文章编号:1008-1534(2026)05-0444-12

# 基于 JPDA-InEKF 的实时目标跟踪方法

刘 佳[1],孙湘山[2],刘 续[3],马英宝[4],杨宇龙[1],奚乐乐[1]

(1. 河北科技大学大学生创新创业中心(工程训练中心),河北石家庄 050018;2. 河北科技大学材料科学与工程学院,河北石家庄 050018;3. 河北科技大学澳联大信息工程学院,河北石家庄 050018;4. 河北科技大学信息科学与工程学院,河北石家庄 050018)

**摘 要**:为解决高动态目标遮挡漏检、虚警干扰、关联歧义和高速旋转引起的轨迹不连续、ID 跳变及状态估计不稳定问题,提出一种融合联合概率数据关联(joint probabilistic data association, JPDA)与统一滤波框架的实时目标跟踪方法。该方法采用 JPDA 软关联与 Viterbi 时序平滑算法,并基于微分空间接口统一扩展卡尔曼滤波(extended Kalman filter, EKF)、容积卡尔曼滤波(cubature Kalman filter, CKF)和不变扩展卡尔曼滤波(invariant extended Kalman filter, InEKF)等滤波器,实现滤波算法、协方差表示方式和状态空间几何结构的解耦。结果表明:基于 JPDA-InEKF 的实时目标跟踪方法可有效降低高速旋转和强机动场景下的跟踪误差,ID 正确率达到 98.5%,跟踪与预测流程延迟低于 0.3 ms。研究结果可为工业机器人视觉跟踪、反无人机侦察和智能交通等智能装备感知系统提供参考。

**关键词**:模式识别;状态估计;联合概率数据关联;卡尔曼滤波;多目标跟踪

**中图分类号**:O343 **文献标识码**:A **DOI**: 10.7535/hbgykj.2026yx05008

# A real-time target tracking method based on JPDA-InEKF

LIU Jia[1], SUN Xiangshan[2], LIU Xu[3], MA Yingbao[4], YANG Yulong[1], XI Lele[1]

(1. Innovation and Entrepreneurship Center for College Students (Engineering Training Center), Hebei University of Science and Technology, Shijiazhuang, Hebei 050018, China; 2. School of Materials Science and Engineering, Hebei University of Science and Technology, Shijiazhuang, Hebei 050018, China; 3. FedUni Information Engineering Institute, Hebei University of Science and Technology, Shijiazhuang, Hebei 050018, China; 4. School of Information Science and Engineering, Hebei University of Science and Technology, Shijiazhuang, Hebei 050018, China)

**Abstract**: To address trajectory discontinuity, ID switching, and unstable state estimation caused by missed detection under occlusion, false-alarm interference, association ambiguity, and high-speed rotation of highly dynamic targets, this paper proposed a real-time target tracking method that integrates Joint Probabilistic Data Association (JPDA) with a unified filtering framework. The proposed method employed JPDA-based soft association and the Viterbi temporal smoothing algorithm, and unified the Extended Kalman Filter (EKF), Cubature Kalman Filter (CKF), and Invariant Extended Kalman Filter (InEKF) through a differential-space interface to achieve decoupling of filtering algorithms, covariance representations, and the geometric structure of the state space. The experimental results demonstrate that the proposed method effectively reduces tracking errors in high-speed rotational and highly maneuvering scenarios, with an ID accuracy of 98.5% and a tracking-and-

收稿日期:2026-05-21;修回日期:2026-07-24;责任编辑:王海云

基金项目:国家自然科学基金(62503149);河北省自然科学基金(F2024208002);河北省高等学校科学技术研究项目(QN2024205)

第一作者简介:刘佳(1988—),女,河北石家庄人,硕士,主要从事工程创新创业与工程实践方面的研究。

通信作者:杨宇龙。E-mail: 106865928@qq.com

刘佳,孙湘山,刘续,等. 基于 JPDA-InEKF 的实时目标跟踪方法[J]. 河北工业科技,2026,43(5):444-455.

Liu Jia, Sun Xiangshan, Liu Xu, et al. A real-time target tracking method based on JPDA-InEKF[J]. Hebei Journal of Industrial Science and Technology, 2026, 43(5): 444-455.

prediction latency of less than 0.3 ms. The results provides reference for intelligent equipment perception systems, including industrial robotic visual tracking, counter-UAV reconnaissance, and intelligent transportation.

**Keywords**: pattern recognition; state estimation; joint probabilistic data association (JPDA); Kalman filtering; multi-target tracking

实时目标跟踪是智能装备感知系统中的关键技术之一，在工业机器人视觉伺服、反无人机侦察、智能交通、自动驾驶和移动机器人自主作业等场景中具有重要应用价值。轻量化视觉感知方法的工程价值已在自动导引车(automated guided vehicle, AGV)动态目标检测和车载疲劳状态检测等任务中得到验证[1-2]。随着目标运动速度、环境复杂度和系统实时性要求的不断提高，跟踪系统不仅需要在连续观测条件下获得稳定的状态估计结果，还需要在遮挡、漏检、虚警干扰和强机动运动条件下保持轨迹连续性与身份一致性。自 Kalman[3] 提出最优递归滤波器以来，状态估计理论已成为现代跟踪系统的重要基础，近年来数据驱动的卡尔曼滤波[4]、左/右不变扩展卡尔曼滤波[5]、多层级解耦滤波[6]等方法不断推动目标跟踪技术发展。然而，在目标高速旋转、频繁遮挡和快速变向的动态环境中，跟踪系统仍面临观测不连续、数据关联模糊和状态估计不稳定等问题，如何同时保证关联鲁棒性、旋转几何一致性和实时部署能力，仍是当前实时目标跟踪研究中的难题[7-8]。

从智能装备工程应用角度看，复杂动态场景中的实时目标跟踪主要面临以下共性问题。首先，目标在高速运动或快速旋转过程中可能产生周期性显隐，导致观测序列不连续；其次，复杂光照、金属反光、运动模糊和局部遮挡容易造成检测器输出虚警观测或漏检真实目标；再次，目标平移、旋转与强机动运动相互耦合，使单纯依赖欧氏空间加法更新的状态估计方法难以保持旋转状态的几何一致性；最后，智能装备通常受到计算资源和控制周期约束，要求跟踪算法在较低延迟下完成数据关联、状态估计和短时预测。因此，面向高动态目标的实时跟踪方法需要同时兼顾概率数据关联、几何一致状态估计和工程实时性。

