

基于双阈值多层滤波的事件流去噪算法研究

苗好田¹ 李 凯¹
MIAO Haotian LI Kai

摘 要

事件相机是一种新型的成像设备，能够生成高速异步事件流数据。与传统相机相比，事件相机具有高时间分辨率、低延迟和高动态范围等优点，但拍摄的事件流数据稀疏杂乱，需要适用的处理方法。基于此，通过挖掘事件流数据的时空相关性，设置三层滤波逐步过滤噪声，实现数据预处理，为后续目标检测等提供基础。通过对事件相机特点和噪声种类的分析，采用基于事件数量和时间密度双重限制的动态切片方法，并针对不同噪声类型采用相应的滤波算法，以去除噪声并尽可能保留事件信息。最后通过实验验证了算法的去噪效果，噪声去除率较好，为事件相机的应用提供了数据基础，后续还将继续研究去噪算法的自适应参数选择和普适性，优化算法流程。

关键词

事件相机；点云去噪；时空相关性；邻域密度；多层滤波

doi: 10.3969/j.issn.1672-9528.2025.05.012

0 引言

事件相机是一种根据生物视网膜成像特点研发出来的能够生成异步事件流数据的相机，生成的数据包括像素的坐标以及亮度的极性变化和时间戳。具有高分辨率、低延迟、低功耗、高动态范围的特点，在多领域中具有显著优势^[1]。在机器人感知和控制中，可以突破传统相机的限制，实现对快速移动物体的感知和响应，降低感知系统的功耗，并在复杂光照条件下提高感知能力。在无人机应用中，文献[2]实现了高精度障碍物避障功能，延迟仅为3.5 ms，成功率超过90%。事件相机还有更大的潜力。在3D重建领域，预计将推动3D重建技术的发展^[3]。Li等人^[4]提出了E2DSNeRF，使用高动态范围和低延迟的事件相机代替传统的RGB-D相机作为NeRF的输入，提高了稀疏视图的渲染质量，消除了模糊和鬼影。基于传统相机语义分割，面对动态光照和高速移动目标的运动模糊等问题，文献[5]提出了EVISS（事件图像语义分割），以推动该领域技术的发展。弥补了SLAM领域中普通相机的不足。曾思康^[6]在航天器姿态测量中使用了动态视觉传感器。文献[7]指出在实际应用场景中，传统的帧基相机常受到运动模糊、过曝和欠曝等因素的限制^[8]，这些因素主要源于剧烈运动、光照条件变化以及平台功耗限制。相比之下，事件相机则不易受上述因素影响。

Delbruck^[9]提出了一种滤波方法，在一个固定的时间邻域内积累时间，检索每个事件周围相邻的八个像素位置是

否也发生了事件，若未发生则当前点被标定为噪声去除。Benosman等人^[10]提出的活动事件表面（SAE），这一方法保留了最近事件的时间信息，但忽略了事件的时空历史关联性。Mueggler等人^[11]基于活动事件（SAE）构建了活动事件滤波面（FSAE）。对于每个到达的事件，只有当其时间戳与相同像素上邻近事件的时间戳差异大于阈值时，事件才会传递。Baldwin等人^[12]进一步改进了FSAE算法，提出了初始事件曲面的概念。初始事件是与边缘到达的确切时间一致的第一个到达事件，初始事件曲面只传递初始事件，可以快速提取物体特征。周晓丽等人^[13]提出了一种基于邻域密度的时空相关性事件流滤波（NDSEF），以帧的形式在时间维度累积事件并计算邻域密度，达到降噪的目的，又提出了基于NDSEF的级联滤波，通过增加像素窗口累积实现算法的高度优化。闫昌达等人^[14]利用物体运动边缘的时间和空间连续性进行降噪处理，进而利用事件数量和时间阈值双限制的方式累积事件得到事件“帧”，达到可视化、便于应用的目的。林凯滨等人^[15]提出一种新的基于密度排序的事件降尺度算法，通过分析事件流中的时空邻域关系计算时空关联密度，并根据时空关联密度进行密度排序，从而减少冗余事件，降低计算资源的消耗。Fang等人^[16]提出了基于神经网络的事件降噪算法，建立了异步事件去噪神经网络AEDNet，以保持数据的异步性，并建立了嵌入式特征提取模块以保持时空相关性。

