基于转速调制卡尔曼滤波的纯事件无人机轨迹预测

Hari Prasanth S.M.[1*], Pejman Habibiroudkenar[1*], Eerik Alamikkotervo [1], Dimitrios Bouzoulas [1] 和 Risto Ojala [1]

arXiv:2603.01997v1 [cs.CV] 2 Mar 2026

摘要——事件相机提供高时间分辨率的视觉感知，非常适合观测快速移动的空中目标；然而，其在无人机轨迹预测中的应用仍然有限。本文提出一种利用螺旋桨诱导运动线索的纯事件无人机轨迹预测方法。螺旋桨转速直接从原始事件数据中提取，并在转速感知卡尔曼滤波框架中进行融合。在FRED数据集上的评估表明，所提出的方法在0.4秒和0.8秒预测时域上的平均距离误差和最终距离误差方面优于基于学习的方法和标准卡尔曼滤波器。结果表明，该方法能够在不依赖RGB图像或训练数据的情况下，实现稳健且准确的短时域与中时域轨迹预测。

I. 引言

无人驾驶飞行器（UAV）的轨迹预测是空域监测、避碰、自主航空和反无人机技术等多种应用场景中的一项关键需求。检测和跟踪固然有用，但预测空中目标的未来轨迹有助于及早做出决策并进行威胁分析。在真实场景中，这项任务尤其具有挑战性，因为无人机可能快速加速并大幅改变方向。如果无人机是非合作的，无法获取其控制信号或机载测量数据，预测只能依赖远程检测，难度便又增加了一层。

尽管非合作无人机的检测与预测已得到广泛研究，但目前大多数方法都聚焦于RGB相机 [6], [9], [1]。遗憾的是，这些方法都可能受到运动模糊、帧率有限以及传感器测量延迟的影响，从而损害状态观测的准确性，尤其是在激烈机动或高速飞行时。由于轨迹预测需要准确可靠的历史状态观测，这些感知局限会影响任何采用RGB相机的方法的性能。

事件相机已被提出，作为应对这一高速视觉挑战的替代传感器方案。与传统相机不同，事件相机以逐像素层面的异步方式运行。每个像素都会在微秒量级 [4]对观测场景中的强度变化作出响应。这些特性有助于避免观察快速运动时产生运动模糊。近年来，人们对事件相机在机器人学和无人机应用中的基于事件的感知越来越感兴趣 [15][4]。事件相机已用于无人机存在检测 [3], [19], 、定位 [10] 和跟踪 [5], [13] ，但其在轨迹预测方面的潜力仍基本未得到探索。

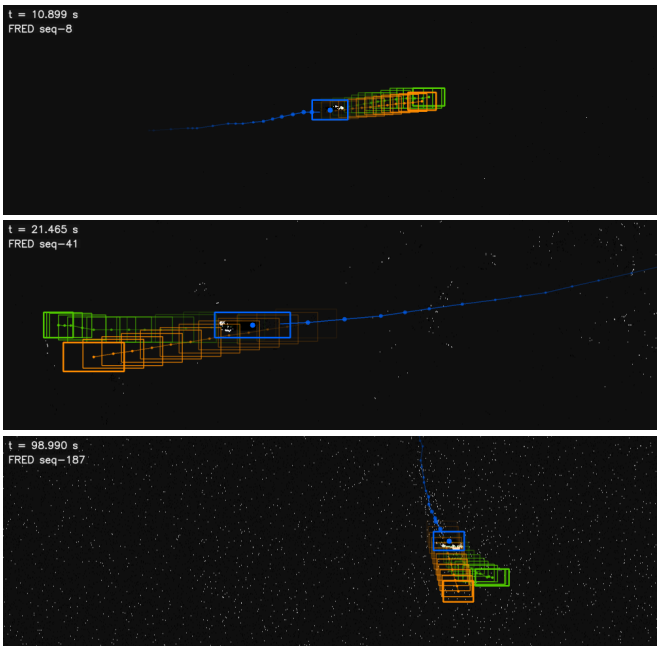


图 1：**所提出的最长达未来 0.4 秒的轨迹预测方法概览。**蓝色表示当前无人机位置和过去轨迹。未来真实位置以绿色显示，预测位置以橙色显示。

远程轨迹预测通常依赖运动学建模 [16] 或基于机器学习的解决方案 [20], [1][12]。机器学习方法能够从数据中学习复杂的预测机制，但需要大量训练数据，而且所学习的预测机制难以迁移到训练数据中未包含的无人机类型和飞行模式。

