

基于平面拟合的事件传感器光流估计改进算法

郭爽^{1,2}, 徐江涛^{1,2*}, 高志远^{1,2}, 张磊^{1,2,3}¹天津大学微电子学院, 天津 300072;²天津市成像与感知微电子技术重点实验室, 天津 300072;³天津中德应用技术大学软件与通信学院, 天津 300350

摘要 为进一步提高事件传感器光流估计的精确度,解决平面拟合算法的拟合模型误差问题,提出一种事件传感器平面拟合光流估计改进算法。该算法采用Prim贪婪算法思想,从事件流中提取有效事件,获取最优局部邻近事件集,为后续光流估计奠定基础。同时,采用特征值算法代替传统最小二乘法,结合贪婪算法下事件集内数据的优劣排序,优化平面拟合模型的建立,提高光流估计算法的精确度。实验结果表明,相比于现有的基于平面拟合的事件传感器光流估计算法,该算法在平均端点误差和平均角度误差两个指标上分别约提升20%和11%,有效提升了事件传感器光流估计算法的精确度。

关键词 机器视觉; 光流估计; 平面拟合; Prim算法; 特征值法; 随机抽样一致算法

中图分类号 TP391

文献标志码 A

DOI: 10.3788/LOP222029

Optical Flow Estimation Algorithm of Event Sensor
Based on Improved Plane FittingGuo Shuang^{1,2}, Xu Jiangtao^{1,2*}, Gao Zhiyuang^{1,2}, Zhang Lei^{1,2,3}¹School of Microelectronics, Tianjin University, Tianjin 300072, China;²Tianjin Key Laboratory of Imaging and Sensing Microelectronic Technology, Tianjin 300072, China;³School of Software and Communication, Tianjin Sino-German University of Applied Sciences,
Tianjin 300350, China

Abstract An improved algorithm for estimating the plane-fitting optical flow is proposed to further improve the accuracy of event sensor optical flow estimation and solve the fitting model error of the plane-fitting algorithm. The algorithm adopts the principle of the Prim greedy algorithm to extract effective events from the event flow and obtain the optimal local adjacent event set, laying the foundation for subsequent optical flow estimation. In addition, the eigenvalue algorithm is used to replace the traditional least square method, and the data ranking of the event set under the greedy algorithm is combined to optimize the plane-fitting model and improve the accuracy of the optical flow estimation algorithm. The experimental results show that compared with the existing estimation algorithm for event sensor optical flow based on plane-fitting, the algorithm improves the average endpoint error and average angle error by 20% and 11%, respectively. This study demonstrates effective improvement of the accuracy of the event sensor optical flow estimation algorithm.

Key words machine vision; optical flow estimation; plane-fitting; Prim algorithm; eigenvalue algorithm; random sample consensus algorithm

1 引言

光流估计是机器视觉的重要研究方向,在导航^[1]、定位^[2]、目标对象分割^[3]、跟踪^[4]、识别^[5]、图像配准^[6]等领域中都有重要的应用,准确及快速的光流估计是应

用于视觉任务的必然要求。事件传感器^[7-8]是一种新型图像传感器,相较于传统图像传感器,该传感器采用地址事件表达方式,仅输出动态事件,具有低延迟、低功耗、高动态范围、高时间分辨率等特性,有效解决了传统图像传感器在高速运动和极端光照条件下的运动

收稿日期: 2022-07-08; 修回日期: 2022-08-11; 录用日期: 2022-08-20; 网络首发日期: 2022-08-29

基金项目: 国家自然科学基金(62134004)、天津市科技计划项目(20YDTPJC00890)

通信作者: *xujiantao@tju.edu.cn

模糊问题,在机器视觉中有着越来越重要的应用。然而,传统的光流估计算法是依据 Lucas 等^[9]和 Horn 等^[10]的算法,基于亮度不变及邻域光流相似等假设^[11-12]逐渐改进而来的,该假设基于传统图像传感器输出的灰度帧,不能直接应用于事件传感器。近年来,越来越多面向事件传感器的光流估计算法被提出。

目前,基于事件传感器的光流估计算法可分为两类:一类算法需要依靠累积事件,通过重构图像等手段实现光流估计,其中,对比度最大化框架算法和基于神经网络架构的算法是该类的常用算法。对比度最大化框架算法^[13-15]通过评估累积事件运动补偿图像的清晰度,利用对比度最大化框架来间接完成事件的光流估计。基于神经网络架构的光流估计算法^[16-19]需要对数据集进行训练测试,通过大量数据驱动学习能力,从而实现光流估计。但是该类算法的缺点在于计算成本较高,耗时较长,针对稀疏且实时的光流估计缺乏优势。另一类算法无需依靠累积事件,可以直接处理事件数据,更适用于实时的光流估计处理,平面拟合算法是该类的典型算法。2014年, Benosman 等^[20]首次提出基于平面拟合的光流估计算法,假设事件局部为平面,基于事件传感器的高数据稀疏性和时间分辨率特性,在活跃事件表面上利用局部微分的方法,允许以微妙级精度和非常低的计算成本实现事件传感器光流估计。2015年, Brosch 等^[21]为了解决噪声对平面拟合模型精度的影响,提出一种受生物启发的高效运动滤波器,从事件流中提取有效事件,进一步提升平面拟合算法的精确度,但是该算法在后续平面拟合中仍采用传统迭代手段,通过无差别选取事件,迭代获取最优平面拟合模型,会引入一定的随机误差。2018年, Aung 等^[22]为进一步提取有效事件,提高平面拟合光流估计算法的精确度,在当前活跃事件周围 $5 \text{ pixel} \times 5 \text{ pixel}$ 范围内提取 $3 \text{ pixel} \times 3 \text{ pixel}$ 子区域进行光流估计,避免边缘方向对光流估计算法的影响,但是该算法限制区域的同时也限制了平面拟合的优越度。