本研究利用事件数据的噪声种类设置三层滤波，根据噪声的特点进行去除，例如热像素噪声在时间轴上持续出现，

1. 沈阳理工大学 辽宁沈阳 110159

在某个像素点异常活跃,使用热像素滤波去除热像素噪声,背景噪声中部分密集的物体,可用双维度滤波去除。分布的离散随机噪声点,使用邻域密度滤波去除。首先使用热像素噪声滤波去除热像素噪声避免对后续滤波产生影响,再根据时间间隔、事件密度对点云进行动态切片,使数据降噪更加精细化准确化。

1 事件相机

仿生神经视觉传感器,也称为事件相机,是一种模仿生物视觉系统的动态视觉传感器。与传统帧相机在视觉信息获取方式不同。现有的、经过验证的计算机视觉技术不能直接应用于这些数据。因此,需要研究新的算法来处理事件数据。

1.1 事件相机的特点

独立像素响应即每个像素对亮度变化(对数光电流 $L=\log(I)$) 独立响应。当亮度变化超过设定的阈值 $\pm C$ 时,会在像素位置 x_k, y_k 和时间 t_k 触发事件 $e_k=(x_k, y_k, p_k, t)$; 高时间分辨率即事件相机的模拟电路能够快速监测亮度变化,并通过数字方式以 1 MHz 的时钟频率标记事件时间,使得相机能够以微秒级的时间分辨率捕捉快速运动,避免帧相机常见的运动模糊问题;具有低延时、高动态范围、低功耗等特点。

1.2 事件相机中的噪声种类

噪声产生和成像设备内外关系可以分为外部噪声和内部噪声。外部噪声由外部环境干扰产生,例如电磁波干扰、大气放电等;内部噪声由设备或系统的内部环境引起,如光或电的基本特性、电气和机械运动、设备材料以及内部设备和电路产生的噪声^[17]。