为验证复杂动态环境下实时目标跟踪算法的有效性，本文选取 RoboMaster 自动瞄准系统作为小规模、高动态、强实时的机器人视觉跟踪实验平台。该平台存在的多目标快速运动、遮挡、漏检、虚警干扰、高速旋转和低延迟控制等问题，与工业机器人视觉跟踪、反无人机探测跟踪和车载智能感知等智能装备应用的关键技术需求具有相似性。本文借助该平台构建可重复的高动态目标跟踪实验环境，用于评估所提出方法在复杂观测条件和强实时约束下的跟踪性能。

在小规模机器人视觉跟踪系统的工程实现中，受计算资源和实时性约束影响，常采用结构简单的“最近邻匹配＋恒速扩展卡尔曼滤波(constant velocity extended Kalman filter, CV-EKF)”技术路线。以 robomaster_vision 开源社区及相关机器人视觉系统实现[9]为例，该类方法具有计算代价低、部署方便等优点，但在复杂动态环境中仍存在明显不足：最近邻匹配属于确定性硬分配方法，在遮挡、虚警和多装甲板周期性显隐条件下容易发生误关联，进而导致 ID 跳变和跟踪发散；CV-EKF 通常在欧氏空间中直接对旋转状态进行加法更新，容易破坏旋转矩阵的正交性，使高速旋转场景下的估计精度显著下降；此外，现有工程实现往往针对特定模型进行定制，缺乏能够统一支持不同滤波算法、协方差表示和状态空间几何结构的通用框架[7,10]。因此，亟需构建一种兼顾概率数据关联、几何一致状态估计和低延迟实时部署的统一跟踪方法。

为解决上述问题，本文提出一种融合联合概率数据关联(joint probabilistic data association, JPDA)与统一卡尔曼滤波框架(unified Kalman filter framework, Uni-KF)的实时目标跟踪方法。该方法采用马氏距离门控、联合概率数据关联和 Viterbi 时序平滑算法描述复杂动态环境下观测结果与估计轨迹之间的不确定关系，以提高遮挡、漏检和虚警干扰下的轨迹一致性，基于微分空间接口统一扩展卡尔曼滤波、容积卡尔曼滤波和不变扩展卡尔曼滤波等状态估计方法，使滤波算法、协方差表示方式和状态空间几何结构解耦。本文围绕数据关联性能、状态估计精度、协方差表示、系统延迟和工程验证效果 5 个方面开展实验，旨在为实时目标跟踪系统设计提供技术思路和实验支撑。

## 1　研究基础

### 1.1　李群滤波

在机器人视觉跟踪任务中，目标状态不仅包含平移量，还可能包含姿态、角速度等旋转相关变量。对于高速旋转目标，若直接在欧氏空间中采用加法形式更新旋转状态，容易破坏旋转矩阵的正交性，进而导致状态估计误差累积。为解决这一问题，不变

扩展卡尔曼滤波[11](invariant extended Kalman filter,InEKF)采用李群上的误差定义,将旋转状态的更新从普通向量加法转换为群运算,从而提高旋转状态估计的几何一致性。

已有研究表明,李群滤波能够在包含姿态和旋转运动的状态估计问题中提高滤波稳定性。本文并非重新推导 InEKF 的基础理论,而是将扩展卡尔曼滤波(extended Kalman filter,EKF)、容积卡尔曼滤波(cubature Kalman filter,CKF)和 InEKF 等滤波器统一到微分空间接口下,使滤波算法、协方差表示方式和状态空间几何结构解耦,为后续实时目标跟踪系统提供统一实现框架。

### 1.2 数据关联

在多目标或多观测跟踪任务中,检测器每帧可能输出多个候选观测结果,系统需要判断各观测结果与已有轨迹之间的对应关系。目前已有较多关于数据关联方法的研究,其中最近邻匹配和匈牙利算法等硬匹配方法计算效率较高,但通常将单帧最优分配结果直接作为确定关联,在遮挡、漏检、虚警和多目标距离接近时容易发生误关联,进而引起 ID 跳变和轨迹发散。

近年来,ByteTrack[8]、iKUN[12]、MOTR[13]、MeMOT[14]、MOTIP[15]等通用多目标跟踪方法,以及基于路径一致性的自监督多目标跟踪方法[16],在行人、车辆等开放场景中取得了较好效果,然而,上述方法多面向大规模开放场景,不适合本文强实时小规模高动态场景。

JPDA 通过计算多种可行关联假设的概率,以边缘关联概率描述观测结果与估计轨迹之间的不确定关系,能够降低单帧硬分配错误对滤波更新的影响[13]。但 JPDA 的计算复杂度会随目标数量和观测数量的增加而上升,且单帧概率结果仍可能受噪声扰动产生波动。因此,本文针对高动态视觉跟踪场景中目标数量较少、实时性要求高、虚警和漏检频繁等特点,采用马氏距离门控对不合理配对进行剪枝,并结合 Viterbi 时序平滑算法在滑动窗口内寻找更稳定的关联序列。Viterbi 时序平滑算法基于隐马尔可夫模型的动态规划思想,可用于抑制单帧匹配结果的短时跳变,从而在控制计算开销的同时提高复杂观测条件下的轨迹连续性。

### 1.3 系统总体设计

RoboMaster 自动瞄准系统由上位机(Mini PC)和下位机微控制单元(microcontroller unit,MCU)两部分组成。上位机负责目标检测、数据关联、状态估计和弹道补偿,最终输出目标的 yaw/pitch 角度和射击指令;下位机接收上位机发送的信息后,采用线性自抗扰控制(linear active disturbance rejection control,LADRC)驱动云台电机实现目标跟踪。这种分层解耦架构在多层级滤波方法[6]中也被采用,能够有效解耦感知与控制模块。

在上位机端,相机采集图像后,检测器输出装甲板的像素坐标与分类信息,经反投影得到三维空间位置。数据关联模块将检测结果分配给已有轨迹或创建新轨迹,滤波器对每条轨迹进行状态估计与预测,弹道补偿模块根据预测位置计算发射仰角。本文的核心贡献集中在数据关联和状态估计 2 个模块。