目前的平面拟合光流估计算法主要通过优化迭代过程获取最优的拟合平面进行事件传感器光流估计,但是在提取有效事件、获取更优的平面拟合模型上仍可进一步改进。为此,本文利用 Prim 贪婪算法思想提取有效事件,选取最优局部邻近事件集,优化平面拟合数据集质量。同时采用特征值算法代替传统最小二乘法,优化平面拟合模型的建立,并结合随机抽样一致 (RANSAC) 算法,进一步提高事件传感器光流估计的精确度。

2 平面拟合算法基本原理

事件传感器的每个像素点具有独立的异步像素单元结构,每个像素点只响应像素强度的变化,当像素点响应的对数光强超过既定阈值时,就会产生一个事件,每个事件采用地址事件表示进行表达,即用四元

组 $e = (x, y, t, P)$ 来表征,其中, (x, y) 表示事件在像素坐标中的像素地址, t 表示事件的时间戳, $P \in \{-1, 1\}$, 表示事件的极性,即光强增加 ($P=1$) 或减少 ($P=-1$)。

不考虑事件的极性,事件传感器输出的事件流在三维 xyt 时空域内可视为一个曲面,称该曲面为活跃事件表面 (SAE)。SAE 的表达式为

$$\begin{cases} \sum_e: R^2 \rightarrow R \\ \sum_e(x, y) = t \end{cases} \quad (1)$$

将事件流视为一个曲面时,事件传感器每产生一个新事件,SAE 上将生成或更新曲面上的一个点。因此,事件传感器所产生的每一个事件都可以在对应的时间切片上找到其准确的像素空间位置,从而确定在该时间上对应的事件流,如图 1 所示,将所拟合平面通过 $ax + by + ct = d$ 表示,则局部平面 SAE 采用方程可表示为

$$\sum_e(x, y) = \begin{bmatrix} -a & -b & -d \\ c & c & c \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix}. \quad (2)$$

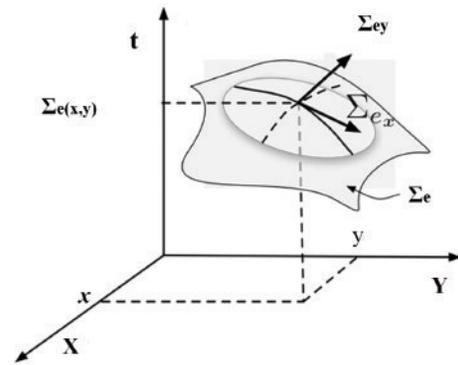


图 1 活跃事件表面的光流估计^[20]
Fig. 1 Plane-fitting optical flow estimation for SAE^[20]

因为事件传感器产生的事件流是通过时间切片确定的,而事件流所对应的时间是一个严格的空问递增函数,所以局部平面 SAE 同样为单调递增函数。因此,平面上任意一个像素点所对应的梯度都不为零,此时:

$$\frac{\partial \Sigma_e}{\partial x} = \left(\frac{\partial x}{\partial \Sigma_e} \right)^{-1} = \left(\frac{\partial x}{\partial t} \right)^{-1} = \frac{1}{v_x} = -\frac{a}{c}, \quad (3)$$

$$\frac{\partial \Sigma_e}{\partial y} = \left(\frac{\partial y}{\partial \Sigma_e} \right)^{-1} = \left(\frac{\partial y}{\partial t} \right)^{-1} = \frac{1}{v_y} = -\frac{b}{c}. \quad (4)$$

显然,SAE 的空间梯度 $\mathbf{g} = (-a/c, -b/c)$ 是对活跃事件相关的光流信息进行编码的,但其描述的是时间相对于空问的变化,在大小和单位上并不匹配,因此需要对梯度向量进行归一化,经归一化后,光流向量可表示为

$$\begin{bmatrix} v_x \\ v_y \end{bmatrix} = \frac{1}{|\mathbf{g}^2|} \mathbf{g} = \frac{-c}{a^2 + b^2} \begin{bmatrix} a \\ b \end{bmatrix}. \quad (5)$$

3 平面拟合光流估计改进算法

所提平面拟合光流估计改进算法的流程如图 2 所示。对于传入的事件流,首先对不应期的事件进行预过滤处理,文献[23]提出事件预过滤手段,通过该方法可有效提升数据流质量。其次,利用 Prim 贪婪算法选

取最优的局部邻近事件集,选取有效事件,为后续平面拟合提供更为精确的初始内点集。然后,利用特征值算法结合最优局部邻近事件集,求取光流估计的初始模型,从而提高初始模型的准确性。最后,运用 RANSAC 算法进一步提升所提算法的精确性,实现光流估计。