(1) 背景噪声 (Background Noise): 当某个像素产生了一个并非由事件源引起的事件时,就被认为是背景噪声。

(2) 热像素噪声: 产生原因可能是像素损坏或充放电装置存在问题导致高频事件。

(3) 散粒噪声: 在昏暗场景下,由事件相机像素感光器和变化检测器电路的波动随机超过像素事件阈值而产生。

(4) 事件抖动噪声: 事件相机输出事件的时间戳可能存在一定的抖动,即事件发生的实际时间与记录的时间戳之间存在偏差。

(5) 量化噪声: 事件相机将像素亮度变化转换为离散的事件输出时,由于量化过程的存在,会导致量化噪声。

(6) 固定模式噪声 (FPN): 不同像素对相同光照变化的响应可能存在差异,导致在没有实际场景变化的情况下,像素输出的事件存在固定的偏差。

(7) 阈值波动噪声: 事件产生的原理是某像素亮度的变化达到某个阈值 c ,但 c 并非常量,而是亮度的恒定百分比,并且会因当前亮度而变化。

2 事件流的降噪算法

事件相机在捕获场景亮度变化时会产生多种噪声,噪声的存在严重影响后续特征提取算法的精度。为减少这些噪声的影响,本研究设计一个多重滤波降噪算法。

与常规图像不同,事件相机的数据流是连续的,不包含静态图像中所有像素的信息。传统处理方法通常依据固定的时间间隔将事件流分割成帧。然而,由于事件相机的异步触发机制,亮度变化剧烈的时段会生成大量密集的数据,而亮度变化平缓的时段则产生较少且稀疏的数据,其中包含大量噪声,有效信息相对较少。若仅依据固定时间间隔进行数据切片,可能导致某些时段数据过于密集,而其他时段数据过于稀疏;若仅依据固定事件数量,则可能包含过时信息,无法准确反映当前场景状态。因此,本文使用了一种基于事件数量和时间密度双重限制的动态切片方法,即在达到一定的事件密度时进行切片,若未达到该密度但超过时间限制,也不再积累事件。在理想情况下,仅场景中移动的部分会引起亮度变化并生成事件,尤其是在物体边缘轮廓处。然而,实际应用中,环境因素和传感器温度变化等因素会导致噪声的产生。因此,本文采用了去噪算法来消除这些噪声,目的是最大化还原出接近理想状态的事件信息。考虑到噪声的特点,本文通过三种不同的滤波来辅助判断该事件是否为噪声。使用热像素噪声滤波 (Hot Pixel Noise Filter) 针对热像素噪声,在单个像素位置长时间连续出现,在读取数据时添加计数器用于统计每个像素位置点出现的次数,当长时间连续出现在同一位置时判定为热像素噪声并去除。

定义一个计数器函数 $C: R^2 \rightarrow N$, 将每个 (x, y) 位置映射到一个非负整数,表示该位置出现事件的次数。公式表示为:

$$C(x, y) = |\{e \in E | e.x = x \wedge e.y = y\}| \quad (1)$$

式中: $|\cdot|$ 表示集合中元素的数量。

定义一个噪声检测函数 $N: R^2 \rightarrow \{T, F\}$, 将每个 (x, y) 出现的次数映射到一个布尔值,表示该位置是否被判定为噪声。如果 $C(x, y)$ 小于阈值 P_L , 则 (x, y) 位置被认为是噪声。公式表示为:

$$N(x, y) = \begin{cases} T & \text{if } C(x, y) < P_L \\ F & \end{cases} \quad (2)$$

式中: P_L 是判定为噪声的事件次数阈值。

对传输进来的事件流数据进行坐标转化,因事件数据只有 x 坐标和 y 坐标,所以可以将时间戳赋给 z 坐标,制成三维时序图处理。在时空密度中进行切段,在一定时间内,若事件数量达到一定密度则进行切段,同时更新时间戳进入下一个切段,若事件数量稀疏则按照时间进行切段,同时更新时间戳进入下一个切段。公式表示为:

$$S(E, T, D, \Delta t) = \{E_i | E_i \subseteq E, \forall e \in E_i, e.t \in [t_0, t_1]\} \quad (3)$$

式中: E 为所有事件的集合; T 为切段的时间范围; D 为事件密度; Δt 为当前的时间长度。 $C(T)$ 用于统计 T 时间内的事

件数量。切段规则为：

如果在时间窗口 T 内，事件计数 $C(T) \geq D$ ，则：

$$t_1 = t_0 + \Delta t \quad (4)$$

如果在时间窗口 T 内，事件计数 $C(T) < D$ ，则：

$$t_1 = t_0 + T \quad (5)$$

根据目标事件密度大，在时间上空间上都是邻近的，而噪声表示某个时间点，某个位置上的异常，可以对事件流段上的点做统计使用双维度滤波(double dimensional filter)处理，在小的误差范围 P 内，这个点 p 的 x 坐标附近有很多点则判定为目标事件，若点数很少则判定为噪声。同理对 y 坐标也进行如此操作，可以尽可能多地保留事件信息。

对于 x 坐标方向：

$$N_x = |\{p' \in P \mid |p' \cdot x - p \cdot x| \leq \alpha\}| \quad (6)$$

对于 y 坐标方向：

$$N_y = |\{p' \in P \mid |p' \cdot y - p \cdot y| \leq \beta\}| \quad (7)$$

如图 1 所示，若 x 维度密度阈值为 5， y 维度密度阈值为 4，点 M 在 x 误差范围内有 5 个邻居大于阈值符合条件，在 y 误差范围内有 2 个邻居小于阈值不符合条件，两个条件只要符合一个就判断它为目标事件，所以点 M 保留，同理遍历其他点进行筛选。




图 1 滤波原理图

因上一层滤波为保留更多的信息，此时仍会有部分边缘噪声，可缩小事件流的时间尺度增大数据密度，在空间范围内再进行一次滤波，计算每个点在一定范围的邻居点数量，密度大的保留。

$$N(p_i, R) = |\{p_i \in P \mid \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2} \leq R\}| \quad (8)$$

