

FRFCM 聚类与深度优化的 RGBD 场景流计算

张聪炫^{1,2}, 裴刘继¹, 陈震¹, 黎明¹, 江少锋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: 针对现有 RGBD 场景流计算模型在复杂场景、非刚性运动和运动遮挡等情况下易产生场景过度平滑和运动边缘模糊的问题, 提出一种基于 FRFCM (Fast and Robust Fuzzy C-Means) 聚类与深度优化的 RGBD 场景流计算方法. 首先以图像序列连续帧间光流信息为基准, 利用 FRFCM 聚类算法对输入图像进行初始分割, 然后根据深度图像的运动边缘信息优化初始分割结果, 提取高置信度的运动分层信息. 最后设计基于图像分割的 RGBD 场景流能量函数, 采用金字塔变形策略计算精确的场景流结果. 分别采用 Middlebury 和 MPI-Sintel 数据库所提供的测试图像集对本文方法和现有的 RGBD 场景流算法进行综合对比分析, 实验结果表明本文方法相对于其他方法具有更好的场景流估计精度和鲁棒性, 有效改善了场景过度平滑和运动边缘模糊问题.

关键词: RGBD 场景流; FRFCM 聚类; 深度信息; 过度平滑; 边缘模糊

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2020)07-1380-07

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2020.07.018

RGBD Scene Flow Estimation Based on FRFCM Clustering and Depth Optimization

ZHANG Cong-xuan^{1,2}, PEI Liu-ji¹, CHEN Zhen¹, LI Ming¹, JIANG Shao-feng¹

(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 address the issues of scene over-smoothing and motion edge-blurring caused by the existing RGBD scene flow methods under complex scenes, non-rigid movement and motion occlusions, this paper proposes a RGBD scene flow method based on FRFCM (Fast and Robust Fuzzy C-Means) clustering and depth optimization. First, the optical flow information from the consecutive frames is marked as the benchmark and the FRFCM clustering approach is utilized to obtain the initial segmentation of the input image sequences. Second, according to the motion edge information of the depth image, we further optimize the initial segmentation to extract the high-confidence hierarchical motion information. Finally, an energy function of RGBD scene flow based on image segmentation is designed, and the pyramid warping strategy is adopted to compute the scene flow field. We employ the test sets of Middlebury and MPI-Sintel databases to conduct a comparison experiment between the proposed method and the existing RGBD scene flow methods. The experimental results indicate that the proposed method has better accuracy and robustness of scene flow estimation, especially when dealing with the issues of scene over-smoothing and motion edge-blurring.

Key words: RGBD scene flow; FRFCM clustering; depth information; over-smoothing; edge-blurring

1 引言

场景流是空间场景或目标运动形成的三维运动矢

量, 其不仅体现了目标与场景的运动趋势, 也包含了丰富的三维结构信息. 因此, 3D 场景流计算技术是计算机视觉与图像处理领域的研究热点, 研究成果被广泛应

收稿日期: 2019-07-01; 修回日期: 2020-04-17; 责任编辑: 李勇锋

项目基金: 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. 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); 中国博士后科学基金 (No. 2019M650894)

用于无人驾驶、智能交通检测以及医学图像处理等领域^[1,2].

1999年,Vedula等人^[3]首次提出场景流的概念,并通过将光流约束条件拓展到三维空间,进而推导出由光流计算稠密场景流的基本模型.自Vedula等人提出3D场景流的基本理论与计算框架后,各种新颖的RGBD图像序列3D场景流计算模型不断涌现.

针对深度传感技术的配准问题,Gottfried等人^[4]首次提出基于Kinect相机的RGBD图像序列场景流估计模型,该模型通过设计惩罚函数以抑制深度图像中的异常值,有效地改善了场景流估计的鲁棒性.针对非刚性运动模式场景流估计问题,Yamaguchi等人^[5]基于分段刚性场景流模型,并利用半全局匹配算法进一步提高场景流估计的可靠性.针对图像中不同运动层场景流计算的准确性问题,Sun等人^[6]提出基于深度分层的RGBD场景流估计模型,通过检索不同深度层的三维刚性运动以计算场景流结果,但该方法在深度差异不明显或复杂结构区域的计算效果往往表现不佳.针对该问题,Golyanik等人^[7]通过采用图像分割算法在深度图像中对场景进行分割,并利用非线性最小二乘法将各分段刚性变化映射至深度图像的不同区域,能够较好地克服了场景流估计的边界模糊问题.