基于深度学习（DL）的事件相机轨迹预测方法已见于 [12]，但相较于非事件相机配置，其性能提升相当有限。本文提出一种方法，利用经典算法从事件相机数据中提取关键无人机属性，例如螺旋桨速度，以改善无人机的状态估计。随后可利用运动学建模，根据

*贡献相同 本研究得到阿尔托大学的支持[1]能源与机械工程系，阿尔托大学，02150 埃斯波，芬兰firstname.lastname@aalto.fi

当前状态预测未来状态。本文采用卡尔曼滤波进行状态估计，并利用检测到的螺旋桨转速动态实时估计过程噪声。我们在目前规模最大的基于事件相机的无人机数据集 FRED [12], 上评估了所提方法，结果表明，与基于深度学习的基线方法和标准卡尔曼滤波器方法相比，该方法在 0.4 秒和 0.8 秒预测时域上的预测准确率均有所提高。图1展示了预测轨迹示例。贡献可概括如下:

- 我们提出了一种基于卡尔曼滤波器的实时轨迹预测方法，通过螺旋桨转速调制过程噪声矩阵，以提升性能。
- 我们在 FRED 数据集 [12] 上实现了事件相机轨迹预测的最先进结果，性能优于基于深度学习的基线方法和标准卡尔曼滤波器。

II. 相关工作

轨迹预测是指仅利用截至当前时刻的信息来预测未来位姿。无人机通常具有很强的机动性，运动轨迹难以预测，这使得预测任务极具挑战性。第 II-A 节和第 II-B 节简要介绍了最常见的无人机轨迹预测技术。若需更详细的综述，我们推荐阅读 [18]。第 II-C 节将介绍事件相机及其在无人机检测和轨迹预测中的应用。更详细的综述见 [11]。

A. 利用机载传感器进行无人机轨迹预测

如果能够获取无人机的机载传感器信息，并且已知其属性，就可以通过动力学建模估计其未来轨迹。该方法通过估算作用于无人机上的力和力矩来推导其未来状态。无人机受到的最重要的力包括空气动力阻力、重力和螺旋桨推力。文献 [7], [2]探讨了无人机的动力学建模。本文关注非合作无人机的轨迹预测，在这种情况下，动力学建模通常不可行。

B. 远程无人机轨迹预测

对于非合作无人机的远程观测者，可以采用运动学建模，而非动力学建模。运动学建模假设在预测时间间隔内速度或加速度恒定，并据此推算未来状态。对于无人机而言，恒定速度或加速度的假设通常只在较短时间间隔内成立。作为远程观测者，运动学建模应用于 [16]。

此外，也可以利用传统机器学习或深度学习方法从数据中学习轨迹预测任务。 [21]介绍了一种基于高斯过程的传统轨迹预测方法。大多数深度学习方法利用过去轨迹中的序列数据来预测未来轨迹，并提出了多种架构，例如变换器 [20], 循环神经网络（RNN） [1],和长短期记忆网络（LSTM） [12] 。

尽管深度学习模型能够从数据中学习复杂的预测模式，但它们需要大量计算资源和高质量的训练数据，而且在训练域之外的泛化能力通常较差。

C. 事件相机与无人机轨迹预测

传统相机在每一帧中捕捉每个像素的绝对强度，因此容易受到严苛光照条件和快速移动物体的影响。另一方面，事件相机以微秒级精度单独捕捉每个像素的亮度变化，并且仅在强度变化超过给定阈值时才为相应像素生成样本。由此产生连续数据流，其中每个样本（称为事件）都包含像素空间坐标、微秒级分辨率的时间戳，以及强度变化的极性：强度是降低还是增加。这一工作原理显著提高了动态范围，并使其能够捕捉高速运动而不产生运动模糊。关于事件相机的更详细综述见 [4]。

事件相机的特性非常适合用于无人机检测，因此基于事件相机的无人机感知已成为日益热门的研究主题 [11]。无人机存在检测 [3], [19], 无人机定位 [10],无人机跟踪 [5], 以及无人机螺旋桨叶片分析 [22], [17]方面均已取得令人瞩目的成果。然而，基于事件相机的无人机轨迹预测鲜少得到研究。据我们所知，只有 [12], 介绍了基于真实事件相机数据的轨迹预测方法，该方法采用了卷积神经网络（CNN）-Transformer 混合方法。该方法先将过去的事件相机帧裁剪至无人机区域，再用 CNN 对其进行编码，随后将这些编码与过去的轨迹状态一同输入 Transformer，以预测未来状态。然而，与无法获取事件相机数据的模型相比，该方法带来的提升相当有限。我们认为，通过从事件相机数据中提取螺旋桨转速等信息，并将其用于改进状态估计和运动预测，可以显著提高预测准确率。