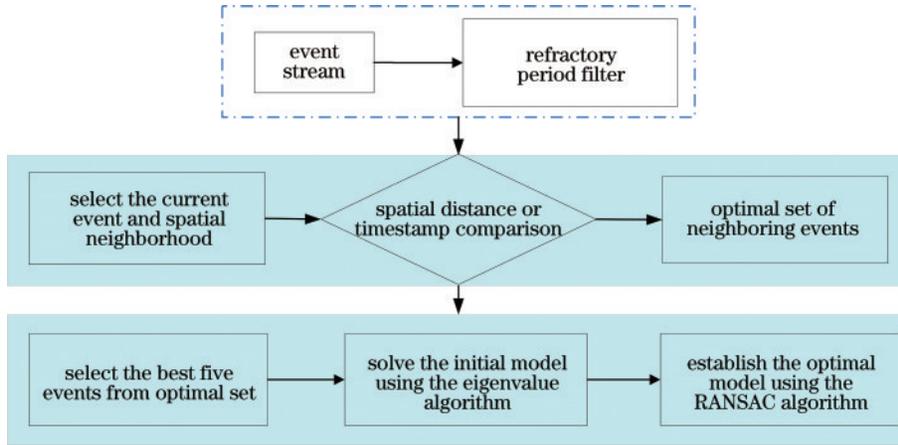


图 2 平面拟合光流估计改进算法框架

Fig. 2 Framework of improved plane-fitting optical flow estimation algorithm

3.1 有效事件提取的优化设计

对于 SAE 上的事件,除了最新触发的事件外,还可能包含过去触发的事件,甚至有些事件的产生可能完全归因于噪声。因此,选取 SAE 上的最优局部邻近事件集,提取有效事件具有很高的意义。文献[22]提出在当前活跃事件周围 $5 \text{ pixel} \times 5 \text{ pixel}$ 范围内提取 $3 \text{ pixel} \times 3 \text{ pixel}$ 子区域进行光流估计的方法,但是限制区域同样也限制了拟合的优度,且无差别选取机制同样也会带来一定误差。

最优局部邻近事件集虽然无法准确定义,但是根据局部平面拟合原理,该方法是在最新时间戳的 SAE 上进行光流估计的,在该表面上,有效事件呈现稀疏分布几乎是不可能的。根据 SAE 的性质可知,最优局部邻近事件集必然为 SAE 最新触发事件 E_n 的最邻近事件集,即假设在小区域内,其边缘为近恒速运动,那么空间位置差异最小事件便更大可能为该区域内最近发生事件,即有效事件,空间位置差异较大的事件更大可能是孤立的噪声点。针对空间距离一致的事件,时间戳差异最小事件便更大可能为有效事件,这是因为引发邻近事件的边缘和自然结构最终会在接近当前触发事件 E_n 的邻近位置及时间瞬间发生。同时,相邻事件应具有相同的极性。

对于最优局部邻近事件集 N_n 的选取准则如下:

- 1) N_n 中事件 N_n 应与当前触发事件 E_n 具有相同的极性;
- 2) N_n 中事件 N_n 应位于当前触发事件 E_n 的 $L \times L$ 邻域内;

3) N_n 中事件不包含当前触发事件 E_n ,以排除偶然误差;

4) N_n 中事件应为当前触发事件 E_n 或事件集中其他事件在 $L \times L$ 空间区域内空间位置最小差异事件集,若空间距离差异性相同,则选取与当前触发事件 E_n 时间戳差异最小事件。

根据上述准则,选定当前触发事件 E_n 为初始事件,采用 Prim 贪婪算法思想提取有效事件,求取最优局部邻近事件集,如图 3 所示,在特殊情况下,存在 4 种可能性,即当最终选取的事件为图中同种颜色事件时,此时选取的事件在空间中为共线状态,无法实现平面拟合。为解决此种情况,所选事件总数不应小于 L ,根

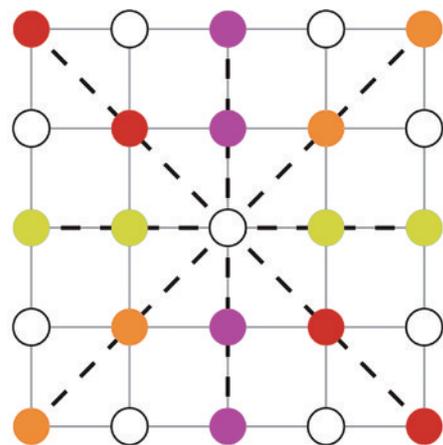


图 3 共线事件示意图

Fig. 3 Spatially collinear arrangements of events

据图 3 可知,此时所选事件必然为不共线事件,能够形成活跃事件表面,从而实现平面拟合。

3.2 平面拟合模型建立的优化设计

3.2.1 初步模型建立

利用 Prim 贪婪算法确定最优局部邻近事件集 N_n 后,利用特征值法求取光流估计的初步模型,以解决传统最小二乘法将误差全部归因到 t 轴方向的误差问题。针对最新触发事件 E_n ,在 $L \times L \times \Delta t$ 范围内进行平面拟合, L 表示以当前触发事件 E_n 为中心的空间邻域长度, Δt 为当前触发事件 E_n 的邻域时间窗。假设拟合平面的数学表达式为 $ax + by + ct = d$,此时事件流中任意一点 (x_0, y_0) 到该拟合平面的空间距离为

$$L_{\text{distance}} = \frac{|ax_0 + by_0 + ct_0 - d|}{\sqrt{a^2 + b^2 + c^2}} \quad (6)$$

由式(5)可知,光流估计与 d 的大小无关,仅与 a, b, c 的值有关,当 $a^2 + b^2 + c^2 = 1$ 时,参数 d 的绝对值表示坐标原点到该拟合平面的空间距离。根据 SAE 的性质可知,事件集 N_n 中各个事件到最佳拟合平面的距离值应被最小化。此时待优化的目标函数即邻域内任意事件到该拟合平面的空间距离以及其约束条件可以设定为

$$d_i = |ax + by + ct - d|, \quad (7)$$

$$a^2 + b^2 + c^2 = 1. \quad (8)$$

在约束条件 $a^2 + b^2 + c^2 = 1$ 的情况下,采用拉格朗日乘数法进行估计,此时对应的拉格朗日函数为

$$f = \sum_{i=1}^n [d_i^2 - \lambda(a^2 + b^2 + c^2 - 1)]. \quad (9)$$

对目标函数求取极小值,此时其对应的拉格朗日函数的偏导数值应为 0,其对应表达式如下:

$$\frac{\partial f}{\partial d_i} = 2 \sum_{i=1}^n d_i = 2 \sum_{i=1}^n |ax_i + by_i + ct_i - d| = 0, \quad (10)$$