针对现有场景流计算方法在复杂场景、非刚性运动和运动遮挡等情况下易产生场景过度平滑和运动边缘模糊的问题,本文提出一种基于FRFCM聚类和深度优化的RGBD场景流计算方法,实验结果表明本文方法具有较高的场景流计算精度和较好的鲁棒性,能够有效克服由运动遮挡、大位移和复杂场景导致的运动模糊和过度平滑现象.

2 基于FRFCM与深度优化的图像分割

2.1 基于FRFCM聚类的光流图像分割

为减少图像噪声对分割结果的影响,本文首先引入基于局部空间信息的形态重建:

$$R^e(f) = R_{R^e(\varepsilon(f))}^e(\delta(R_f^e(\varepsilon(f)))) \quad (1)$$

式(1)中, f 表示原始图像, R_f^e 和 R_f^e 分别表示形态扩张重建和形态侵蚀重建, δ 和 ε 均表示像素扩张.同时,为保证图像局部细节的稳定性,本文通过模糊聚类对图像序列进行分割,以提取具有相似运动分布的像素点集合,其目标函数可公式化如下:

$$J_m = \sum_{l=1}^q \sum_{k=1}^c \gamma_l \mathbf{u}_{kl}^m \|\xi_l - \mathbf{v}_k\|^2 \quad (2)$$

式(2)中, q 和 c 分别表示聚类中心数量和图像中灰度级数量, γ_l 表示灰度值为 l 的像素点数量, \mathbf{u}_{kl} 表示图像灰度 l 相对于第 k 个聚类中心 \mathbf{v}_k 的模糊隶属度, m

表示模糊参数, ξ_l 表示像素灰度值.其中,分割结果由分区矩阵 \mathbf{u}_{kl} 和聚类中心 \mathbf{v}_k 共同决定,其数学表达式可写作如下:

$$\mathbf{u}_{kl} = \frac{\|\xi_l - \mathbf{v}_k\|^{\frac{-2}{(m-1)}}}{\sum_{j=1}^c \|\xi_l - \mathbf{v}_j\|^{\frac{-2}{(m-1)}}}, \quad \mathbf{v}_k = \frac{\sum_{l=1}^q \gamma_l \mathbf{u}_{kl}^m \xi_l}{\sum_{l=1}^q \gamma_l \mathbf{u}_{kl}^m} \quad (3)$$

由式(3)迭代计算 \mathbf{u}_{kl} 和 \mathbf{v}_k 即可获得最终的分区矩阵 $\mathbf{U}' = [\mathbf{u}_{kl}]^{c \times N}$,其矩阵值的大小表示图像中各像素点隶属不同聚类中心的概率,进而可提取到更贴合运动边界的初始图像分割结果.

2.2 基于深度信息的优化分割

相比于可见光图像,深度图像中目标或场景表面像素点通常具有相同或相近的深度值,因此深度图像中不同运动层的深度值存在显著区别.图1(a)和图1(b)分别展示了Alley_1参考帧及其对应的深度视差值.从图中可以看出,深度图像具有目标边界轮廓清晰和结构简单等优势.因此,本文将深度信息作为约束条件,以解决初始分割结果中不同目标边界和目标内部区域的过度分割问题.