III. 方法

所提出的框架使用事件相机数据和无人机边界框作为输入。尽管边界框可以通过任意检测器模型获得，但我们使用真实标注，以便在不受检测性能影响的情况下评估轨迹预测。过去轨迹的真实标注也用于 [12]。我们的方法利用事件相机的高时间分辨率来提取螺旋桨转速，随后使用该转速调制卡尔曼滤波器的过程噪声。完整框架的概览如图 2 所示。

A. 转速估计

螺旋桨旋转频率蕴含关于推力和机动性的关键信息。我们估计转数

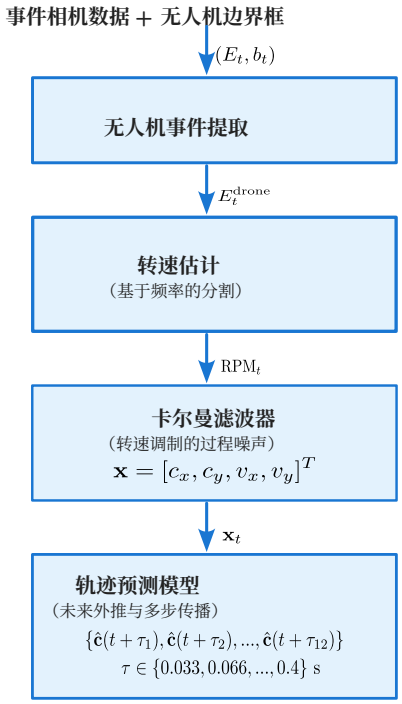


图 2：**所提出的基于事件的轨迹预测框架概览。**

利用周期直方图方法，根据螺旋桨事件的时间周期性估计每分钟转数（RPM）。为构建空间频率图 $F(x, y)$，我们统计无人机边界框内每个像素的事件数量。为了准确进行转速估计，必须将机身像素与螺旋桨像素分离。通过选择基于百分位数的阈值 τ_p，我们将高频螺旋桨像素与低频机身像素区分开来。在实验中，第70百分位数取得了最佳结果。这种基于百分位数的阈值使我们的系统能够适应由不同光照条件和飞行速度引起的事件率变化。频率图和最终分割后的螺旋桨的示例见图3。

每个筛选后的螺旋桨像素（x， y）都会记录其最近一次开启和关闭事件的时间戳： $t_{ON}(x,\ y)$ 和 $t_{OFF}(x,\ y)$。如果某个像素开启时此前处于关闭状态，则记录这两个事件之间的时间间隔 Δt 。边界框内所有像素的周期会按分箱统计为直方图 $H(b)$，分箱宽度为 $\Delta b = 0.1ms$ ，范围为 $[0, 25.6ms]$ ，总计 256 个分箱。为计入 RPM 随时间的变化，会通过先进先出队列移除早于 $100ms$ 的直方图条目。最显著的周期 ˆperiod T 确定如下：

$$\hat{T} = (b^* + 0.5) \cdot \Delta b, \quad b^* = \arg\max_b H(b)$$

主导频率 $f = 1/\hat{T}$ 转换为 RPM 的公式为：

$$\text{RPM} = f \cdot \frac{60}{N_b}$$

其中， N_b 是每个螺旋桨的桨叶数量。分箱宽度和分箱数量的值通过实验选定，使用所选值可以估计出范围为 2300 至 300,000 RPM 的 RPM。

B. 轨迹预测模型

我们将轨迹预测建模为一个实时卡尔曼滤波问题，从含噪测量中估计当前状态，并利用运动学运动模型预测未来位置。过程噪声矩阵根据检测到的螺旋桨转速进行调制，因为较高的螺旋桨转速与不规则运动相关。

1）运动模型：无人机状态在图像空间中估计，包含四个状态变量：中心位置（c_x， c_y）和速度（v_x， v_y）。我们采用离散时间恒定速度作为状态转移模型 [14], [8]。该运动模型假设 v_x 和 v_y 在预测区间内保持恒定，而 c_x 和 c_y 按如下方式更新：

$$c_{x,k} = c_{x,k-1} + v_{x,k-1}\Delta t$$
$$c_{y,k} = c_{y,k-1} + v_{y,k-1}\Delta t$$

过程噪声协方差矩阵初始化为对角矩阵，并按取决于检测到的螺旋桨转速的系数进行缩放。较高的螺旋桨RPM与更激烈机动和快速加速度相关，因此滤波器会增大运动不确定性，并给予测量更新更大权重。相反，在低RPM时，假定无人机运动更平滑且更接近悬停，从而可以给予运动模型更大权重。