由式(10)可得:

$$d = a \frac{1}{n} \sum_{i=1}^n x_i + b \frac{1}{n} \sum_{i=1}^n y_i + c \frac{1}{n} \sum_{i=1}^n t_i, \quad (11)$$

将式(11)代入式(7)中,此时目标函数可改写为

$$d_i = a(x_i - \hat{x}) + b(y_i - \hat{y}) + c(t_i - \hat{t}), \quad (12)$$

$$\text{式中: } \hat{x} = \frac{1}{n} \sum_{i=1}^n x_i; \hat{y} = \frac{1}{n} \sum_{i=1}^n y_i; \hat{t} = \frac{1}{n} \sum_{i=1}^n t_i$$

将式(12)代入式(9)中,此时目标函数对应的拉格朗日函数可以改写为

$$f = \sum_{i=1}^n [a(x_i - \hat{x}) + b(y_i - \hat{y}) + c(t_i - \hat{t})]^2 - \lambda(a^2 + b^2 + c^2 - 1). \quad (13)$$

为求取目标函数的极小值,对式(13)的参数 a, b, c 分别求偏导并使其为 0,此时有

$$\begin{cases} 2 \sum_{i=1}^n [a(x_i - \hat{x}) + b(y_i - \hat{y}) + c(t_i - \hat{t})](x_i - \hat{x}) = 2\lambda a \\ 2 \sum_{i=1}^n [a(x_i - \hat{x}) + b(y_i - \hat{y}) + c(t_i - \hat{t})](y_i - \hat{y}) = 2\lambda b \\ 2 \sum_{i=1}^n [a(x_i - \hat{x}) + b(y_i - \hat{y}) + c(t_i - \hat{t})](t_i - \hat{t}) = 2\lambda c \end{cases} \quad (14)$$

将式(14)写为矩阵形式:

$$\begin{bmatrix} \sum_{i=1}^n \Delta x_i \Delta x_i & \sum_{i=1}^n \Delta x_i \Delta y_i & \sum_{i=1}^n \Delta x_i \Delta t_i \\ \sum_{i=1}^n \Delta x_i \Delta y_i & \sum_{i=1}^n \Delta y_i \Delta y_i & \sum_{i=1}^n \Delta y_i \Delta t_i \\ \sum_{i=1}^n \Delta x_i \Delta t_i & \sum_{i=1}^n \Delta y_i \Delta t_i & \sum_{i=1}^n \Delta t_i \Delta t_i \end{bmatrix} \begin{bmatrix} a \\ b \\ c \end{bmatrix} = \lambda \begin{bmatrix} a \\ b \\ c \end{bmatrix}, \quad (15)$$

$$\Delta x_i = x_i - \hat{x}, \Delta y_i = y_i - \hat{y}, \Delta t_i = t_i - \hat{t}, \quad (16)$$

$$\text{设 } \mathbf{A} = \begin{bmatrix} \sum_{i=1}^n (x_i - \hat{x})(x_i - \hat{x}) & \sum_{i=1}^n (x_i - \hat{x})(y_i - \hat{y}) & \sum_{i=1}^n (x_i - \hat{x})(t_i - \hat{t}) \\ \sum_{i=1}^n (y_i - \hat{y})(x_i - \hat{x}) & \sum_{i=1}^n (y_i - \hat{y})(y_i - \hat{y}) & \sum_{i=1}^n (y_i - \hat{y})(t_i - \hat{t}) \\ \sum_{i=1}^n (t_i - \hat{t})(x_i - \hat{x}) & \sum_{i=1}^n (t_i - \hat{t})(y_i - \hat{y}) & \sum_{i=1}^n (t_i - \hat{t})(t_i - \hat{t}) \end{bmatrix}, \mathbf{x} = (a \quad b \quad c)^T, \text{则式(15)可改写为}$$

$$\mathbf{Ax} = \lambda \mathbf{x}. \quad (17)$$

此时矩阵 \mathbf{A} 的最小特征值所对应的特征向量即为所求拟合参数 a, b, c ,根据式(2)即可求取平面拟合初步模型。

3.2.2 最优平面拟合模型建立

平面拟合光流估计算法的核心是通过迭代获取最佳的平面拟合模型进行光流估计,初步模型建立后,一般选用 RANSAC 算法进行后续的迭代处理。该算法的核心思想为假设性和随机性:假设性是指假设样本空间中既包含正确的数据,也包含一些异常数据点,即噪声;随机性是指从数据样本中随机抽取一定的样本数据进行初始模型估计,并通过不断迭代,最终选取内点率最高的模型作为最终模型,根据大数据定律可以近似得到正确结果。因此,平面拟合迭代的改进与优化对光流估计的精确度至关重要,只有当平面拟合的初始模型足够精确时,后续通过迭代排除异常数据点才具有重要的意义。但是,随机抽取的初始样本点可能是内点,也可能是离群点,若初始样本引入的是离群点,便会引入误差,造成初始模型偏离正确值,那么后续进行迭代操作时,有效事件就会被认为是离群值而被排除在外,造成事件传感器光流估计精确度的明显降低。

在第 2.1 节中,已经求出了最优局部邻近事件集,为生成更精确的结果,初始选取的内点集应该是最优局部邻近事件集 N_n 中最优的 5 个事件(选取当前触发事件 E_n 的空间邻域长度 $L=5$),从而减少传统 RANSAC 算法随机抽取初始样本所引入的误差,以生成更加精确的初步模型,保证通过迭代生成的最优平面拟合模型的准确性。

