,得到的 MAE 随迭代次数变化的曲线如图 2 所示。

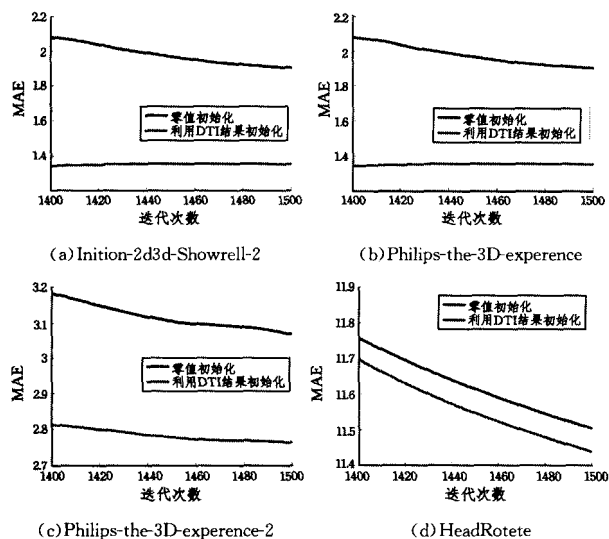


图 2 DTI 初始化对算法收敛速率的影响

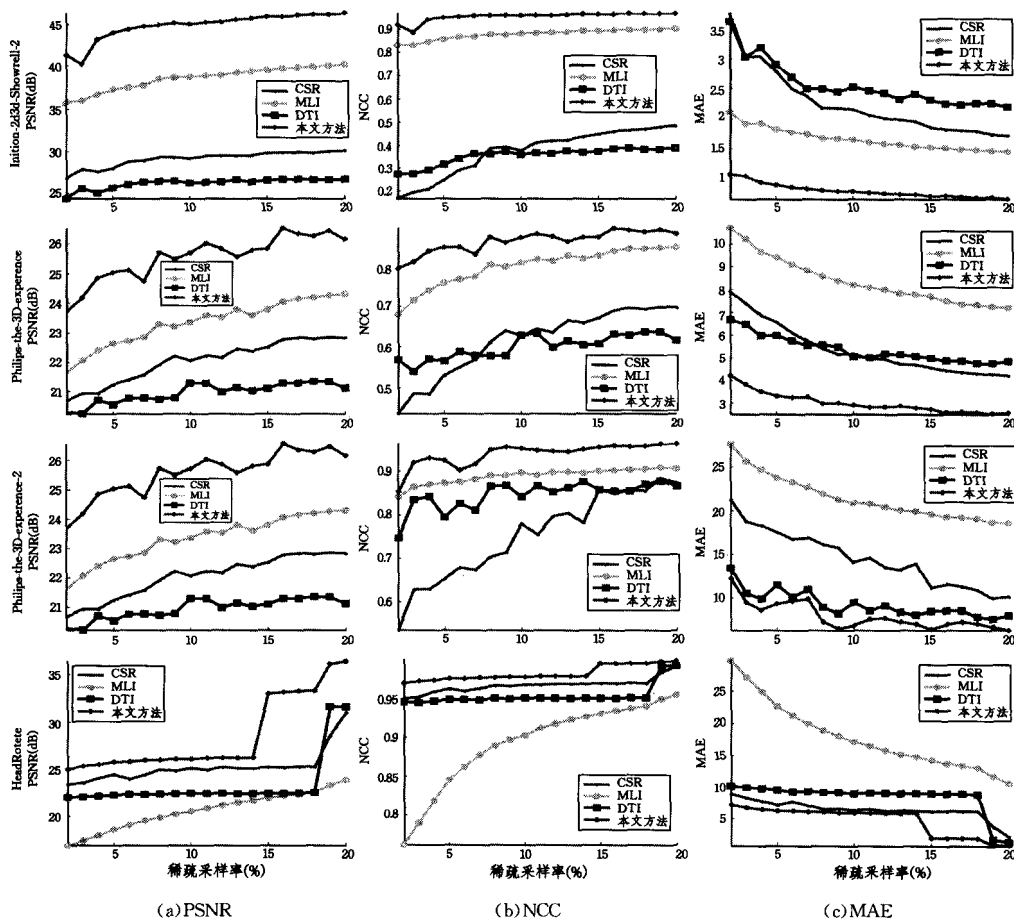


图 3 不同采样率下稠密深度图重构的定量比较

3.3 定性比较

当稀疏采样率为 7% 时,4 个算法重构结果的视觉比较如图 4 所示。由图 4 可看出,真实深度图有两个特点:(1)对象内部深度具有均匀性;(2)对象间深度过渡具有不连续性。本文算法恢复结果和真实深度图在视觉上最为接近,重构深度在对象内部均匀性较好,且保持了对象边界处的不连续性。