过程噪声协方差矩阵初始化为对角矩阵，并按取决于检测到的螺旋桨转速的系数进行缩放。较高的螺旋桨RPM与更激烈机动和快速加速度相关，因此滤波器会增大运动不确定性，并给予测量更新更大权重。相反，在低RPM时，假定无人机运动更平滑且更接近悬停，从而可以更大程度地依赖运动模型。

速度相关缩放因子定义为

$$\alpha_v = \max(0.5,\ 1 + 2r + \max(0, \dot{r}))\,,$$

其中， $r \in [0, 1]$ 表示归一化转速水平，反映无人机可用的推力和整体机动能力。 $\dot{r} \in [-1, 1]$ 表示转速变化率，正值意味着推力增加，且快速运动变化的可能性更高。因此，过程噪声会随着稳定推力增大而增加，也会在油门快速增加时增大，使估计器能够更好地处理动态运动，同时在稳定飞行期间保持保守。

2）测量模型：所有状态变量（c_x， c_y， v_x， v_y）均可直接测量。中心位置（c_x， c_y）由真实边界框中心位置恢复，速度分量（v_x， v_y）则根据以下两者之差计算：

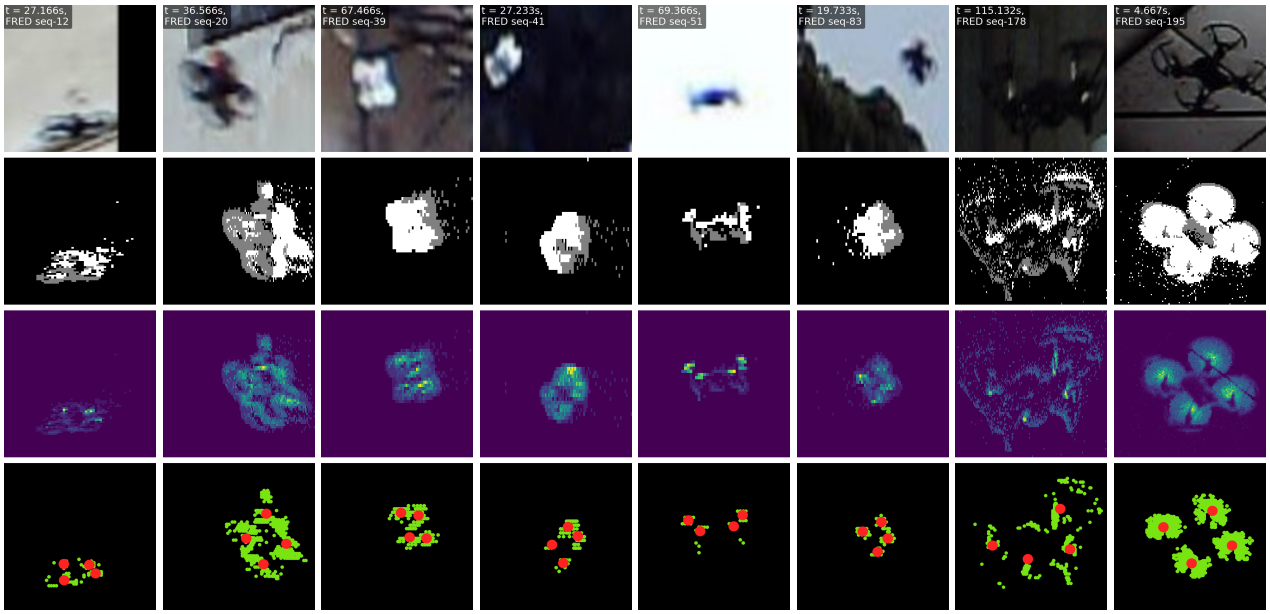


图 3：**基于事件数据的旋翼定位多场景可视化**。每列对应一个不同的场景。从上到下依次为：RGB检测、对应的事件帧、无人机事件的频率热图，以及滤波后的仅螺旋桨事件，其中红色标记表示估计得到的旋翼中心。

当前和前一时间步的真实边界框位置。

3）预测：当前时刻 t的状态通过采用RPM调制过程噪声的卡尔曼滤波器进行恢复。在 $t+\tau$时刻，使用时间步长为 τ的卡尔曼滤波器运动模型预测状态。显然，对于预测状态不执行测量更新。按照FRED数据集 [12]的基准格式，预测时域设为0.4秒和0.8秒。除区间末端的最终位置外，还以33毫秒的时间步长预测所有中间位姿，以便评估完整的预测轨迹。