## 2 概率数据关联与轨迹一致性保持

### 2.1 复杂环境下的观测不确定性

在高动态视觉跟踪场景中,系统需要持续从检测器输出的多组目标观测中恢复真实目标的运动状态。图 1 显示了复杂环境下的装甲板检测结果。由图可见,识别到的装甲板存在高速旋转、突然变向以及局部遮挡等情况,说明同一目标在连续帧中的观测具有明显的不确定性,因此观测结果与估计轨迹之间并不存在天然的一一对应关系。对于任意时刻,系统接收到的观测集合可表示为

$$Z_k=\{z_k^1,z_k^2,\cdots,z_k^m\},$$

式中:$Z_k$ 为第 $k$ 帧检测器输出的观测集合;$z_k^m$ 为第 $k$ 帧中的第 $m$ 个观测向量;$m$ 为当前帧检测到的装甲板数量。与此同时,系统维护的轨迹集合表示为

$$X_k=\{x_k^1,x_k^2,\cdots,x_k^n\},$$

式中:$X_k$ 表示第 $k$ 帧系统维护的轨迹集合;$x_k^n$ 表示第 $k$ 帧中第 $n$ 条轨迹的状态,通常包含目标位置、速度、姿态或其他用于滤波预测的状态量;$n$ 表示当前时刻系统维护的轨迹数量。

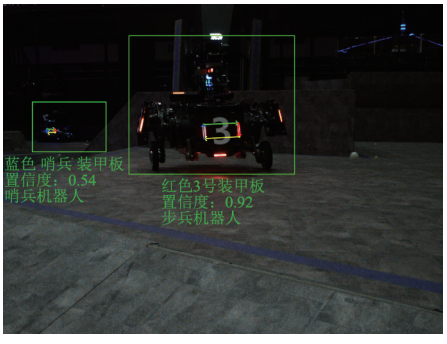


图 1 复杂环境下的装甲板检测结果

Fig. 1 Armor-plate detection results in complex environments

与传统单目标跟踪不同,RoboMaster 场景中的目标具有明显的周期性显隐特征。机器人在高速旋转时,不同装甲板会交替进入和离开相机视野,同一目标在短时间内可能对应多个不同观测,而某些

轨迹则会由于遮挡产生临时漏检。此外，复杂光照环境、金属反光以及识别器误差还会导致检测器产生虚警观测，使系统面临如下 3 类不确定性：1）观测缺失　真实目标未被检测器正确识别；2）虚警干扰　检测器输出不存在的错误目标；3）关联歧义　多个观测结果与多个估计轨迹之间无法通过简单距离关系唯一确定。

传统最近邻方法默认“距离最近即正确匹配”，这种硬决策方式虽然计算量较低，但在高速旋转和遮挡条件下容易发生 ID 跳变。一旦错误观测被写入滤波器状态，后续预测会持续偏离真实轨迹，最终导致目标跟踪发散。因此，数据关联问题本质上是一个在不确定条件下进行概率推断的问题，其核心并非寻找唯一最优匹配，而是在所有可能关联关系中评估每种假设的可信度。

为提高复杂场景下的轨迹连续性与系统鲁棒性，本文采用 JPDA 方法，对所有满足约束条件的观测-轨迹组合进行概率建模。首先，利用马氏距离构建几何一致性约束，对明显不合理的关联关系进行门控筛除；随后，对剩余关联假设计算后验概率，并求解轨迹与观测之间的边缘关联概率。最终，滤波器利用这些概率结果完成状态加权更新，从而在观测不完整、存在虚警以及目标高速机动的情况下维持稳定跟踪。

## 2.2　基于 JPDA 的联合概率数据关联模型

JPDA 最初是由 Bar-Shalom 等系统阐述，其基本思想是枚举所有可能的关联假设，计算各假设的后验概率，并根据概率权重对关联结果进行融合。最终输出的不是确定分配，而是每个轨迹 $i$ -观测 $j$ 组合的关联概率 $\beta_{ij}$ 。每个方案是一个映射，$\varnothing$ 表示漏检。

### 2.2.1　假设似然

每个方案 $a$ 的合理程度通过似然函数衡量。若轨迹 $i$ 与观测 $j$ 被关联，其似然为观测值在预测分布下的概率密度；若某观测被判定为虚警或某轨迹未被检测到，则分别乘以固定的虚警概率 $p_{\mathrm{FA}}$ 和漏检概率 $p_{\mathrm{ND}}$。

$$L(a)=\prod_{(i,j)\in a}\mathcal{N}(z_t^{(j)};\hat{z}_t^{(i)},\boldsymbol{S}_t^{(i)})\prod_{j\in A_{\mathrm{FA}}}p_{\mathrm{FA}}\prod_{i\in A_{\mathrm{ND}}}p_{\mathrm{ND}}\ ,\tag{1}$$

式(1)中：$L(a)$ 为关联方案 $a$ 的似然值，用于衡量该方案与当前观测结果和预测状态的一致程度；$(i,j)\in a$ 表示在方案中轨迹 $i$ 与观测 $j$ 被关联；$\mathcal{N}(\cdot)$ 为高斯概率密度函数；$z_t^{(j)}$ 为第 $t$ 帧第 $j$ 个实际观测向量；$\hat{z}_t^{(i)}$ 为轨迹 $i$ 根据预测状态得到的预测观测向量；$\boldsymbol{S}_t^{(i)}$ 为轨迹 $i$ 对应的创新协方差矩阵；$A_{\mathrm{FA}}$ 表示被判定为虚警的观测集合；$A_{\mathrm{ND}}$ 表示当前帧未被检测到的轨迹集合；$p_{\mathrm{FA}}$ 为虚警概率；$p_{\mathrm{ND}}$ 为漏检概率；$a$ 表示任意一个可行关联方案。

$\boldsymbol{S}_t^{(i)}$ 表征预测位置周围的不确定范围，定义为

$$\boldsymbol{S}_t^{(i)}=\boldsymbol{H}_t^{(i)}\boldsymbol{P}_{t\mid t-1}(\boldsymbol{H}_t^{(i)})^{\mathrm{T}}+\boldsymbol{R}_t^{(i)}\ ,\tag{2}$$