所提最优局部平面拟合光流估计模型算法步骤如下:

1) 选取最优局部邻近事件集 N_n 中最优的 5 个事件作为初始内点集合 S_0 ,采用特征值算法求解初始模型 M_0 ;

2) 将最优局部邻近事件集 N_n 中的其余事件代入初始模型中,并计算此时的拟合误差,若误差值小于设定阈值,则加入内点集 S_0 ;

3) 若当前内点集 S_0 中所含事件数大于当前最优内点集 S_{pre} ,则更新 $S_{pre} = S_0$;

4) 重复迭代上述步骤,内点数最多的 S_{pre} 所得到的模型即为最优局部平面拟合光流估计模型。

4 实验与结果分析

4.1 数据集及实验设计

采用 DVSFLOW16 数据集及 `rgb_event_lifetime` 数据集,从该公共数据集中选用斜向运动、水平运动、旋转运动的数据进行检验评估,并将所提改进算法与其他平面拟合光流估计算法进行对比验证,包括文献[20]中的传统平面拟合光流估计算法、文献[21]中的边缘降噪平面拟合光流估计算法以及文献[22]中的小区域平面拟合光流估计算法,并分别记它们为 LP_{ori} 、 LP_{rob} 和 LP_{reg} 。

4.2 评价指标

采用的评价指标为平均端点误差(E_{AEE})和平均角度误差(E_{AAE}),以直观评估光流估计算法的可行性和精确性,两个指标的值越小,代表算法光流估计精确度越高。

E_{AEE} 对真实光流与估计光流的平均位置差进行估计,其计算公式如下:

$$E_{AEE} = \frac{1}{n} \sum_{i=1}^n \text{dist}(\mathbf{u}_i, \mathbf{v}_i) = \frac{1}{n} \sum_{i=1}^n \sqrt{(v_{ix} - u_{ix})^2 + (v_{iy} - u_{iy})^2}, \quad (18)$$

式中: $\mathbf{v}_i = (v_{ix}, v_{iy})$ 表示第 i 个事件所对应的估计光流向量; $\mathbf{u}_i = (u_{ix}, u_{iy})$ 表示第 i 个事件所对应的真实光流向量;光流向量的距离 dist 采用欧氏距离公式进行计算。

E_{AAE} 对真实光流与估计光流的平均角度进行估计,其计算公式如下:

$$E_{AAE} = \frac{1}{n} \sum_{i=1}^n \arccos \frac{v_{ix}u_{ix} + v_{iy}u_{iy}}{|\mathbf{v}_i| |\mathbf{u}_i|}. \quad (19)$$

4.3 定性实验分析

图 4 为所提算法与文献[22]算法在斜向运动上的实验对比结果,该实验为 1 ms 及 30 ms 积累条件下棋盘格子的斜向运动实验。在 1 ms 条件下,由于产生的事件并不是足够多,此时通过选取有效事件建立更精确的平面拟合光流估计初始模型尤为重要,可以为后续迭代提供更好的基础。从图 4 可以观察到,相比于文献[22]算法,所提算法处理的图像结构更清晰。在 30 ms 条件下,此时已经积累足够多的事件进行光流估计,可以观察到,所提算法在优化有效事件提取及初步模型建立后,通过 RANSAC 算法不断迭代优化,光流估计的精确度得到了有效提升。图 5 和图 6 为所提算法与另外 3 种算法在水平运动加菲猫序列与旋转运动磁盘序列上的对比结果。所提算法与文献[22]算法相较于另外两种算法,通过提取有效事件,在光流估计精确度上均有一定程度提升。但是,文献[22]算法通过限制区域提取事件,会造成区域内的事件无差别选择,仍会带来一定误差。所提算法通过优化有效事件的提取,利用贪婪算法思想选取最优局部邻近事件集,优化了有效事件的提取。在加菲猫序列中,所提算法在手部细节上表现更优秀,而旋转磁盘序列,所提算法的光流估计结果同样更精确。

4.4 定量精确度分析

为检验所提算法精确度,参照文献[20]设计一组定量实验。以直流电动机驱动垂直于地面的白色磁盘上的红线以恒定角速度做旋转运动,其平面示意图如图 7 所示。由平面图分析可知,其真实光流方向投影到水平方向的角度范围值应为 $[-\pi/2, \pi/2]$ 。图 8 显