*C. FRED*数据集

为评估所提出的方法，我们使用FRED数据集 [12]。FRED是一个用于无人机检测、跟踪和轨迹预测的基准数据集，结合了同步的RGB视频和高清分辨率的事件相机数据（1280×720）。该数据集包含每种模态超过7小时的带标注录制数据（总计超过14小时），是目前规模最大的、专门针对空中无人机场景的RGB-事件数据集。数据分为两个部分：训练集和测试集。由于我们的方法不依赖学习，因此仅使用测试集。

FRED 包含五种不同的无人机型号，从超轻型FPV微型无人机到商用无人机，涵盖了广泛的目标尺寸、飞行速度、机动性和悬停行为。它提供逐帧密集标注，包括边界框和一致的轨迹身份标识，不仅支持目标检测，还支持多目标跟踪和轨迹预测。这些录制内容涵盖了多种具有挑战性的真实场景，包括雨天、低光照和夜间条件、室内环境、远距离飞行、多个无人机同时可见的情况，以及昆虫等视觉干扰物。此外，FRED 提供了常规和域偏移挑战性数据划分，专门用于评估模型在不利条件下的模型鲁棒性和泛化能力。

D. 评估

本文提出的方法与经典预测方法和基于深度学习的预测方法进行了比较。所有模型均使用 FRED 测试集进行评估，基于深度学习的模型则仅使用与测试样本相互独立的训练集进行训练。LSTM、Transformer 和 CNN +Trans- former 模型是文献 [12] 中提出的基于深度学习的模型。LSTM 和 Transformer 仅将过去的真实边界框信息作为输入，而 CNN +Transformer 模型还会使用经 CNN 编码的过去 RGB 和/或事件帧。作为经典基线方法，我们实现了线性外推和标准卡尔曼滤波器。线性外推直接将前四个位姿的平均值作为 (v_x, v_y) 速度，不进行任何滤波，然后使用与我们的方法相同的恒定速度运动模型预测未来位姿。标准卡尔曼滤波器的实现与我们的方法完全相同，但其过程噪声矩阵固定不变，不会根据旋翼转速进行调制。

按照 FRED 基准测试协议，预测性能采用两项标准轨迹预测指标进行评估：平均位移误差（ADE）和最终位移误差（FDE）。ADE 衡量所有预测时间步上预测轨迹与

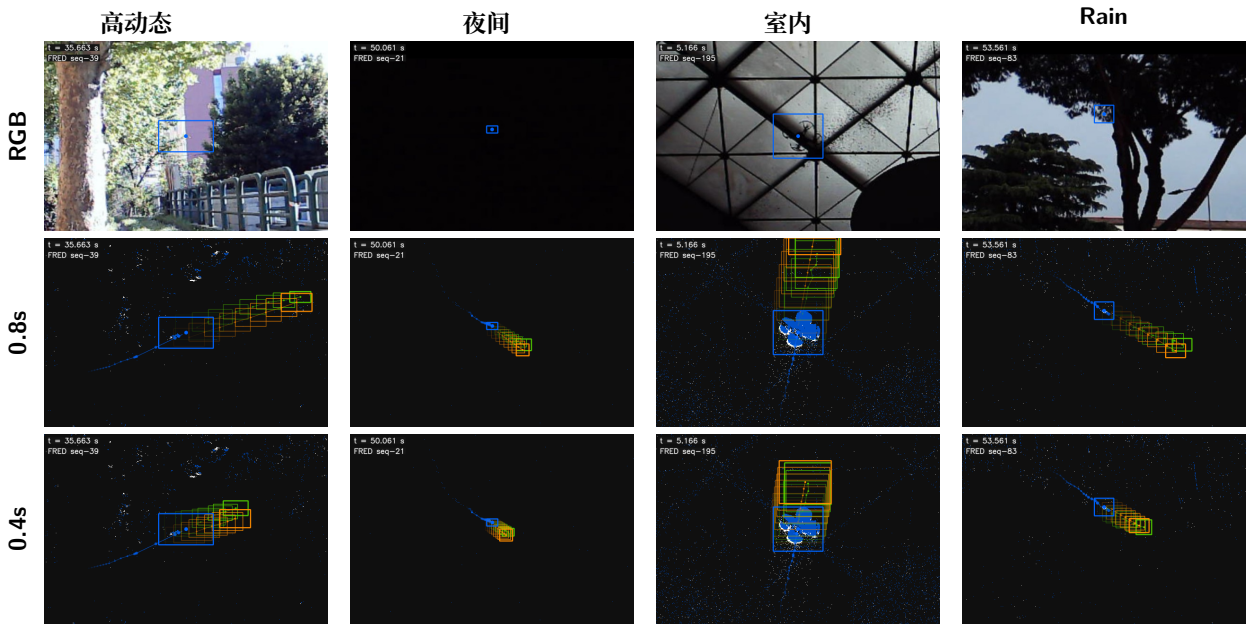


图4：**挑战性条件下的定性轨迹预测结果**。当前真实位置和过去轨迹以蓝色显示；未来真实位置以绿色显示；预测未来位置以橙色显示。结果展示了高动态运动、夜间、室内和雨天场景。