MLI 重构结果在对象边界处不连续性较好,但在对象内

部均匀性较差,如 HeadRotete 帽子处的深度跳变较大,这是由于 MLI 假设相似颜色的像素点具有相似深度。CSR 结果均匀性较好,但对象边界处的深度恢复结果较差,如 Philips-the-3D-experience-2 重构结果已看不清楚树和天空分界处的轮廓,而本文恢复结果能清晰地看出二者的分界。DTI 在对象边界处的深度重构质量较差,如 Philips-the-3D-experience 女孩头部区域出现较多的虚假轮廓。本文方法恢复的深度既

3.2 定量比较

在不同采样率下重构深度图的定量比较指标如图 3 所示。由图 3 可知,在 4 个测试数据中,本文算法的 3 个指标,即 PSNR、NCC 和 MAE 均优于 CSR、MLI 和 DTI。

除了 Initon-2d3d-Showrell-2 测试场景外,MLI 的 MAE 指标均最差。这是因为 MLI 假设在一个小的窗内深度是颜色的线性函数,因而 MLI 过于依赖图像的颜色信息,使得深度容易受颜色变化的影响,导致重构深度的均匀性较差。对于 PSNR 和 NCC 两个指标,MLI 在前 3 个测试数据中仅次于本文方法,但在最后一个测试数据中却是最差的。这说明,MLI 场景适应性较差,只有当假设条件满足时才能得到较好的结果。

对于 4 个测试数据,CSR 的 PSNR 指标要优于 DTI 方法,但在 NCC 和 MAE 指标上两者各有优劣。

具有 MLI 深度不连续性的优势,又保持了 CSR 深度均匀性的优点。




图4 采样率为7%时稠密深度图重构的定性比较

结束语 与现有图像引导类深度重构方法不同,本文仅利用灰度图提供的边缘信息,避免了因过度依赖颜色信息而导致的深度均匀性较差的问题。二阶总广义变分可逼近分段仿射平面,能够保证重构深度的均匀性。进一步,为保持对象边界处的深度不连续性,本文将图像扩散张量引入二阶总广义变分,建立图像引导的深度图重构模型。实验结果表明,本文重构结果的定量和定性指标均优于现有方法。下一步准备引入时域信息,建立稀疏深度图序列时空一致性边界保持的稠密重构模型。

参 考 文 献

[1] 袁红星,吴少群,余辉晴,等. 语义级深度迁移的2D转3D算法[J]. 计算机辅助设计与图形学学报,2014,26(1):72-80
Yuan Hong-xing, Wu Shao-qun, Yu Hui-qing, et al. 2D-to-3D method via semantic depth transfer[J]. Journal of Computer-Aided Design & Computer Graphics, 2014, 26(1): 72-80

[2] Vosters L, Haan G D. Efficient and stable sparse-to-dense conversion for automatic 2-D to 3-D conversion[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2013, 23(3):373-386

[3] 尚斐,杜慧茜,贾云得. 结合图像结构特征和近似 l_0 范数的压缩采样恢复算法[J]. 计算机辅助设计与图形学学报, 2010, 22(11):1874-1879
Shang Fei, Du Hui-qian, Jia Yun-de. Compressive sampling image recovery with structure features and approximate l_0 norm [J]. Journal of Computer-Aided Design & Computer Graphics, 2012, 24(1): 14-28

[4] 李然,干宗良,朱秀昌. 基于 PCA 硬阈值收缩的平滑投影 Landweber 图像压缩感知重构[J]. 中国图像图形学报, 2013, 18(5): 504-514
Li Ran, Gan Zong-liang, Zhu Xiu-chang. Smoothed projected

landweber image compressed sensing reconstruction using hard thresholding based on principal components analysis[J]. Journal of Image and Graphics, 2013, 18(5): 504-514

[5] 季云云,杨震. 脉冲噪声环境下高斯稀疏源贝叶斯压缩感知重构[J]. 电子学报, 2013, 41(2): 363-370
Ji Yun-yun, Yang Zhen. Bayesian compressed sensing for gaussian sparse signals in the presence of impulsive noise[J]. ACTA Electronic SINICA, 2013, 41(2): 363-370

[6] 胡文瑾,刘仲民,李战明. 一种改进的小波域图像修复算法[J]. 计算机科学, 2014, 41(5): 299-303
Hu Wen-jing, Liu Zhong-min, Li Zhan-ming. Improved Algorithm for Image Inpainting in Wavelet Domains[J]. Computer Science, 2014, 41(5): 299-303