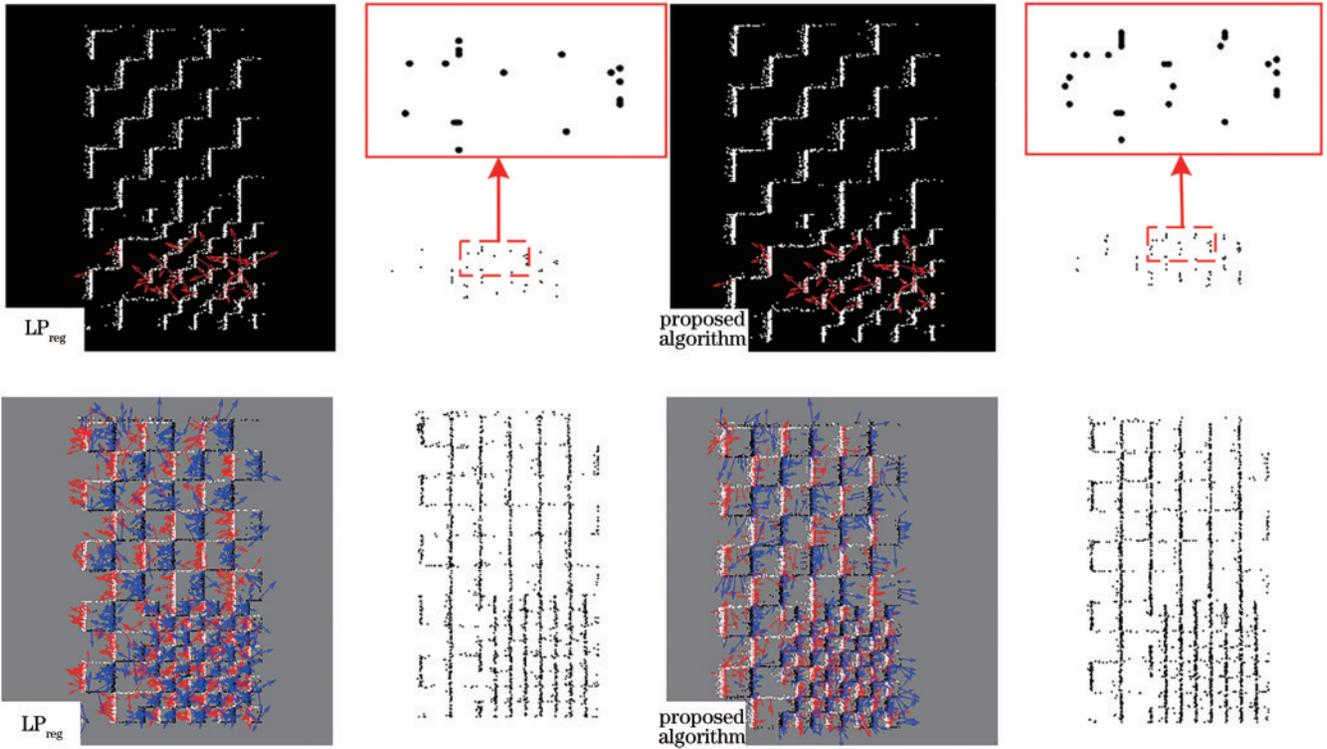


图 4 斜向运动棋盘格子实验
Fig. 4 Oblique motion checkerboard experiment

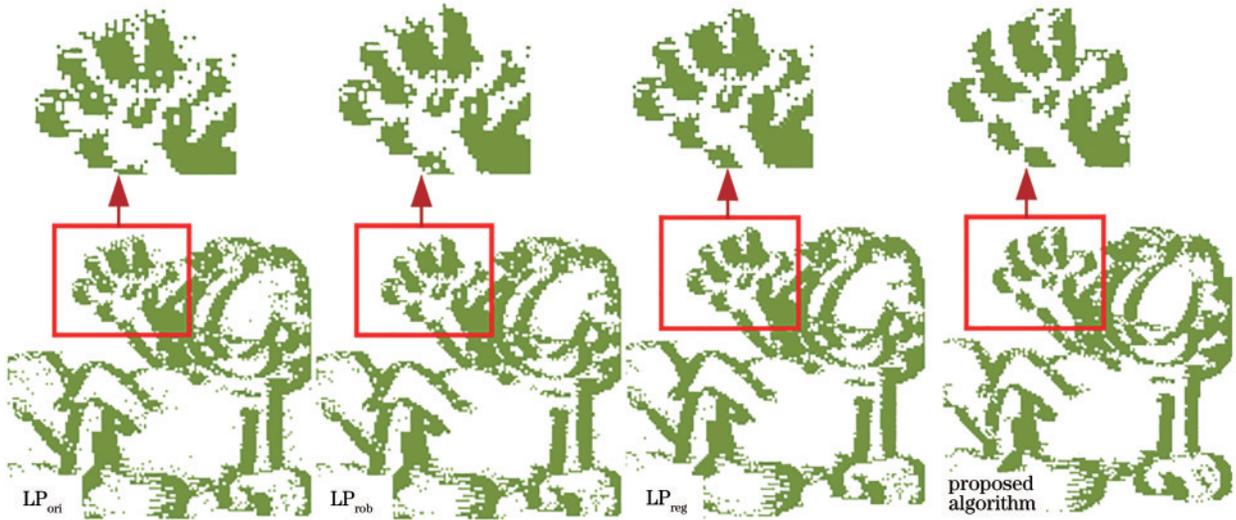


图 5 水平运动加菲猫实验
Fig. 5 Horizontal motion Garfield experiment

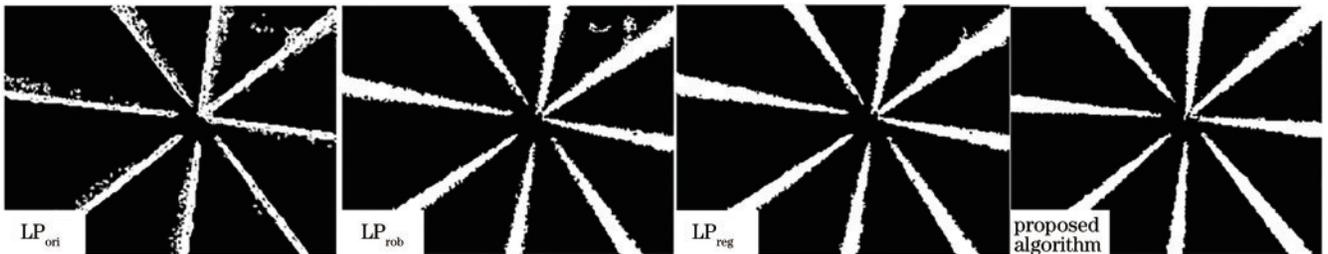


图 6 旋转运动磁盘实验
Fig. 6 Rotating motion disk experiment

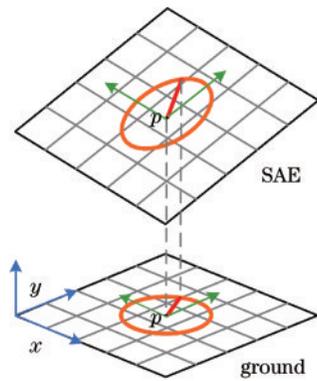


图 7 旋转运动红线实验

Fig. 7 Rotating motion red bar experiment

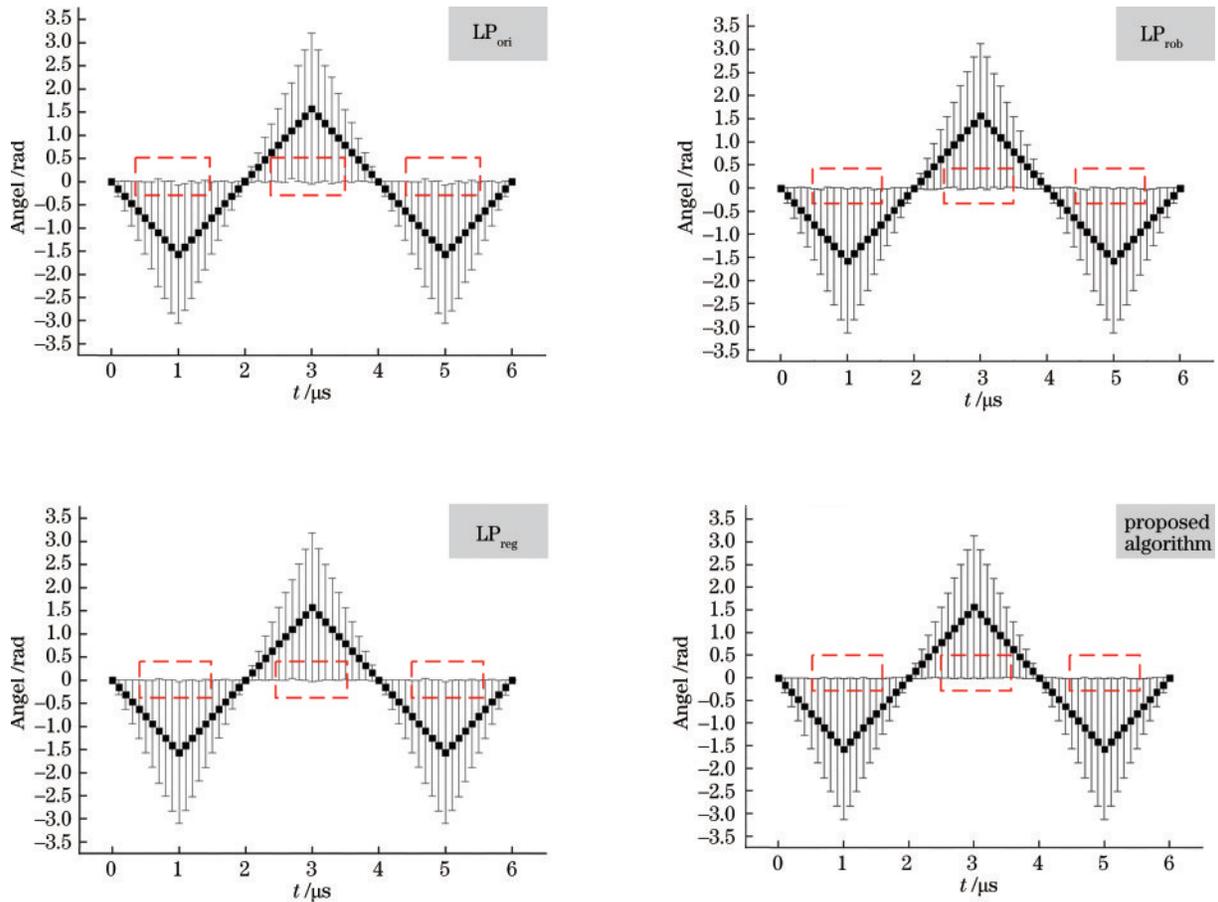


图 8 旋转运动角度误差对比

Fig. 8 Comparison of true value and estimated rotation angle

表 1 不同算法光流估计评估

Table 1 Evaluation of optical flow estimations for different algorithms

Algorithm	$E_{AEE} / \%$			$E_{AAE} / (^\circ)$			Processing time per event / μs
	chessboard	Garfield	disk	chessboard	Garfield	disk	