式(2)中：$\boldsymbol{H}_t^{(i)}$ 为轨迹在当前预测状态处的观测雅可比矩阵；$\boldsymbol{P}_{t\mid t-1}$ 为滤波器预测得到的状态协方差矩阵；$\boldsymbol{R}_t^{(i)}$ 为轨迹 $i$ 对应的观测噪声协方差矩阵；上标 T 表示矩阵转置。

### 2.2.2　几何一致性先验

除了式(1)中的假设似然，还可以利用目标的几何结构为不合理的配对降权。具体方法如下：计算每对轨迹-观测配对的马氏距离，距离越大表明配对合理性越低。

$$e_{\mathrm{geo}}(i,j)=(z_t^{(j)}-\hat{z}_t^{(i)})^{\mathrm{T}}\boldsymbol{S}_t^{(i)^{-1}}(z_t^{(j)}-\hat{z}_t^{(i)})\ ,\tag{3}$$

式(3)中：$e_{\mathrm{geo}}(i,j)$ 为轨迹 $i$ 与观测 $j$ 之间的几何一致性代价，也可理解为马氏距离平方；$z_t^{(j)}-\hat{z}_t^{(i)}$ 为实际观测与预测观测之间的创新向量；$\boldsymbol{S}_t^{(i)^{-1}}$ 为创新协方差矩阵的逆矩阵，用于根据预测的不确定性对创新向量进行归一化；几何一致性代价越小，说明该观测与该轨迹的预测结果越一致。

然后将几何代价通过指数变换转化为先验概率，即代价越高，先验概率越低。

$$p(a)\propto\exp\Big(-\lambda\sum_{(i,j)\in a}e_{\mathrm{geo}}(i,j)\Big)\cdot\mathbb{I}(a\in\mathcal{A}_t^{\mathrm{feasible}})\ ,\tag{4}$$

式(4)中：$p(a)$ 为关联方案 $a$ 的几何先验概率；$\lambda$ 为几何约束权重，用于调节几何代价对先验概率的影响强度；$\mathbb{I}(\cdot)$ 为指示函数，当方案 $a$ 满足一对一匹配和门控等基本约束时取 1，否则取 0，排除不满足基本约束（如一对一匹配）的方案；$\mathcal{A}_t^{\mathrm{feasible}}$ 为第 $t$ 帧满足约束条件的可行关联方案集合。

### 2.2.3　后验与边缘概率

有了假设似然函数和几何一致性先验概率，由贝叶斯定理可以计算每个关联方案的后验概率。

$$p(a\mid Z_t)=\frac{L(a)p(a)}{\sum_{a'\in A_t}L(a')p(a')}\ ,\tag{5}$$

式(5)中：$p(a\mid Z_t)$ 为在当前观测集合 $Z_t$ 条件下关联方案 $a$ 的后验概率；$L(a')$ 为在分母求和过程中当前遍历到的关联变量 $a'$ 的似然值；$p(a')$ 为当前遍历到的关联变量 $a'$ 的先验概率。

然后对所有可行关联方案求边缘概率，就得到轨迹 $i$ 与观测 $j$ 的边缘关联概率。

$$\beta_{ij}=\sum_{a:(i,j)\in a}p(a\mid Z_t)\ ,\tag{6}$$

式(6)中:求和范围为所有包含配对 $(i,j)$ 的可行关联方案。这组边缘关联概率就是 JPDA 的最终输出,将在“3.2”节中用于滤波器的加权更新。该边缘概率不是单一硬匹配结果,而是综合所有可能关联方案后得到的软关联权重。

### 2.3 面向实时跟踪的工程优化

JPDA 的理论复杂度随轨迹数和观测数呈组合式增长,直接应用于大规模场景时难以满足实时性要求。但在 RoboMaster 场景中,单帧轨迹数不超过 4、观测数不超过 6,最多只需检验 24($4\times6=24$)对轨迹-观测候选组合;经过一对一约束和马氏距离门控后,实际保留的联合关联假设数量较少,因此可以进行精确枚举。通过以下 3 项优化进一步降低计算开销。

1) 编译期预计算 用 C++ 模板元编程在编译期生成所有可行排列。运行时不需要动态分配内存,也不需要递归生成排列。

2) 似然表查找 预先计算所有轨迹-观测组合的单独似然值并存入查找表。枚举每个方案时直接查表连乘,将每个方案的似然计算从 $O(m)$ 次浮点运算降至 $O(1)$ 次。

3) 门控剪枝 对马氏距离超过门控阈值的候选配对直接予以排除,不参与关联方案枚举,在目标分散的场景下可显著减少实际枚举量。

上述编译期预计算、似然表查找和门控剪枝 3 项工程优化前后的计算复杂度对比如表 1 所示。

表 1 JPDA 匹配器 3 项工程优化前后的计算复杂度对比

Tab. 1 Comparison of the computational complexity of the JPDA matcher before and after three engineering optimizations

| 步 骤 | 原始复杂度 | 优化后复杂度 | 加速技术 |
|---|---|---|---|
| 排列生成 | $O(m!)$ | $O(1)$ | 编译期预计算 |
| 马氏距离计算 | $O(mn)$ | $O(mn)$ | 无可优化 |
| 似然计算 | $O(m!\cdot m)$ | $O(m!)$ | 似然表查找 |
| 归一化 | $O(m!)$ | $O(m!)$ | 并行求和 |
| 边缘概率 | $O(m!\cdot m)$ | $O(m!)$ | 增量累计 |

## 3 状态估计

高动态场景目标常会呈现周期性出现与消失的观测特征,例如在 RoboMaster 场景下,机器人在运动过程中不仅存在平移,还常伴随绕竖轴的高速旋转,使得装甲板呈现此类特征,如图 2 所示。若仍在欧氏空间中对旋转状态进行加法更新,容易破坏旋转状态的几何一致性,进而导致高速旋转场景下的估计误差累积。因此,有必要构建能够适应旋转几何结构的统一滤波框架。

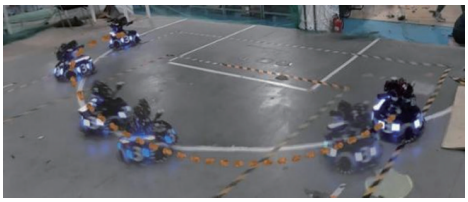

图 2 装甲板平移与绕竖轴旋转运动

Fig. 2 Translation and rotation of the armor plate around the vertical axis

### 3.1 微分空间与统一滤波框架

卡尔曼滤波器无论是 EKF、无迹卡尔曼滤波(unscented Kalman filter,UKF)还是 CKF,其基本结构均相同(预测、计算增益、更新),差异仅在于线性化策略。然而当状态空间为李群[如 SO(3)]时,公式中的加减运算需替换为群运算,每种滤波器均需单独实现其李群版本。