假设初始分割结果中第 k 层像素点 \mathbf{x} 的深度值与其所属分割层的平均深度值间的差值 $\Delta_k(\mathbf{x})$:

$$\Delta_k(\mathbf{x}) = |D(\mathbf{x}) - \frac{1}{N_k} \sum_{\tilde{\mathbf{x}} \in \Omega_k} D(\tilde{\mathbf{x}})| \quad (4)$$

式(4)中, $D(\mathbf{x})$ 和 $\frac{1}{N_k} \sum_{\tilde{\mathbf{x}} \in \Omega_k} D(\tilde{\mathbf{x}})$ 分别表示像素点 \mathbf{x} 的深度值和深度平均值,其中 N_k 是第 k 分割层中所有像素点的数量.通过设定分割阈值 Λ ,使得当 $\Delta_k(\mathbf{x}) > \Lambda$ 时则该像素被判定为误分割点.因此,通过提取所有被标记的误分割像素,分别计算它们与各分割层深度平均值间的差值,并将其归类到深度差值最小的分割层,以获得经深度信息优化后的最终分割图像.图1(c)和图1(d)分别展示了Alley_1图像序列的初始分割结果和深度约束优化后的分割结果,从图中可以看出,经深度信息优化后,初始分割图像中目标与背景边缘和目标内部区域的过度分割现象得到明显改善.




图1 基于深度约束的图像分割结果

3 基于 FRFCM 聚类与深度优化的场景流模型

3.1 基于图像分割的场景流运动模型

针对复杂结构场景下 RGBD 场景流估计易产生边缘模糊的问题,本文将全局运动分解为水平、垂直和深度方向等独立运动:

$$\begin{cases} \mathbf{u}_{ik}^R(\mathbf{p}) = f_x \frac{X_2}{Z_2} + c_x - x \\ \mathbf{v}_{ik}^R(\mathbf{p}) = f_y \frac{Y_2}{Z_2} + c_y - y \\ \mathbf{w}_{ik}^R(\mathbf{p}) = Z_w - Z \end{cases} \quad (5)$$

式(5)中, $(c_x, c_y)^T$ 是相机坐标系原点, f_x 和 f_y 分别表示相机水平和垂直方向的焦距, $(x, y)^T$ 和 $(X_2, Y_2, Z_2)^T$ 分别表示像素点 \mathbf{p} 在第一帧中的二维坐标和第二帧中的三维坐标, Z 和 Z_w 分别表示像素点 \mathbf{p} 的深度值和由双线性插值计算的深度值.

假设连续两帧图像序列中位于相同分割层的对应像素点坐标集合为 \mathbf{A}_i 和 \mathbf{B}_i , 通过利用 Horn 四元数法计算各层的旋转矩阵 \mathbf{R} 和平移矩阵 $\boldsymbol{\tau}$:

$$\begin{aligned} E(\mathbf{R}, \boldsymbol{\tau}) &= \min \sum_{\Omega} (\mathbf{R} \cdot \mathbf{A}_i + \boldsymbol{\tau} - \mathbf{B}_i)^2 \\ \text{s. t. } & i \in (1, 2, 3, \dots, k) \end{aligned} \quad (6)$$

结合式(5)和式(6),即可求得水平、垂直和深度方向的场景运动模型:

$$\begin{cases} E_u(\mathbf{u}_{ik}, \boldsymbol{\psi}_{ik}) = \sum_{\mathbf{x}} \eta_b(\mathbf{u}_{ik}(\mathbf{x}) - \mathbf{u}_{ik}^R(\mathbf{x})) \\ \quad + \sum_{\mathbf{x}' \in N_x} \eta_u((\mathbf{u}_{ik}(\mathbf{x}) - \mathbf{u}_{ik}^R(\mathbf{x})) \\ \quad - (\mathbf{u}_{ik}(\mathbf{x}') - \mathbf{u}_{ik}^R(\mathbf{x}')))) \\ E_v(\mathbf{v}_{ik}, \boldsymbol{\psi}_{ik}) = \sum_{\mathbf{x}} \eta_b(\mathbf{v}_{ik}(\mathbf{x}) - \mathbf{v}_{ik}^R(\mathbf{x})) \\ \quad + \sum_{\mathbf{x}' \in N_x} \eta_u((\mathbf{v}_{ik}(\mathbf{x}) - \mathbf{v}_{ik}^R(\mathbf{x})) \\ \quad - (\mathbf{v}_{ik}(\mathbf{x}') - \mathbf{v}_{ik}^R(\mathbf{x}')))) \\ E_w(\mathbf{w}_{ik}, \boldsymbol{\psi}_{ik}) = \sum_{\mathbf{x}} \eta_b(\mathbf{w}_{ik}(\mathbf{x}) - \mathbf{w}_{ik}^R(\mathbf{x})) \\ \quad + \sum_{\mathbf{x}' \in N_x} \eta_u((\mathbf{w}_{ik}(\mathbf{x}) - \mathbf{w}_{ik}^R(\mathbf{x})) \\ \quad - (\mathbf{w}_{ik}(\mathbf{x}') - \mathbf{w}_{ik}^R(\mathbf{x}')))) \end{cases} \quad (7)$$