[7] Dong W, Yang X, Shi G. Compressive sensing via reweighted TV and nonlocal sparsity regularization[J]. Electronics Letters, 2013, 49(3): 184-186

[8] Hu Y, Jacob M. Higher degree total variation (HDTV) regularization for image recovery[J]. IEEE Transactions on Image Processing, 2012, 21(5): 2559-2571

[9] 费选,韦志辉,肖亮,等. 优化加权 TV 的复合正则化压缩感知图像重建[J]. 中国图象图形学报, 2014, 19(2): 211-218
Fei Xuan, Wei Zhi-hui, Xiao Liang, et al. Compound regularized compressed sensing image reconstruction based on optimal reweighted TV[J]. Journal of Image and Graphics, 2014, 19(2): 211-218

[10] Zhang J, Liu S H, Xiong R Q, et al. Improved total variation based image compressive sensing recovery by nonlocal regularization[C]//Proc of IEEE International Symposium on Circuits and Systems. Los Alamitos; IEEE Computer Society Press, 2013: 2836-2839

[11] 袁红星,吴少群,朱仁祥,等. 融合对象性和视觉显著度的单目图像 2D 转 3D[J]. 中国图象图形学报, 2013, 18(11): 1478-1485
Yuan Hong-xing, Wu Shao-qun, Zhu Ren-xiang, et al. Single-view image 2D-to-3D conversion based on objectness and visual saliency[J]. Journal of Image and Graphics, 2013, 18(11): 1478-1485

[12] Hawe S, Kleinsteuber M, Diepold K. Dense disparity maps from sparse disparity measurements[C]//Proc of IEEE International Conference on Computer Vision. Los Alamitos; IEEE Computer Society Press, 2011: 2126-2133

[13] Levin A, Lischinski D, Weiss Y. A closed-form solution to natural image matting[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2008, 30(2): 228-242

[14] Zhuo S J, Sim T. Defocus map estimation from a single image [J]. Pattern Recognition, 2011, 44(9): 1852-1858

[15] Vosters L, Haan G D. Efficient and stable sparse-to-dense conversion for automatic 2-D to 3-D conversion. IEEE Transactions on Circuits and Systems for Video Technology, 2013, 23(3): 373-386

[16] Saad Y. Iterative methods for sparse linear systems (2nd ed) [M]. Philadelphia, PA; Society for Industrial and Applied Mathematics, 2003: 1-10

[17] Wu H, Song Z, Yao J, et al. Stereo matching based on support points propagation[C]//Proc of IEEE International Conference on Information Science and Technology. Los Alamitos; IEEE

Computer Society Press, 2012; 732-736

- [18] Huang J, Schonfeld D. A novel particle filtering framework for 2D-to-3D conversion from a monoscopic 2D image sequence[C]// Proc of IEEE Conference on Visual Communications and Image Processing. Los Alamitos; IEEE Computer Society Press, 2012; 1-6
- [19] Ranftl R, Gehrig S, Pock T, et al. Pushing the limits of stereo using variational stereo estimation[C]// Proc of IEEE Intelligent Vehicles Symposium. Los Alamitos; IEEE Computer Society Press, 2012; 401-407
- [20] Ferstl D, Reinbacher C, Ranftl R. Image guided depth upsampling using anisotropic total generalized variation// Proc of IEEE International Conference on Computer Vision. Los Alamitos; IEEE Computer Society Press, 2013; 1-8
- [21] Rockafellar R T. Convex analysis[M]. Princeton, NJ; Princeton University Press, 1997; 1-20
- [22] Bredies K, Kunisch K, Pock T. Total generalized variation[J]. SIAM Journal on Imaging Sciences, 2010, 3(3): 492-526
- [23] Chambolle A, Pock T. A first-order primal-dual algorithm for convex problems with applications to imaging[J]. Journal of Mathematical Imaging and Vision, 2011, 40(1): 120-145
- [24] Boyd S, Vandenberghe L. Convex optimization[M]. Cambridge: Cambridge University Press, 2004; 1-10
- [25] Pock T, Chambolle A. Diagonal preconditioning for first order primal-dual algorithms in convex optimization[C] // Proc of IEEE International Conference on Computer Vision. Los Alamitos; IEEE Computer Society Press, 2011; 1762-1769
- [26] Cao X, Li Z, Dai Q H. Semi-automatic 2D-to-3D conversion using disparity propagation[J]. IEEE Transactions on Broadcasting, 2011, 57(2): 491-499

(上接第 294 页)