为避免这种重复,本文定义了微分空间接口,将几何运算与滤波算法解耦。接口仅包含 3 个运算。

1) $\oplus$— $\mathcal{M}\times\mathbb{R}^n\to\mathcal{M}$(广义加法) 将切向量叠加至流形上的点。在欧氏空间即为普通加法 $x+\delta$;在李群上即为右乘指数映射 $x\cdot\exp(\delta)$。

2) $\ominus$— $\mathcal{M}\times\mathcal{M}\to\mathbb{R}^n$(广义减法) 计算 2 点间的切向量差。在欧氏空间即为 $x-y$;在李群上即为对数映射 $\log(y^{-1}\cdot x)$。

3) retract— $\mathcal{M}\times\mathbb{R}^n\to\mathcal{M}$(重映射) $\oplus$ 的快速近似版本,用于积分点的生成。

这 3 个接口需要满足往返一致性,即$(x\oplus\delta)\ominus x=\delta$。只要实现这组接口,所有滤波算法即可自动在对应的状态空间上运行。

有了微分空间,预测和更新的公式可以统一写成如下形式。设状态 $x\in\mathcal{M}$,协方差 $P\in\mathbb{R}^{n\times n}$ 定义在 $x$ 处的切空间上。

1) 预测 利用过程模型 $f$ 将状态向前传播一步。

$$x_{t\mid t-1}=f(x_{t-1\mid t-1}), \tag{7}$$

$$\boldsymbol{P}_{t\mid t-1}=\boldsymbol{F}\boldsymbol{P}_{t-1\mid t-1}\boldsymbol{F}^{\mathrm{T}}+\boldsymbol{Q}, \tag{8}$$

式(7)、式(8)中:$x_{t\mid t-1}$ 为当前时刻的预测状态;$x_{t-1\mid t-1}$ 为上一时刻更新后的状态估计;$f(\cdot)$ 为过程模型,用于描述目标状态随时间的演化;$\boldsymbol{P}_{t\mid t-1}$ 为当前时刻预测协方差矩阵;$\boldsymbol{P}_{t-1\mid t-1}$ 为上一时刻更新后的状态协方差矩阵;$\boldsymbol{F}$ 为过程模型在切空间中的雅可比矩阵;$\boldsymbol{Q}$ 为过程噪声协方差矩阵,用于描述运动模型的不确定性。各滤波器采用不同方法对该雅可比矩阵进行近似:EKF 通过解析求导计算,UKF 和 CKF 通过采样点进行数值估计。

2）更新　获得观测 $z$ 后，利用观测模型 $h$ 修正状态：

$$y = z - h(x_{t|t-1}) \ , \tag{9}$$

$$\boldsymbol{S} = \boldsymbol{H}\boldsymbol{P}_{t|t-1}\boldsymbol{H}^{\mathrm{T}} + \boldsymbol{R} \ , \tag{10}$$

$$\boldsymbol{K} = \boldsymbol{P}_{t|t-1}\boldsymbol{H}^{\mathrm{T}}\boldsymbol{S}^{-1} \ , \tag{11}$$

$$x_{t|t} = x_{t|t-1} + \boldsymbol{K}y \ , \tag{12}$$

$$\boldsymbol{P}_{t|t} = (\boldsymbol{I} - \boldsymbol{K}\boldsymbol{H})\boldsymbol{P}_{t|t-1} \ 。 \tag{13}$$

统一更新形式的关键在于广义减法⊖和广义加法⊕。具体而言，创新向量通过⊖计算，状态修正量通过⊕叠加。滤波算法仅处理切空间中的向量与矩阵，几何运算全部由微分空间接口承担。

在统一框架下，不同滤波算法仅需指定各自的线性化方式：EKF 采用雅可比矩阵，UKF 采用 Sigma 点，CKF 采用容积点，不变卡尔曼滤波（invariant Kalman filter，InKF）和 InEKF 采用右不变误差。协方差存储方式（$\boldsymbol{P}$、平方根因子 $\boldsymbol{S}$ 或 UDU 分解）和更新公式形式（标准形式或 Joseph 形式）是另外 2 个独立选择，可以自由搭配。

### 3.2　JPDA 加权更新

标准卡尔曼更新假设观测必然对应某一轨迹。但 JPDA 给出的是概率分布，因此更新时需要对所有候选观测进行加权平均。该式按照关联概率对多个候选观测进行加权，可避免单一观测硬分配带来的误更新。

$$\overline{y}_t^{(i)} = \sum_{j=1}^{m_t} \beta_{ij} y_t^{(ij)} \ , \tag{14}$$

$$y_t^{(ij)} = z_t^{(j)} - h(\hat{x}_{t|t-1}^{(i)}) \ , \tag{15}$$

式(14)、式(15)中：$\overline{y}_t^{(i)}$ 为轨迹 $i$ 的加权创新向量；$m_t$ 为第 $t$ 帧观测数量；$y_t^{(ij)}$ 为轨迹 $i$ 与观测 $j$ 对应的单观测创新；$z_t^{(j)}$ 为第 $j$ 个实际观测；$\hat{x}_{t|t-1}^{(i)}$ 为轨迹 $i$ 的预测状态；$h(\cdot)$ 为观测模型。

用 $\overline{y}_t^{(i)}$ 替代标准更新中的单一创新向量，状态更新为

$$x_{t|t}^{(i)} = \hat{x}_{t|t-1}^{(i)} \oplus (\boldsymbol{K}_t^{(i)}\overline{y}_t^{(i)}) \ , \tag{16}$$

式(16)中：$x_{t|t}^{(i)}$ 为轨迹 $i$ 在第 $t$ 帧更新后的状态；$\hat{x}_{t|t-1}^{(i)}$ 为轨迹 $i$ 的预测状态；$\boldsymbol{K}_t^{(i)}$ 为轨迹 $i$ 的卡尔曼增益；广义加法运算⊕表示将切空间中的状态修正量叠加到当前状态估计上。