真实轨迹之间的平均欧氏距离，而 FDE 则计算预测终点位置与对应真实终点位置之间的欧氏距离。两项指标均以像素空间为单位报告，数值越低表示预测准确率越高。由于我们的方法主要关注轨迹预测，而非边界框回归，因此评估时采用目标中心点，而非完整的边界框坐标。这种选择能够在不受目标尺度或宽高比变化影响的情况下，公平、直接地比较不同方法的轨迹预测准确率。

IV. 结果

表 I 展示了各评估方法在 0.4s 和 0.8s 预测时间间隔下的平均位移误差和最终位移误差。我们提出的方法在所有指标上均取得最高性能。所有经典方法的表现都优于基于深度学习的方法，且在 0.4s 预测时域下性能差距更大。表现最佳的深度学习模型是同时利用 RGB 和事件相机数据的 CNN + Transformer。

与线性外推基线方法相比，卡尔曼滤波器在 0.4s 预测时域下提升了 0.1px，在 0.8s 预测时域下提升了 2.2px。根据螺旋桨转速调节卡尔曼滤波器的过程噪声，可在 0.4s 预测时域下进一步提升 1.6px，在 0.8s 预测时域下进一步提升 4.2px。

为进一步评估我们方法的误差分布，图 5 展示了两种预测时域下所有测试序列的平均位移误差和最终位移误差分布。箱线图不仅展示了平均预测性能，也反映了变异性。

表 I：FRED数据集上的轨迹预测结果。平均位移误差和最终位移误差以像素为单位报告。

方法	输入		平均位移误差 (px) ↓		最终位移误差 (px) ↓	
	RGB	事件	0.4s	0.8s	0.4s	0.8s
LSTM	✗	✗	171.9	353.3	53.04	96.44
Transformer	✗	✗	124.8	292.2	46.74	87.68
卷积神经网络 +Transformer	✓	✗	124.0	280.9	45.92	83.86
卷积神经网络 +Transformer	✗	✓	151.7	337.0	58.06	100.6
卷积神经网络 + Transformer	✓	✓	121.3	281.5	45.23	85.78
线性外推	✗	✗	16.45	37.93	32.90	83.32
卡尔曼滤波器	✗	✗	16.40	37.08	32.80	81.54
卡尔曼 + RPM	✗	✓	**15.35**	**34.85**	**31.16**	**77.76**

V. 讨论

我们提出的方法在规模庞大的 FRED 无人机数据集上，于 0.4 秒和 0.8 秒预测时域均取得了最高的预测性能。我们的方法仅使用事件相机数据作为输入，不依赖基于学习的模型，且几乎无需进行参数调优。在我们的实验中（表 I），即使是简单的线性外推，其预测性能也优于表现最佳的深度学习模型。这表明深度学习模型可能会对训练数据过拟合，从而限制其泛化能力。此外，结果表明，在保持运动模型不变的同时，采用卡尔曼滤波器进行状态估计，相较于线性外推，能够持续改善平均位移误差和最终位移误差。当