具体流程如下：

输入：事件数据 E ，切片时间范围 T ，事件密度 D 。

输出：事件帧 frame。

(1) 读取事件流 E ，根据式 (1) 去除热像素噪声。

(2) 按照式 (3) 对事件流切段。

(3) 在 xy 维度积累点判断 $G(p) = \text{噪声}$ if $(N_x < \lambda) \wedge (N_y < \mu)$

(4) If $N(p, R) < M$, remove p_i 。

(5) 将事件帧 frame 输出。

3 实验与分析

为验证算法的去噪效果，本文使用 Prophesee 事件相机拍摄的卫星仿真数据进行实验和测试，数据总时长 1 066 627 μs ，事件点数量 1 853 263 个，并使用开源软件 CloudCompare 对数据进行可视化展示。图 2 为截取的某段事件流的可视时序图，白色点为目标事件点，黑色点为背景噪声，白色线条为热像素噪声，经过热像素噪声滤波之后如图 2 中过滤后图像所示，白色方框中线条状的热像素噪声已被去除。之后再对黑色的背景噪声进行过滤。使用双维度滤波器在 xy 维度上积累事件点的数量，密集的判定为目标事件，稀疏的判定为离群点噪声。再投影到平面上进一步增加事件数据的密度，利用邻域密度滤波去除离散的点达到如图 3 的效果。




图 2 事件流时序图




图 3 正面去噪对比图

针对不同滤波组合对噪声的滤除效果进行数据展示分析。由表 1 可看出此数据中热像素噪声数量庞大，90% 以上的事件数据是噪声且为热像素噪声，可见热像素滤波是很有必要的。而剩下的事件数据中噪声和目标事件比例约为 50%，使用双维度滤波和邻域密度滤波处理可使得噪声去除率达 99% 以上。由图 4（1 层滤波为热像素噪声滤波，2 层滤波为双维度滤波，3 层滤波为邻域密度滤波）可看出在总体上，3 种滤波去除噪声点的数量都很多，对目标事件的失

误过滤数量较少，能够保留较多的事件信息。由图 5 可看出，在分段处理事件切片时，使用双维度滤波能够去除更多的噪声，剩余的噪声较少，对于后续加快处理速度，在拍摄更短时间的数据进行处理时有较大作用。

表 1 场景 1 滤波数据表

	目标事件	噪声事件	事件总数	噪声去除率
原始数据	91 004	1 762 259	1 853 263	
滤波 1	90 823	107 462	198 285	93.90%
滤波 1 + 滤波 3	84 629	5 599	90 228	99.68%
滤波 1 + 滤波 2 + 滤波 3	85 764	4 163	89 927	99.76%

注：滤波 1 为热像素滤波；滤波 2 为双维度滤波；滤波 3 为邻域密度滤波




图 4 场景 1 数据柱状图




图 5 分段处理剩余噪声折线图

从实验中可知，使用邻域密度滤波即可将剩余的背景噪声基本过滤掉，留下清晰的卫星太阳能板轮廓，但有时在目标物体外仍有一些密集噪声，例如拍摄卫星时旁边有一些陨石漂浮物等，只在一个维度难以去除掉。如图 6 所示，右侧方块部分为模拟陨石的噪声，可以使用双维度滤波器在多个维度进行积累去噪，只保留卫星太阳能板部分的图形，如图 6 中过滤后图像所示。




图 6 双维度滤波去噪效果图

由表 2 数据也可看出只使用邻域密度滤波无法去除密集噪声群，噪声去除率仅为 83.78%，而添加双维度滤波则可以去除 98.15% 的噪声，并且仍保留 90% 的目标事件，由图 7 所示，添加双维度滤波后噪声数量明显下降，在图 8 中分段处理事件切片时效果也较好。

表 2 场景 2 滤波数据表

	目标事件	噪声事件	事件总数	噪声去除率
原始数据	88 671	1 814 592	1 903 263	
滤波 1	88 490	129 830	218 220	92.85%
滤波 1 + 滤波 3	84 381	21 056	105 437	83.78%
滤波 1 + 滤波 2 + 滤波 3	80 297	2 401	82 698	98.15%