式(7)中, η_b 和 η_u 均是鲁棒惩罚函数, $\boldsymbol{\psi}_{ik} = (\mathbf{R}_{ik}, \boldsymbol{\tau}_{ik})^T$ 表示第 t 帧中第 k 分割层像素的变换矩阵, $\mathbf{x}' = (x', y')^T$ 表示以像素点 \mathbf{x} 为中心的局部邻域 N_x 内的任意像素.

3.2 基于图像分割的分层场景流能量函数

根据 FRFCM 聚类 and 深度信息优化的图像分割结果,则图像分层函数可定义如下:

$$s_{ik}(\mathbf{x}) = \begin{cases} g_{ik}(\mathbf{x}) \prod_{k'=1}^{K-1} (1 - g_{ik'}(\mathbf{x})), & 1 \leq k < K \\ \prod_{k'=1}^{K-1} (1 - g_{ik'}(\mathbf{x})), & k = K \end{cases} \quad (8)$$

式(8)中, g_{ik} 表示第 t 帧图像序列中第 k 分割层的支撑函数,该函数值由分割结果决定.若 $g_{ik} \geq 0$, 则像素点 \mathbf{x} 属于该分割层,否则该像素点属于其他分割层.

考虑连续两帧 RGB 图像序列 I_1 和 I_2 及其对应的深度图像 D_1 和 D_2 , 本文首先将图像场景分割为多个相互独立的运动层,继而估计每层的场景运动.假设各分割层中所有像素点应具有相同的运动参数矩阵,则分层场景流估计能量函数可表示如下:

$$\begin{aligned} E(\mathbf{u}, \mathbf{v}, \mathbf{w}, g, \boldsymbol{\psi}) &= \sum_{t=1}^{T-1} \left\{ \sum_{k=1}^K \{ E_{\text{data}}(\mathbf{u}_{ik}, \mathbf{v}_{ik}, g_{ik}) \right. \\ &\quad + \lambda_d E_{\text{depth}}(\mathbf{u}_{ik}, \mathbf{v}_{ik}, \mathbf{w}_{ik}) \\ &\quad + \lambda_m \{ E_u(\mathbf{u}_{ik}, \boldsymbol{\psi}_{ik}) + E_v(\mathbf{v}_{ik}, \boldsymbol{\psi}_{ik}) \\ &\quad + E_w(\mathbf{w}_{ik}, \boldsymbol{\psi}_{ik}) \} \} \\ &\quad + \sum_{k=1}^{K-1} \lambda_t E_t(g_{ik}, g_{t+1,k}, \mathbf{u}_{ik}, \mathbf{v}_{ik}) \} \\ &\quad + \sum_{t=1}^T \sum_{k=1}^{K-1} \lambda_g E_g(g_{ik}) \end{aligned} \quad (9)$$

式(9)中, λ_d , λ_m , λ_t 和 λ_g 均表示权重系数.其中, E_{data} 和 E_{depth} 分别是 RGB 数据项和深度数据项:

$$\begin{cases} E_{\text{data}}(\mathbf{u}_{ik}, \mathbf{v}_{ik}, g_{ik}) = \sum_{\mathbf{x}} s_{ik}(\mathbf{x}) \rho_c (\bar{I}_t(\mathbf{x}) - \bar{I}_{t+1}(\tilde{\mathbf{x}})) \\ E_{\text{depth}}(\mathbf{u}_{ik}, \mathbf{v}_{ik}, \mathbf{w}_{ik}) = \sum_{\mathbf{x}} s_{ik}(\mathbf{x}) \rho_d (z_{t+1}(\tilde{\mathbf{x}}) \\ \quad - z_t(\mathbf{x}) - w_{ik}(\mathbf{x})) \end{cases} \quad (10)$$