参考文献

- [1] 许嘉璐. 现状和设想—试论中文信息处理与现代汉语研究[J]. 中文信息学报, 2001, 15(2): 1-8
Xu Jia-lu. The State-of-the-Art and the Related Strategic Considerations—On the Studies of Chinese Information Processing and Contemporary Chinese Language[J]. Journal of Chinese Information Processing, 2001, 15(2): 1-8
- [2] 刘迁, 贾惠波. 中文信息处理中自动分词技术的研究与展望[J]. 计算机工程与应用, 2006(3): 175-177
Liu Qian, Jia Hui-bo. A View of Chinese Word Automatic Segmentation Research in the Chinese Information Disposal[J]. Computer Engineering and Applications, 2006(3): 175-177
- [3] 黄昌宁, 赵海. 中文分词十年回顾[J]. 中文信息学报, 2007(3): 8-18
Huang Chang-ning, Zhao Hai. Chinese Word Segmentation: A Decade Review[J]. Journal of Chinese Information Processing, 2007(3): 8-18
- [4] 李艳翠, 孙静, 周国栋, 等. 基于清华汉语树库的复句关系词识别与分类研究[J]. 北京大学学报, 2013(12)
Li Yan-cui, Sun Jing, Zhou Guo-dong, et al. Complex Sentence Relative Recognition and Classification Based on Tsinghua Chinese Treebank[J]. Acta Scientiarum Naturalium Universitatis Pekinensis, 2013(12)
- [5] 郭艳华, 周昌乐. 自然语言理解研究综述[J]. 杭州电子工业学院学报, 2005, 20(1): 58-65
Guo Yan-hua, Zhou Chang-le. Natural Language Understanding Research Review[J]. Journal of Hangzhou Institute of Electronic Engineering, 2005, 20(1): 58-65
- [6] 鲁松, 宋柔. 汉英机器翻译中描述型复句的关系识别与处理[J]. 软件学报, 2001, 12(1): 83-93
Lu Song, Song Rou. Distinction and Treatment of the Internal Relation of Descriptive Complex Sentences in Chinese-English Machine Translation[J]. Journal of Software, 2001, 12(1): 83-93
- [7] 鲁松, 白硕. 汉语多重关系复句的关系层次分析[J]. 软件学报, 2001, 12(7): 987-995
Lu Song, Bai Shuo. Parsing the Logical Embedded Complex Sentences in Chinese[J]. Journal of Software, 2001, 12(7): 987-995
- [8] 张文东, 易铁虎. 利用潜在语义分析和关联规则挖掘构造同义与关联词集[J]. 计算机工程与科学, 2007(1): 103-104, 116
Zhang Wen-dong, Yi Yi-hu. To Construct the Set of Synonyms and Association Words Using Latent Semantic Analysis and the Mining of Association Rules[J]. Computer Engineering & Science, 2007(1): 103-104, 116
- [9] 姚双云. 复句关系标记搭配研究[M]. 武汉: 华中师范大学出版社, 2008
Yao Shuang-yun. Research on Relation Markers Collocation in Chinese Complex Sentences[M]. Wuhan: Central China Normal University Press, 2008
- [10] 胡金柱, 吴峰文, 等. 汉语复句关系词库的建设及其利用[J]. 语言科学, 2010, 9(2): 133-142
Hu Jin-zhu, Wu Feng-wen, et al. Establishment and Exploitation of Relationship Marked Corpus for Chinese Complex Sentences[J]. Linguistic Sciences, 2010, 9(2): 133-142
- [11] 胡金柱, 陈江曼, 杨进才, 等. 基于规则的连用关系标记的自动标识研究[J]. 计算机科学, 2012, 39(7): 190-194
Hu Jin-zhu, Chen Jiang-man, Yang Jin-cai, et al. Research on Auto-identifying of Adjoining Relation Markers Based on Rule[J]. Computer Science, 2012, 39(7): 190-194
- [12] Xu Y, Zhang F. Using SVM to construct a Chinese dependency parser[J]. Journal of Zhejiang University Science A, 2006, 7(2): 199-203
- [13] 高维君, 姚天顺, 黎邦洋, 等. 机器学习在汉语关联词语识别中的应用[J]. 中文信息学报, 2000, 14(3): 1-8
Gao Wei-jun, Yao Tian-shun, Li Bang-yang, et al. Applying Machine Learning to Identify Chinese Discourse Markers[J]. Journal of Chinese Information Processing, 2000, 14(3): 1-8
- [14] 宋锐, 林鸿飞, 常富洋. 中文比较句识别及比较关系抽取[J]. 中文信息学报, 2009, 23(2): 102-106
Song Rui, Lin Hong-fei, Chang Fu-yang. Chinese Comparative Sentences Identification and Comparative Relations Extraction[J]. Journal of Chinese Information Processing, 2009, 23(2): 102-106