图 7 场景 2 数据柱状图




图 8 分段处理剩余噪声折线图

为确保实验的准确性，还使用了由 ETH Zurich 的传感器实验室利用 DAVIS 240C 型号的事件相机获取的数据，采用其中城市部分环境采集数据 [18]。如图 9 使用双阈值控制阀切割事件可看到城市街景建筑轮廓，但在道路上以及天空中会有一些离散的噪声点，使用文献 [19] 方法处理后事件信息损失较多，成像效果较差。使用文献 [14] 方法处理后能够清晰

成像但在天空和道路中仍有一些离散点噪声,而本文处理后
可保存更清晰的场景轮廓,消除随机噪声。




图9 场景1效果对比图

如图10所示,在场景2中文献[19]处理仍然丢失信息较多,文献[14]处理效果较清晰,但也存在随机噪声无法去除,而本文对于大面积空白中的随机离散噪声去除效果更好。




图10 场景2效果对比图

4 结论

本研究提出了一种利用事件数据时空相关性的三层滤波去噪方法。通过实验可看出,该方法能够有效去除事件相机中常见的噪声,如背景噪声、热像素噪声等,同时尽可能多地保留了有用的事件信息。实验结果表明,该算法具有较好的去噪效果,为后续的事件相机目标检测和姿态配准等应用提供了可靠的数据基础。

参考文献:

- [1] 栗傑,杨帆,王向禹,等. 基于事件相机的机器人感知与控制综述[J]. 自动化学报,2022,48(8):1869-1889.
- [2] FALANGA D, KLEBER K, SCARAMUZZA D. Dynamic obstacle avoidance for quadrotors with event cameras[J]. Science robotics, 2020, 5(40): 9712.
- [3] 王文举,唐邦,顾泽骅,等. 深度学习的多视角三维重建技术综述[J]. 计算机工程与应用, 2025,61(6):22-35.
- [4] LI Q X, WANG Z, JIE L P, et al. Dynamic wind turbine blade 3D model reconstruction with event camera[C]//Proceedings of the UNified Conference of DAMAS, IncoME and TEPEN Conferences (UNified 2023).Berlin:Springer,2023: 863-875.
- [5] WANG C Y, YU N N, QIAO Y, et al. Event-based image semantic segmentation[J/OL]. Journal of computer-aided design & computer graphics, 2024[2024-11-09].https://www.jcad.cn/en/article/doi/10.3724/SP.J.1089.2023-00698. DOI:10.3724/SP.J.1089.2023-00698.
- [6] 曾思康. 基于动态视觉传感的高动态星点提取算法研究[D]. 北京:中国科学院大学(中国科学院光电技术研究所), 2022.
- [7] 邹浩东, 吕敏, 郭金库, 等. 基于事件的视觉SLAM综述[J]. 无人系统技术, 2023, 6(3): 59-80.
- [8] GALLEGO G, DELBRUCK T, ORCHARD G, et al. Event-based vision: a survey[J]. IEEE transactions on pattern analysis and machine intelligence, 2022,44(1):154-180.
- [9] DELBRUCK T. Frame-free dynamic digital vision[J/OL].Computer science,2008[2024-09-11].https://www.semanticscholar.org/paper/Frame-free-dynamic-digital-vision-Delbr%C3%BCck/92754e0f56fadae8e0508f06209f98a-43506d60a.DOI:10.5167/UZH-17620.
- [10] 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.
- [11] MUEGGLER E, BARTOLOZZI C, SCARAMUZZA D. Fast event-based corner detection[C/OL]//British Machine Vision Conference.Durham:BMVA,2017[2024-09-21].https://www.researchgate.net/publication/319531414_Fast_Event-based_Corner_Detection.DOI:10.5244/C.31.33.
- [12] BALDWIN R W, ALMATRAFI M, KAUFMAN J R, et al. Inceptive event time-surfaces for object classification using neuromorphic cameras[C]//Image Analysis and Recognition. Berlin: Springer, 2019: 395-403.
- [13] 周晓丽, 贝超, 张楠, 等. 基于事件相机的空间目标事件流降噪算法[J]. 红外与激光工程, 2023,52(9):326-335.
- [14] 闫昌达, 王霞, 左一凡, 等. 基于事件相机的可视化及降噪算法[J]. 北京航空航天大学学报, 2021,47(2):342-350.