LP _{ori}	75.29	89.51	59.87	13.37	25.68	28.03	4.37
LP _{rob}	56.87	68.03	46.73	10.22	19.75	21.88	0.83
LP _{reg}	38.13	46.26	31.22	8.12	15.61	17.32	0.61
Proposed algorithm	30.27	37.05	25.14	7.14	13.76	15.38	0.67

示了 4 种算法下,光流估计值与水平真实方向值的角度误差对比,其中,黑色点为真实值,从中间误差线可以直观观察到,所提算法通过优化有效事件的提取和平面拟合模型的建立,使得光流估计的精确度得到了进一步提升。

为了更精确评估不同算法的精确度,利用光流估计评价指标进行进一步对比,结果如表 1 所示。可以看出,所提算法具有更好的精确性,在 E_{AEE} 与 E_{AAE} 上都有一定幅度提升。相较于表现较好的文献[22]算法,所提算法在 E_{AEE} 精确度上约提升 20%,在 E_{AAE} 精确度上约提升 11%。

5 结 论

提出一种基于平面拟合的事件传感器光流估计改进算法,利用 Prim 贪婪算法获取最优局部邻近事件集,优化有效事件的提取,提升数据流质量。同时结合特征值算法与 RANSAC 算法,进一步优化平面拟合模型的建立。实验结果表明,相较于目前已有的平面拟合算法,该算法光流估计的精确度得到了有效的提升。目前,该算法仅进行了软件实现,在后续研究中,会将该算法进行硬件实现,同时结合图像数据采集系统搭建完整的硬件体系,从而提升该算法的实时应用性。