式(10)中, $\bar{I}(\mathbf{x})$ 和 $z(\mathbf{x})$ 分别表示像素点 \mathbf{x} 的亮度特征和深度值, ρ_c 和 ρ_d 均是鲁棒参数.当分层函数 $s_{ik}(\mathbf{x}) = 1$ 时,则像素点 \mathbf{x} 属于该分割层,数据项有效,否则该像素点属于其他分割层,数据项无效,能够有效改善该分割层的场景流估计.

此外,式(9)中 $E_t(g_t, g_{t+1}, \mathbf{u}_{ik}, \mathbf{v}_{ik})$ 和 $E_g(g_{ik})$ 记为时间约束项和空间约束项:

$$\begin{cases} E_t(g_{ik}, g_{t+1,k}, \mathbf{u}_{ik}, \mathbf{v}_{ik}) = \sum_{\mathbf{x}} (g_{ik}(\mathbf{x}) - g_{t+1,k}(\tilde{\mathbf{x}}))^2 \\ E_g(g_{ik}) = \sum_{\mathbf{x}} \sum_{\mathbf{x}' \in N_x} (g_{ik}(\mathbf{x}) - g_{ik}(\mathbf{x}')) \omega_{\mathbf{x}} \end{cases} \quad (11)$$

式(11)中, $\tilde{\mathbf{x}} = (x + \mathbf{u}_{ik}(\mathbf{x}), y + \mathbf{v}_{ik}(\mathbf{x}))$ 表示 t 时刻第 k 层像素点 \mathbf{x} 在 $t+1$ 时刻的对应像素点, $(\mathbf{u}_{ik}, \mathbf{v}_{ik})^T$ 表示 RGB 光流场,高斯函数 $\omega_{\mathbf{x}}$ 用于避免图像序列中出现局部亮度突变现象.

4 实验与分析

4.1 评估指标

本文采用异常值百分比 (Fl-all)、均方根误差 (RMS) 和平均角误差 (AAE) 等指标对场景流估计结果进行评测:

$$\text{Fl-all} = \frac{P_3}{N} \times 100\% \quad (12)$$

$$\text{RMS} = \sqrt{\frac{1}{N} \sum_x ((u_{ct}(\mathbf{x}) - u(\mathbf{x}))^2 + (v_{ct}(\mathbf{x}) - v(\mathbf{x}))^2)} \quad (13)$$

$$\text{AAE} = \frac{1}{N} \cdot \sum_x \left(\frac{1 + u_{ct}(\mathbf{x}) \times u(\mathbf{x}) + v_{ct}(\mathbf{x}) \times v(\mathbf{x})}{\sqrt{u_{ct}(\mathbf{x})^2 + v_{ct}(\mathbf{x})^2 + 1} \cdot \sqrt{u(\mathbf{x})^2 + v(\mathbf{x})^2 + 1}} \right) \quad (14)$$

上式中, $(u(\mathbf{x}), v(\mathbf{x}))^T$ 和 $(u_{ct}(\mathbf{x}), v_{ct}(\mathbf{x}))^T$ 分别表示像素点 $\mathbf{x} = (x, y)^T$ 处的估计光流和光流真实值, P_3 表示光流端点误差大于 3 个像素的像素点个数, N 是整幅图像序列中所有像素点的数量。

4.2 参数设置

为验证深度图像中不同分割层数的设置对本文方法估计精度的影响, 本文以 MPI-Sintel 数据库中的 Mountain_1 和 Market_2 图像序列为例。给定深度图像分

割层数 $K \in \{3, 5, 7, 9\}$, 对该两组图像序列进行定量分析。从图 2 可以看出, 随着深度图像分割层的增加, Fl-all 指标均呈现下降趋势, 说明适当地增加深度图像中的分割层数能够提高场景流计算精度。