融合全局和变量间相关性的多变量时间序列预测研究

王宏博¹

WANG Hongbo

摘要

时间序列在现实生活中有着广泛的应用,通过时间序列预测模型可以有效预测未来的变化趋势,为决策提供依据。在多变量时间序列预测研究中,已有诸多模型被提出,但现有方法存在一些问题,如对多变量时间序列中的全局相关性利用不足、未充分考虑时间序列本身的变量信息等。针对这些问题,文章设计了两种不同的序列嵌入方式,通过 Transformer 架构分别对时间维度上的时间标记和通道维度上的变量标记进行特征提取,并将这些特征进行融合,实现对时间序列的精准预测。通过在 3 个真实时间序列数据集上对该模型进行实验评估,结果表明,模型在预测准确度上优于其他基线模型,相比于最优的基线模型 PatchTST,在 3 个数据集上的 MSE 平均降低了约 17.3%,MAE 平均降低了约 12.8%。

关键词

多变量时间序列预测;全局相关性;协变量;注意力机制

doi: 10.3969/j.issn.1672-9528.2025.05.013

0 引言

时间序列是指按照时间顺序排列的一组数据点,通常用于表示随时间变化的某种现象或变量的变化过程。在多变量时间序列中,每个时间戳包含多个变量且每个变量都随着时间变化。

时间序列预测(time series forecasting)已成为各研究领域的重点,广泛应用于传感器网络监测^[1]、金融与能源管理^[2]、交通流量预测^[3]和气象预测与监控^[4]等领域。在这些应用

场景中,目标时间序列通常指希望预测的主要变量或指标,即整个时间序列预测模型的核心。近年来,多变量时间序列预测(multivariate time series forecasting, MTSF)为长期规划提供了较多帮助,在上述场景下的应用显著增加。例如,由清华大学软件学院机器学习实验室与国家气象中心合作设计的基于自研深度自相关网络(Autoformer^[5])的实时场馆气象预报系统,有效支撑了 2022 年北京冬奥会的气象监控和预测工作。

在时间序列预测领域,传统的统计学方法已被广泛应用于各类实际问题中。早期的研究主要集中于自回归积分滑动平均模型(ARIMA)^[6]和指数平滑(Exponential Smoothing)^[7]

1. 贵州财经大学信息学院 贵州贵阳 550025

[15] 林凯滨,陈云华,钟金煜,等.基于时空邻域关联去噪时间面的事件数据表示[J].计算机应用研究,2024,41(2): 3716-3721.

[16] FANG H C, WU J J, LI L D, et al. AEDNet: asynchronous event denoising with spatial-temporal correlation among irregular data[C]//Proceedings of the 30th ACM International Conference on Multimedia (MM'22). New York: ACM, 2022: 1427-1435.

[17] 徐凤.图像去噪算法及噪声估计研究[D].重庆:重庆大学,2020.

[18] MUEGGLER E, REBECQ H, GALLEG0 G, et al. The event camera dataset and simulator: event-based data for pose estimation, visual odometry, and SLAM[J]. International

journal of robotics research, 2017, 36(2): 142-149.

[19] FENG Y, LÜ H Y, LIU H L, et al. Event density based denoising method for dynamic vision sensor[J/OL]. Applied sciences, 2020[2024-10-06]. <https://doi.org/10.3390/app10062024>.

【作者简介】

苗好田(1990—),男,辽宁沈阳人,博士,副教授、教师,研究方向:机器视觉, email:mht@sylu.edu.cn.

李凯(2000—),男,辽宁锦州人,硕士,研究方向:图像处理技术, email:loyalkid00@163.com.

(收稿日期:2025-03-07 修回日期:2025-05-07)