因为匹配关系本身存在不确定性，更新后的协方差需要额外补偿该不确定性所引起的扩散。

$$\widetilde{\boldsymbol{P}}_t^{(i)} = \beta_{i0}\boldsymbol{P}_{t|t-1}^{(i)} + \sum_{j=1}^{m_t} \beta_{ij}\boldsymbol{A}_t^{(ij)} \ , \tag{17}$$

$$\boldsymbol{A}_t^{(ij)} = \boldsymbol{P}_{t|t}^{(ij)} + \boldsymbol{K}_t^{(i)}(y_t^{(ij)}y_t^{(ij)\mathrm{T}} - \overline{y}_t^{(i)}\overline{y}_t^{(i)\mathrm{T}})\boldsymbol{K}_t^{(i)\mathrm{T}} \ , \tag{18}$$

式(17)中，$\beta_{i0} = 1 - \sum_j \beta_{ij}$ 是轨迹 $i$ 未匹配到任何观测的概率。该公式具有 2 个良好的退化特性：若 $\beta_{i0} = 1$（无任何匹配），退化为纯预测，协方差不缩小；若某个 $\beta_{ij} = 1$（确定匹配），退化为标准的单观测更新。

### 3.3　平方根协方差表示

框架支持 3 种协方差存储方式：直接存储、平方根因子、UDU 分解。3 种协方差表示方式的估计结果基本相同，仅数值性质和计算速度存在差异，对比结果详见“5.2.3”节。

平方根协方差表示通过存储协方差矩阵的平方根因子，可在数值计算过程中保持协方差矩阵的正定性，已被广泛应用于航空航天领域。状态传播时，直接采用 QR 分解更新平方根因子 $\boldsymbol{S}$，无需显式计算协方差矩阵 $\boldsymbol{P}$ 后再进行分解。以 CKF 为例，其容积点定义为

$$\xi_i = \sqrt{n}\,e_i, \quad i = 1,2,\cdots,n \ ; \tag{19}$$

$$\xi_i = -\sqrt{n}\,e_{i-n}, \quad i = n+1,n+2,\cdots,2n \ ; \tag{20}$$

$$w_i = \frac{1}{2n} \ 。 \tag{21}$$

式(19)—式(21)中：$\xi_i$ 为第 $i$ 个容积点在切空间中的坐标；$n$ 为状态维度；$e_i$ 为第 $i$ 个标准基向量；$w_i$ 为第 $i$ 个容积点对应的权重。CKF 利用 $2n$ 个对称分布的容积点，逼近状态分布在非线性过程模型下的传播结果。

预测时，把容积点通过过程模型传播，然后对传播后的点做 QR 分解直接得到新的平方根因子。定义传播矩阵 $\boldsymbol{W}$ 为

$$\boldsymbol{W} = \left[\sqrt{w_1}(X_1 - \overline{x}), \sqrt{w_2}(X_2 - \overline{x}), \cdots, \sqrt{w_i}(X_i - \overline{x}), \cdots, \sqrt{w_{2n}}(X_{2n} - \overline{x}), \sqrt{\boldsymbol{Q}}\right] \ , \tag{22}$$

$$\boldsymbol{S}_{t|t-1} = \mathrm{triu}(\mathrm{qr}(\boldsymbol{W}^{\mathrm{T}})) \ , \tag{23}$$

式(22)、式(23)中，$X_i = f(x_{t-1|t-1} + \boldsymbol{S}_{t-1|t-1}\xi_i)$ 是经过过程模型传播的容积点。整个过程只涉及 QR 分解和三角回代，不需要显式算出 $\boldsymbol{P}$ 再重新 Cholesky 分解，避免了中间步骤的数值损失。

实际实现中还增加了多层数值保护措施：协方差对角线加 $10^{-12}$ 防止奇异；Cholesky 分解失败时回退到 LDLT 分解；每步检查对角元素符号以尽早发现退化。

### 3.4　不变卡尔曼滤波器

状态包含旋转矩阵时，普通 EKF 的更新会破坏正交性。不变滤波器[5,11]通过以下 2 项改动解决该问题。

1）采用右不变误差　以群运算代替向量减法定义误差。

$$\eta^R = \log(\hat{x}^{-1}x) \ , \tag{24}$$

式(24)中：$\eta^R$ 为右不变误差在李代数中的表示；$x$ 为真实状态；$\hat{x}$ 为估计状态；$\hat{x}^{-1}x$ 表示真实状态

与估计状态之间通过群运算得到的相对误差；$\log(\cdot)$ 为李群到李代数的对数映射。与欧氏空间中的直接向量相减不同，该误差定义能够保持旋转状态更新的几何一致性，适用于包含姿态或旋转变量的状态估计问题。该误差的优势在于不依赖工作点，即对任意 $g \in G$：

$$\log((g\hat{x})^{-1}(gx)) = \log(\hat{x}^{-1}x)\ , \tag{25}$$

其线性化近似在更大范围内有效。

2）容积点在流形上传播　生成容积点时 $X_i = \hat{x} \oplus (S\xi_i)$（切空间→流形），传播后 $\delta_i = f(X_i) \ominus \overline{x}$（流形→切空间）。协方差运算仍在切空间里用标准线性代数完成。

上述 2 项改动引入的额外计算开销主要来自指数映射与对数映射。SO(3) 的指数映射具有闭式解（Rodrigues 公式），计算开销可控。InKF 采用精确雅可比矩阵，InEKF 采用一阶近似雅可比矩阵，两者均可与任意协方差表示方式结合使用。

## 4　弹道补偿

在本文实验平台的目标跟踪与执行控制任务中，弹丸飞行速度低于常规枪械弹丸初速度，飞行过程中会受到重力和空气阻力的影响，导致实际弹道偏离理想直线。实验中弹速设置为 24.5 m/s，当目标距离较远或存在高度差时，若仅根据目标当前位置直接计算 yaw/pitch 角度，将产生明显的射击偏差。因此，系统需要根据滤波器预测得到的目标三维位置，结合目标水平距离、高度差和弹速计算发射仰角。弹道补偿模块的输入为目标预测位置、枪口初速度和目标相对高度，输出为补偿后的 pitch 发射角，并与 yaw 角共同发送至下位机用于云台控制。弹道补偿是该类高动态跟踪与执行控制系统中的关键环节。装备火控校准研究表明，光电测量与执行控制的一体化设计对命中精度具有重要影响[17]；已有学者将弹道补偿纳入跟踪与射击框架，验证了其对于命中精度的直接影响[7,9]。