同时, 为更直观地观测本文方法在不同分割层数下的光流结果, 本文同样对上述两组图像序列进行了定性对比。从图 3 中可以看出, 随着分割层数的增加, 光流估计结果中不同目标与背景的边界更精细, 但当分割层数过大时, 则会导致本文方法的计算复杂度增大, 降低计算效率。因此, 综合考虑场景流计算精度和效率, 本文设置深度图像中的分割层数为 9。

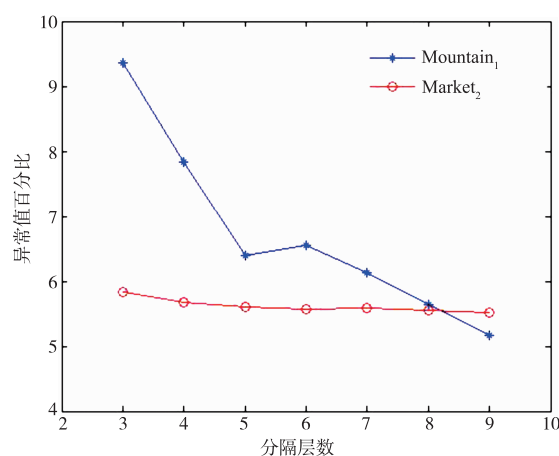


图2 不同分割层数对场景流估计精度的影响



图3 不同分割层数场景流估计结果

4.3 消融实验

为验证本文提出的 FRFCM 聚类和深度优化策略对 RGBD 场景流计算精度的影响, 本文采用 Middlebury 数据库中的 Cones 和 Teddy 图像序列对本文方法与去除 FRFCM 聚类和深度优化策略后的两种消融模型进行了综合实验对比与分析。

表 1 不同模型 RGBD 场景流估计误差对比

对比模型	Cones		Teddy	
	RMS	AAE	RMS	AAE
本文模型	0.09	0.18	0.11	0.12
无 FRFCM 聚类模型	0.12	0.19	0.48	0.24
无深度优化模型	0.15	0.20	0.12	0.13

从表 1 中可以看出, 在 RMS 和 AAE 等指标方面, 相对于无 FRFCM 聚类和无深度优化的两种消融模型, 本文模型的场景流误差最低, 说明了本文所提的 FRF-

CM 聚类和深度优化策略均能够进一步提高场景流估计的准确性。图 4 展示了不同模型在 Cones 和 Teddy 图像序列上的场景流估计结果。从图中可以看出, 无 FRFCM 聚类和无深度优化模型的场景流估计结果中不同物体边界和复杂场景处均出现了明显的边缘模糊现象, 而本文方法通过利用 FRFCM 聚类和深度优化策略能够较好地克服该现象, 具有良好的边缘保护特性。

4.4 Middlebury 数据集实验

首先采用 Middlebury 数据库中标准测试图像序列对本文方法与 LODF^[8]、Classic++^[9] 和 Sun-RGBD^[6] 等对比方法进行评测。图 5 分别展示了 Middlebury 测试图像序列的参考帧、深度真实值和各对比方法场景流估计结果。从图中可以看出, LODF 算法采用的局部匹配策略难以克服遮挡区域的匹配歧义性问题; Classic++ 算法由于基于加权中值滤波计算策略易产生严重的过度平滑现象; Sun-RGBD 算法采用的深度图像分层计算

策略易导致边缘模糊问题;相比于其他算法,本文方法整体场景流估计效果更好.

为更直观地展示本文方法的边缘保护作用,图 6 分别展示了图 5 中 Art 和 Laundry 图像序列中红色标记部分的局部放大图. 从图中可以看出, LODF 和

Classic ++ 算法均存在较明显的过度平滑问题;Sun-RG-BD 算法在图像弱边缘区域包含较多的错误匹配点;本文方法具有更高的场景流估计精度,且在目标与背景边缘区域具有更好的边缘保护效果.