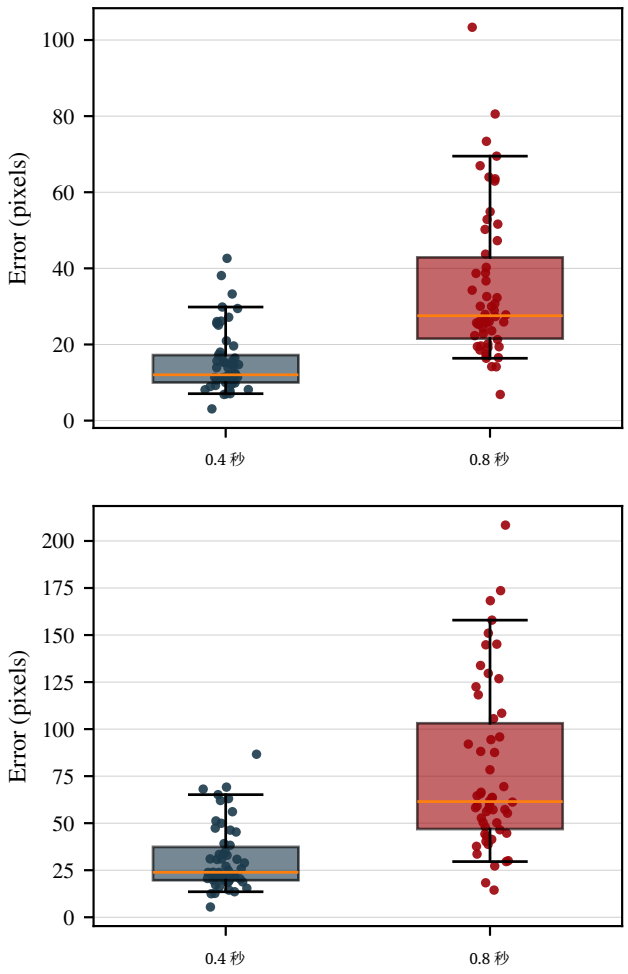


图5：54 个测试案例在 0.4 秒和 0.8 秒预测时域下的预测误差分布。上：平均位移误差；下：最终位移误差。箱体表示四分位距（第 25 至第 75 百分位数），须线表示第 5 至第 95 百分位数，橙色线表示中位数。

卡尔曼滤波器与 RPM 调制过程噪声相结合时，这些结果凸显了准确状态估计在预测中的重要性。当前状态的准确性会显著影响预测状态的准确性。

图4展示了高动态、夜间、室内和雨天等不同场景下的轨迹预测性能。所提出的方法在所有这些场景中均取得了良好的预测性能。此外，该图突显了基于事件相机的感知优势。在事件相机帧中，无人机清晰可见，而在大多数 RGB 帧中则很难检测到。

VI. 结论

本研究提出了一种实时纯事件方法，用于无人机轨迹预测。该方法从事件相机数据中检测螺旋桨转速，并利用这一信息动态调节卡尔曼滤波器的过程噪声矩阵。所提出的方法无需依赖RGB图像，适用于高速且视觉条件具有挑战性的场景。在FRED数据集上的实验结果表明，我们的方法在短期和中期预测中均显著优于基于学习的方法。这些发现凸显了经典事件相机方法在真实场景中实现准确无人机运动预测的潜力。

未来工作将聚焦于整合单个螺旋桨转速估计，而非对整架无人机采用单一转速估计，从而实现更精确的轨迹预测，尤其是在快速且不规则的运动过程中。此外，可基于检测到的螺旋桨估计无人机的姿态，以改进状态估计与预测。这些数值也可用于预测之外的多种无人机应用，例如行为分析。此外，我们计划在无人机于非受限环境中运行的真实环境飞行实验中评估本方法的性能。

致谢

作者感谢Junction组织本次黑客马拉松，并感谢Sensofusion提出用例挑战，该挑战促成了本文的撰写。

参考文献

[1] Stefan Becker、Ronny Hug、Wolfgang Huebner、Michael Arens 和 Brendan T Morris。生成用于深度学习无人机轨迹预测的合成训练数据。*arXiv* 预印本 *arXiv:2107.00422*，2021年。[2] Ane˘zka Chovancov´a、Tom´a˘s Fico、L'ubo˘s Chovanec 和 Peter Hu- binsk。四旋翼飞行器的数学建模与参数辨识（综述）。*Procedia Engineering*，96：172–181，2014年。[3] Anton Eldeborg Lundin、Rasmus Winzell、Hanna Hamrell、David Gustafsson 和 Hannes Ovr´en。利用低功耗神经形态虚拟绊线检测无人机。载于欧洲计算机视觉会议，第105–120页。施普林格，2024年。[4] Guillermo Gallego、Tobi Delbr¨uck、Garrick Orchard、Chiara Bar- tolozzi、Brian Taba、Andrea Censi、Stefan Leutenegger、Andrew J. Davison、J¨org Conradt、Kostas Daniilidis 和 Davide Scaramuzza。事件视觉：综述。*IEEE*模式分析与机器智能汇刊，44(1)：154–180，2022年1月。[5] Craig Iaboni、Deepan Lobo、Ji-Won Choi 和 Pramod Abichandani。用于在线多四旋翼定位与跟踪的基于事件的运动捕捉系统。*Sensors*，22(9)：3240，2022年。[6] Brian KS Isaac-Medina、Matt Poyser、Daniel Organisciak、Chris G Willcocks、Toby P Breckon 和 Hubert PH Shum。基于深度神经网络的无人驾驶飞行器视觉检测与跟踪：性能基准。载于*IEEE/CVF*国际计算机视觉会议论文集，第1223–1232页，2021年。[7] Bouzgou Kamel、Bestaoui Yasmina、Benchikh Laredj、Ibari Be- naoumeur 和 Ahmed-Foitih Zoubir。无人驾驶飞行器（UAV）的动态建模、仿真与PID控制器。载于*2017*年第七届创新计算技术国际会议（*IN- TECH*），第64–69页。IEEE，2017年。[8] Fausto Francesco Lizzio、Martin Bugaj、J´an Rost´a˘s 和 Stefano Primatesta。无人机群分布式目标估计中多种模型的比较。*Drones*，8(1)：5，2023年。[9] Jinyu Ma、Puhui Chen、Xinhan Xiong、Liangcheng Zhang、Shengdong Yu 和 Dongyuan Zhang。用于捕获非法无人机的基于视觉伺服控制与轨迹预测策略研究。*Drones*，8(4)：127，2024年。[10] Gabriele Magrini、Federico Becattini、Pietro Pala、Alberto Del Bimbo 和 Antonio Porta。神经形态无人机检测：一种事件-RGB多模态方法。载于欧洲计算机视觉会议，第259–275页。施普林格，2024年。[11] Gabriele Magrini、Lorenzo Berlincioni、Luca Cultrera、Federico Be- cattini 和 Pietro Pala。基于事件相机的无人机检测，2025年。