考虑重力和二次空气阻力，弹丸运动可近似表示为含阻力项的二维运动模型。弹丸运动过程可表示为

$$\ddot{x} = -\frac{k}{m}v\dot{x}\ , \tag{26}$$

$$\ddot{y} = -g - \frac{k}{m}v\dot{y}\ , \tag{27}$$

式(26)、式(27)中：$x$ 和 $y$ 分别为弹丸在水平方向和竖直方向上的位移；$\dot{x}$ 和 $\dot{y}$ 分别为水平方向和竖直方向的速度分量；$\ddot{x}$ 和 $\ddot{y}$ 分别为水平方向和竖直方向的加速度；$v$ 为弹丸速度；$g$ 为重力加速度；$k$ 为等效二次空气阻力系数；$m$ 为弹丸质量。式(26)表示空气阻力导致的水平减速，式(27)表示竖直方向同时受到重力和空气阻力的影响。由于该模型包含速度相关的非线性阻力项，难以直接获得满足工程精度要求的解析解，本文采用 4 阶 Runge-Kutta (RK4)方法进行离线数值积分。

为满足实时运行需求，本文未在每帧在线求解弹道微分方程，而是在离线阶段建立弹道补偿查找表。查找表以目标水平距离 $d$ 和目标相对高度 $h$ 为输入维度，以发射仰角 $\theta$ 为输出，即建立 $d$、$h$ 与 $\theta$ 间的映射关系。离线建表时，在实验平台实际射击距离范围内对 $d$ 和 $h$ 进行网格划分，在每个网格节点处采用 RK4 方法积分弹丸运动方程，并通过角度搜索获得满足命中条件的发射仰角。

本文采用弹丸质量 $m=3.2$ g、重力加速度 $g=9.81$ m/s$^2$、初速度 $v_0=24.5$ m/s 和等效二次空气阻力系数 $k=1.6\times10^{-4}$ kg/m 进行离线建表。本文查找表的水平距离维度设置为 0.5 ～8.0 m，距离步长为 0.05 m；相对高度维度设置为 −1.0 ～ 1.0 m，高度步长为 0.02 m；RK4 积分步长设置为 1 ms。在线运行时，系统首先根据滤波器的预测结果，计算目标相对于枪口的水平距离 $d$ 和相对高度 $h$，然后在查找表中定位相邻网格点，并采用双线性插值得到当前目标位置对应的发射仰角。该方法将在线弹道补偿过程简化为查表和插值运算，避免了每帧重复积分带来的计算开销。

为评估查表和插值引入的误差，在表格网格中点和随机采样点处重新采用 RK4 方法直接求解发射仰角，并与双线性插值结果进行对比。误差评价指标包括发射角插值误差和目标距离处的落点误差。仿真结果表明，在本文实验距离范围内，双线性插值引入的误差相对于装甲板尺寸较小，对最终命中率影响可忽略。弹道补偿查表参数与插值误差如表 2 所示。

表 2　弹道补偿查表参数与插值误差

Tab. 2　Parameters and interpolation errors of ballistic compensation lookup table

| 参　数 | 取　值 |
|---|---|
| 弹丸质量/g | 3.2 |
| 初速度/(m/s) | 24.5 |
| 重力加速度/(m/s$^2$) | 9.81 |
| 等效二次空气阻力系数/(kg/m) | $1.6\times10^{-4}$ |
| 距离步长/m | 0.05 |
| 高度步长/m | 0.02 |
| RK4 积分步长/ms | 1 |
| 发射角平均插值误差/rad | 0.000 18 |
| 发射角最大插值误差/rad | 0.000 74 |
| 目标距离处平均落点误差/mm | 0.9 |
| 目标距离处最大落点误差/mm | 4.8 |

## 5　跟踪系统性能实验

### 5.1　实验方法

为了验证所提出方法在高动态目标实时跟踪任务中的有效性，本文从数据关联性能、状态估计精度、协方差表示方式、系统实时性以及统一框架结构 5 个方面开展综合实验。实验并非追求通用基准[18]上的泛化性能，而是聚焦智能装备感知系统中常见的遮挡、虚警、漏检、高速旋转和强机动等复杂动态问题。

与 ByteTrack[8] 等通用跟踪器不同，所提出的系统针对高速旋转目标进行了专门优化。仿真设置：4 个装甲板目标，采样周期为 0.01 s，测量噪声为零均值高斯分布（yaw/pitch 角度标准差为 0.004 rad，距离标准差为 0.012 m）。测量噪声参数依据 RoboMaster 场景下装甲板检测结果的经验误差范围设定，用于模拟实际视觉测量中的角度与距离观测扰动。基线采用 robomaster_vision 社区广泛部署的“最近邻匹配＋CV-EKF”链路。

实验平台主要硬件与参数设置如表 3 所示。视觉系统使用工业相机获取装甲板图像，上位机完成目标检测、数据关联、状态估计与弹道补偿，下位机负责云台控制与射击执行，运行频率为 100 Hz，目标模型由 4 个装甲板组成。为保证实验的公平性，各组实验统一使用相同观测输入、相同噪声参数以及相同控制频率，仅替换对应算法模块。

表 3　实验平台主要硬件与参数设置

Tab. 3　Main hardware and parameter settings of the experimental platform

| 参　数 | 设　置 |
|---|---|
| 工业相机 | 海康机器人 MV-CS016-10UC |
| 图像分辨率/px | 1 440×1 080 |
| 相机帧率/fps | 最高 249.1，实验设置为 100 |
| 相机接口 | USB 3.0 |
| 镜头焦距/mm | 6 |
| MCU 主控 | STM32H743VIT6 |
| MCU 主频/MHz | 480 |
| 运行频率/Hz | 100 |
| 弹速/(m/s) | 24.5 |
| 上位机 | Intel NUC 11 |
| CPU | Intel Core i5-1135G7 |
| 内存 | 16 GB DDR4 |
| 操作系统 | Ubuntu 22.04 LTS |
| 云台电机 | DJI GM6020 |
| 云台驱动 | CAN 总线电机驱动 |
| 通信接口 | UART / CAN |
| UART 波特率/(bit/s) | 115 200 |
| CAN 波特率/(Mbit/s) | 1 |