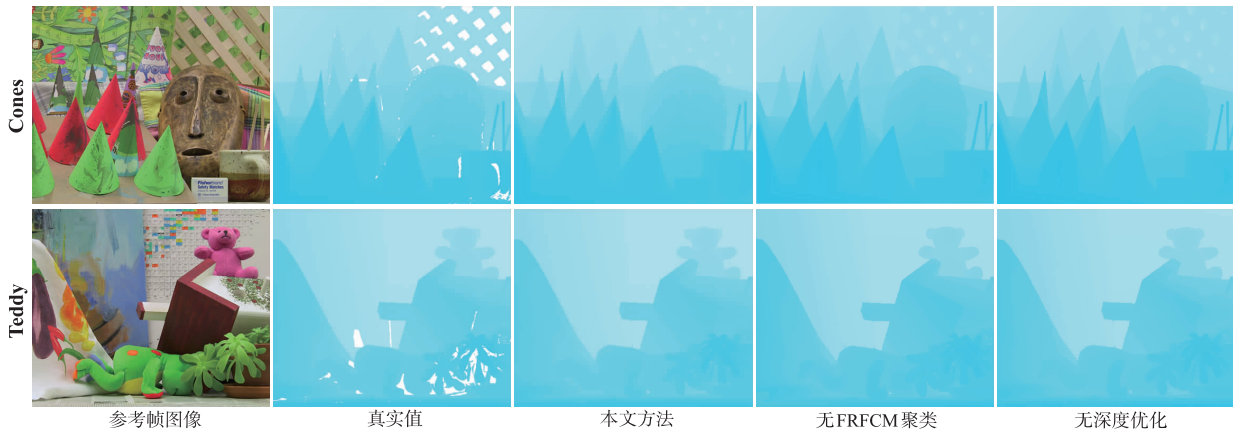


图4 不同模型场景流估计结果





图5 Middlebury图像序列场景流估计结果

表 2 分别列出了本文方法与各对比方法的 RMS 和 AAE 误差统计. 从表中可以看出,相比于其他对比方

法,本文方法在大部分图像序列上均具有较强的竞争力,尤其在 Art、Laundry、Reindeer 和 Dolls 等图像序列上



彩色图 深度图 LDOF Classic++ Sun-RGBD 本文方法 真实值

图6 标签区域局部放大图

RMS 和 AAE 误差指标最低,说明本文方法针对复杂边缘结构场景具有较好的场景流估计精度.

表 2 Middlebury 图像序列场景流估计误差对比

图像序列	LDOF[8]	Classic ++ [9]	Sun-RGBD[6]	本文方法
	RMS/AAE	RMS/AAE	RMS/AAE	RMS/AAE
Art	11.96/1.53	8.39/1.14	1.69/0.77	0.97/0.22
Laundry	22.91/2.41	46.08/34.29	0.39/0.18	0.26/0.16
Moebius	12.39/1.09	18.86/5.80	0.17/0.13	0.17/0.13
Reindeer	62.07/1.62	7.07/0.44	4.24/0.54	3.08/0.43
Books	10.82/2.02	23.75/15.10	0.13/0.15	0.13/0.16
Dolls	10.67/1.02	18.28/0.55	0.53/0.38	0.40/0.20
平均误差	37.38/1.62	20.40/9.55	1.19/0.36	0.83/0.22

表 3 MPI-Sintel 图像序列场景流估计误差对比

对比方法	平均误差	图像序列					
		Alley_1	Bandage_1	Bamboo_1	Bamboo_2	Ambush_5	Temple_2
LDOF[8]	12.32	2.75	7.15	3.58	5.52	40.70	14.24
Classic ++ [9]	11.10	2.22	5.44	2.82	5.25	36.49	14.38
Sun-RGBD[6]	25.60	9.84	37.71	1.90	4.72	71.79	27.61
OSF[10]	14.98	7.33	18.40	4.04	4.86	44.70	10.52
PRSF[11]	10.01	2.05	4.72	2.86	5.05	32.79	12.61
SceneFField[12]	16.37	5.94	3.82	6.11	5.84	46.92	29.58
本文方法	9.78	1.32	3.99	2.00	3.91	34.60	12.88