参 考 文 献

- [1] 徐陈,周怡君,罗晨. 动态场景下基于光流和实例分割的视觉 SLAM 方法[J]. 光学学报, 2022, 42(14): 1415002.
Xu C, Zhou Y J, Luo C. Visual SLAM method based on optical flow and instance segmentation for dynamic scenes[J]. Acta Optica Sinica, 2022, 42(14): 1415002.
- [2] 钱琦,白庭铭,闭云峰,等. 基于点线特征的单目同步定位与建图初始化方法[J]. 光学学报, 2021, 41(12): 1215002.
Qian Q, Bai T M, Bi Y F, et al. Monocular simultaneous localization and mapping initialization method based on point and line features[J]. Acta Optica Sinica, 2021, 41(12): 1215002.
- [3] 郭清达,全燕鸣. 采用空间投影的深度图像点云分割[J]. 光学学报, 2020, 40(18): 1815001.
Guo Q D, Quan Y M. Depth image point cloud segmentation using spatial projection[J]. Acta Optica Sinica, 2020, 40(18): 1815001.
- [4] Gehrig D, Rebecq H, Gallego G, et al. Asynchronous, photometric feature tracking using events and frames[M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11216: 766-781.
- [5] Amir A, Taba B, Berg D, et al. A low power, fully event-based gesture recognition system[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 7388-7397.
- [6] 陈庆,周海洋,余飞鸿. 基于改进光流法的显微图像拼接算法研究[J]. 激光与光电子学进展, 2021, 58(24): 2410001.
Chen Q, Zhou H Y, Yu F H. Microscopic image mosaic algorithm using improved optical flow method[J]. Laser & Optoelectronics Progress, 2021, 58(24): 2410001.
- [7] Lichtsteiner P, Posch C, Delbruck T. A 128 × 128 120 dB 15 μs latency asynchronous temporal contrast vision sensor[J]. IEEE Journal of Solid-State Circuits, 2008, 43(2): 566-576.
- [8] Brandli C, Berner R, Yang M H, et al. A 240 × 180 130 dB 3 μs latency global shutter spatiotemporal vision sensor[J]. IEEE Journal of Solid-State Circuits, 2014, 49(10): 2333-2341.
- [9] Lucas B D, Kanade T. An iterative image registration technique with an application to stereo vision[C]//IJCAI'81: Proceedings of the 7th International Joint Conference on Artificial Intelligence-Volume 2, August 24-28, 1981, Vancouver, BC, Canada. New York: ACM Press, 1981: 674-679.
- [10] Horn B K P, Schunck B G. Determining optical flow[J]. Artificial Intelligence, 1981, 17(1/2/3): 185-203.
- [11] Yu J J, Harley A W, Derpanis K G. Back to basics: unsupervised learning of optical flow via brightness constancy and motion smoothness[M]//Hua G, Jégou H. Computer vision-ECCV 2016 workshops. Lecture notes in computer science. Cham: Springer, 2016, 9915: 3-10.
- [12] Yin Z C, Shi J P. GeoNet: unsupervised learning of dense depth, optical flow and camera pose[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 1983-1992.
- [13] Gallego G, Rebecq H, Scaramuzza D. A unifying contrast maximization framework for event cameras, with applications to motion, depth, and optical flow estimation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 3867-3876.
- [14] Stoffregen T, Kleeman L. Event cameras, contrast maximization and reward functions: an analysis[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 12292-12300.
- [15] Liu D Q, Parra Á, Chin T J. Globally optimal contrast maximisation for event-based motion estimation[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 6348-6357.
- [16] Zhu A Z, Yuan L Z, Chaney K, et al. EV-FlowNet: self-supervised optical flow estimation for event-based cameras[C]//Robotics: Science and Systems XIV, Robotics: Science and Systems Foundation, June 26-30, 2018, Pittsburgh, Pennsylvania, USA. [S. l.: s. n.], 2018: 26-30.
- [17] Zhu A Z, Yuan L Z, Chaney K, et al. Live demonstration: unsupervised event-based learning of optical flow, depth and egomotion[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), June 16-17, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 1694.
- [18] Paredes-Vallés F, Scheper K Y W, de Croon G C H E. Unsupervised learning of a hierarchical spiking neural network for optical flow estimation: from events to global motion perception[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2051-2064.
- [19] Chaney K, Panagopoulou A, Lee C, et al. Self-

- supervised optical flow with spiking neural networks and event based cameras[C]//2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), September 27-October 1, 2021, Prague, Czech Republic. New York: IEEE Press, 2021: 5892-5899.
- [20] Benosman R, Clercq C, Lagorce X, et al. Event-based visual flow[J]. IEEE Transactions on Neural Networks and Learning Systems, 2014, 25(2): 407-417.
- [21] Brosch T, Tschechne S, Neumann H. On event-based optical flow detection[J]. Frontiers in Neuroscience, 2015, 9: 137.
- [22] Aung M T, Teo R, Orchard G. Event-based plane-fitting optical flow for dynamic vision sensors in FPGA [C]//2018 IEEE International Symposium on Circuits and Systems, May 27-30, 2018, Florence, Italy. New York: IEEE Press, 2018.
- [23] Czech D, Orchard G. Evaluating noise filtering for event-based asynchronous change detection image sensors[C]//2016 6th IEEE International Conference on Biomedical Robotics and Biomechatronics (BioRob), June 26-29, 2016, Singapore. New York: IEEE Press, 2016: 19-24.