[12] Gabriele Magrini、Niccol`o Marini、Federico Becattini、Lorenzo Berlin- cioni、Niccol`o Biondi、Pietro Pala 和 Alberto Del Bimbo。FRED：佛罗伦萨 RGB-事件无人机数据集。载于第*33*届*ACM*国际多媒体会议论文集，MM '25，第13170–13176页，美国纽约州纽约，2025年10月。计算机协会。[13] Anton Mitrokhin、Cornelia Ferm¨uller、Chethan Parameshwara 和 Yiannis Aloimonos。基于事件的移动物体检测与跟踪。载于*2018*年*IEEE/RSJ*智能机器人与系统国际会议（*IROS*），第1–9页。IEEE，2018年。[14] Oscar Javier Monta˜nez、Marco Javier Suarez 和 Eduardo Avendano Fernandez。运用扩展卡尔曼滤波器算法进行传感器数据融合，以识别和跟踪来自激光雷达–雷达数据的移动目标。《遥感》，15(13)：3396，2023年。[15] Elias Mueggler、Henri Rebecq、Guillermo Gallego、Tobi Delbruck 和 Davide Scaramuzza。事件相机数据集与模拟器：用于位姿估计、视觉里程计和同步定位与建图的基于事件数据。《国际机器人研究杂志》，36(2)：142–149，2017年。[16] Han Peng、Abolfazl Razi、Fatemeh Afghah 和 Jonathan Ashdown。用于无人机网络中无人机移动性预测与目标画像的统一框架。《通信与网络杂志》，20(5)：434–442，2018年。[17] Nitin J Sanket、Chahat Deep Singh、Chethan M Parameshwara、Cornelia Ferm¨uller、Guido CHE De Croon 和 Yiannis Aloimonos。Evpropnet：通过寻找螺旋桨来检测无人机，以实现空中着陆和跟随。*arXiv* 预印本 *arXiv:2106.15045*，2021年。[18] Pushpak Shukla、Shailendra Shukla 和 Amit Kumar Singh。无人驾驶飞行器（UAV）轨迹预测技术：全面综述。《*IEEE*通信综述与教程》，27(3)：1867–1910，2024年。[19] Terrence Stewart、Marc-Antoine Drouin、Michel Picard、Frank Billy Djupkep Dizeu、Anthony Orth 和 Guillaume Gagn´e。无人机虚拟围栏：使用DVXplorer事件相机高效检测螺旋桨叶片。载于*2022*年国际神经形态系统会议论文集，第1–7页，2022年。[20] Wuwei Wang、Ruiye Gao、Chi Du 和 Yuanqing Li。利用干扰项消除与轨迹预测增强基于Transformer的无人机间跟踪。载于*2024*年*IEEE*第*17*届信号处理国际会议（*ICSP*），第352–357页。IEEE，2024年。[21] Guangrui Xie 和 Xi Chen。面向非合作无人驾驶飞行器的高效稳健在线轨迹预测。《航空航天信息系统杂志》，19(2)：143–153，2022年。[22] Guangrong Zhao、Yiran Shen、Ning Chen、Pengfei Hu、Lei Liu 和 Hongkai Wen。利用动态视觉传感器进行高速旋转估计。*arXiv* 预印本 *arXiv:2209.02205*，2022年。