4.5 MPI-Sintel 数据集实验

为验证本文方法在大位移、非刚性形变和运动遮挡等困难场景下场景流估计的效果,本文采用 MPI-Sintel 数据库中提供的测试图像序列对本文方法与 LDOF、Classic ++、Sun-RGBD、OSF^[10]、PRSF^[11] 和 SceneFFields^[12] 等对比方法进行量化评测.表 3 分别列出了本文方法与各对比方法的 Fl-all 误差统计.从表中可以看出,本文方法平均误差最小,尤其在 Alley_1、Bandage_1、Bamboo_2 和 Temple_2 等图像序列上均取得了较准确的估计结果,说明本文方法针对运动遮挡、大位移和复杂结构等复杂场景同样具有较好的场景流估计效果.

5 结论

本文提出一种基于 FRFCM 聚类与深度优化的 RGBD 场景流计算方法.首先采用 FRFCM 聚类和深度信息对 RGB 图像序列中运动场景进行分割与优化,然后将图像帧间光流作为先验信息,并计算不同分割层的初始场景流,最后利用图像金字塔分层策略估计最终场景流.实验结果表明本文方法具有较好的场景流计算精度和鲁棒性,尤其针对运动遮挡、大位移和复杂边缘等困难场景具有良好的边缘保护效果.

参考文献

[1] Ke R, Li Z, Tang J, et al. Real-time traffic flow parameter

estimation from UAV video based on ensemble classifier and optical flow [J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 20(1): 54-64.

[2] 张聪炫, 陈震, 汪明润, 等. 基于光流与 Delaunay 三角网格的图像序列运动遮挡检测 [J]. 电子学报, 2018, 46(2): 479-485.

ZHANG Cong-xuan, CHEN Zhen, WANG Ming-run, et al. Motion occlusion detecting from image sequence based on optical flow and Delaunay triangulation [J]. Acta Electronica Sinica, 2018, 46(2): 479-485. (in Chinese)

[3] Vedula S, Rander P, Collins R, et al. Three-dimensional scene flow [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(3): 475-480.

[4] Gottfried J M, Fehr J, Garbe C S, et al. Computing range flow from multi-modal Kinect data [A]. Advances in Visual Computing [C]. Berlin: Springer, 2011. 758-767.

[5] Yamaguchi K, McAllester D, Urtasun R. Efficient joint segmentation, occlusion labeling, stereo and flow estimation [A]. European Conference on Computer Vision [C]. Cham: Springer, 2014. 756-771.

[6] Sun D, Sudderth E B, Pfister H. Layered RGBD scene flow estimation [A]. IEEE Conference on Computer Vision and Pattern Recognition [C]. Boston: IEEE, 2015. 548-556.

[7] Golyanik V, Kim K, Maier R, et al. Multiframe scene flow with piecewise rigid motion [A]. IEEE International Conference on 3D Vision [C]. Qingdao: IEEE, 2017. 273

- 281.
- [8] Brox T, Malik J. Large displacement optical flow: Descriptor matching in variational motion estimation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(3): 500 - 513.
- [9] Sun D, Roth S, Black M J. A quantitative analysis of current practices in optical flow estimation and the principles behind them [J]. International Journal of Computer Vision, 2014, 106(2): 115 - 137.
- [10] Menze M, Heipke C, Geiger A. Object scene flow [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2018, 140: 60 - 76.
- [11] Vogel C, Schindler K, Roth S. 3D scene flow estimation with a piecewise rigid scene model [J]. International Journal of Computer Vision, 2015, 115(1): 1 - 28.
- [12] Schuster R, Wasenmuller O, Kusch G, et al. SceneFlow-Fields: Dense interpolation of sparse scene flow correspondences [A]. IEEE Winter Conference on Applications of Computer Vision [C]. Lake Tahoe: IEEE, 2018. 1056 - 1065.

作者简介



张聪炫 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: zcxds@163.com



裴刘继 男, 1993年7月出生于安徽宣城. 现为南昌航空大学测试与光电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: 492888191@qq.com