#### 5.1.1　概率数据关联实验

在 3 200 帧仿真数据上分别对 4 种关联策略进行对比实验，包括 RMVision 最近邻基线、本文提出的基于马氏距离门控的硬匹配策略、JPDA 以及 JPDA＋Viterbi。仿真数据中包含周期性遮挡（每 180 帧设置 25 帧遮挡窗口）和随机虚警（每帧以 26% 的概率产生 1 个虚警、以 8% 的概率产生 2 个虚警）。

#### 5.1.2　滤波器实验

在平移、小陀螺（5.6 rad/s）、陀螺（8 rad/s）、平移＋小陀螺、强机动 5 类目标运动场景下运行 3～5 个随机种子，评价指标为 $X$-$Y$ 平面内的均方根误差（RMSE）。其中，陀螺场景用于验证系统在高速旋转下的鲁棒性。在每个场景中，为保证公平比较，所有方法均使用完全相同的观测数据（包括虚警）。

#### 5.1.3　协方差表示实验

统一框架支持 3 种协方差存储方式：直接存储 $\boldsymbol{P}$、平方根因子 $\boldsymbol{S}$（$\boldsymbol{P}=\boldsymbol{S}\boldsymbol{S}^{\mathrm{T}}$）、UDU 分解。实验统一采用 InEKF 状态空间，并在长时间连续运行条件下，测试直接存储、平方根因子和 UDU 分解 3 种存储方式的数值稳定性与计算性能。

#### 5.1.4　系统延迟实验

采用实验平台实际硬件环境，分别统计以下模块的单帧运行时间：数据关联模块、滤波预测与更新模块、Viterbi 时序平滑模块、弹道补偿模块。以此重点验证系统是否满足高频实时运行需求。

#### 5.1.5　Uni-KF 对比实验

在实际命中率测试中，分别设置平移、小陀螺、陀螺、平移＋小陀螺和强机动 5 类目标运动场景。每组实验中，红方哨兵首先采用 CV-EKF＋硬匹配方法，对蓝方目标进行跟踪并射击；随后仅将状态估计与数据关联模块切换为 Uni-KF＋JPDA 匹配，其余硬件、弹速、射击数量和目标初始距离保持一致。红方机器人以 24.5 m/s 的弹速发射 200 发 17 mm 弹丸，并记录蓝方机器人装甲板系统感知到的命中数量，计算命中率。

### 5.2　实验结果分析

#### 5.2.1　概率数据关联结果分析

表 4 给出了 4 个装甲板目标的 3 200 帧仿真数据的关联结果。由表可知，硬匹配（马氏距离门控）的 ID 正确率高达 99.65%，显著优于 RMVision 最近邻的 89.70%。这说明社区实践中”欧氏距离最近邻”确实存在较大改进空间。JPDA 单独使用时的 ID 正确率为 83.99%，低于硬匹配方法。该现象并不说明概率关联方法失效，而是与 JPDA 的软关联机制和单帧评价方式有关。JPDA 输出的是轨迹与观测之间的边缘关联概率，而不是确定的单一 ID 分配结果。在遮挡、虚警和多个装甲板周期性显隐条件下，多个候选观测可能同时具有相近的后验概率，若直接将单帧最大概率项作为 ID 判定结果，容易产生短时身份波动。此外，JPDA 在不确定性较高时倾向于提高漏检或弱关联假设的概率，以避免错误观测直接污染滤波状态，因此表现出一定的保

表 4 4 个装甲板目标的 3 200 帧仿真数据关联结果

Tab. 4 Correlation results of 3 200 frames of simulation data for four armor-plate targets

| 关联方法 | ID 正确率/% | 召回率/% | 误关联率/% | 单帧耗时/μs |
|---|---|---|---|---|
| RMVision 最近邻 | 89.70 | 94.2 | 7.2 | 15 |
| 硬匹配(马氏距离门控) | 99.65 | 96.5 | 0.3 | 18 |
| JPDA | 83.99 | 96.2 | 0.8 | 27 |
| JPDA+Viterbi | 98.50 | 96.3 | 1.4 | 41 |

守性。由表 4 还可看出,JPDA 单独使用时误关联率仅为 0.8%,说明其主要问题并非大量错误分配,而是单帧概率结果缺乏时序一致性约束。结合 Viterbi 时序平滑算法后,算法能够利用滑动窗口内的关联连续性抑制短时概率波动,对比 RMVision 最近邻,ID 正确率提升至 98.50%,误关联率降至 1.4%。计算开销从 15 μs 增加至 41 μs,但仍远低于帧预算。因此,JPDA 更适合作为滤波加权更新的概率输入,而 JPDA+Viterbi 更适合作为最终轨迹身份保持策略。

5.2.2 滤波器实验结果分析

表 5 列出了 4 种滤波器在不同运动场景下的 RMSE 对比结果。总体来看,不同滤波器和关联策略在不同运动模式下的表现存在明显差异。

1) 旋转场景下 InEKF 优势显著。在小陀螺(5.6 rad/s)和陀螺(8 rad/s)场景中,InEKF+硬匹配的 RMSE 分别为 0.014 m 和 0.049 m,相比 CV-EKF 基线的 0.240 m 和 0.189 m,误差降低 94% 和 74%。这是因为 CV-EKF 在欧氏空间建模旋转状态存在几何不一致性;而 InEKF 通过右不变误差和李群积分,从根本上避免了这个问题。图 3 展示了陀螺(8 rad/s)场景下的滤波轨迹对比。由图可见,CV-EKF 估计轨迹显著偏离真实轨迹,而 InCKF 与真实轨迹紧密贴合。其中 InCKF 代表不变滤波方法,其与 InEKF 同属右不变滤波框架,二者在本场景中轨迹基本重合,故 InCKF 曲线可代替 InEKF 进行对比。

表 5 4 种滤波器在不同运动场景下的 RMSE 对比结果

Tab. 5 RMSE comparison of four filters under different motion scenarios

m

| 场 景 | CV-EKF 基线 | CKF+硬匹配 | InEKF+硬匹配 | InEKF+JPDA |
|---|---|---|---|---|
| 平移 | 0.248 | 0.063 | 0.103 | 0.103 |
| 小陀螺 | 0.240 | 0.023 | 0.014 | 0.017 |
| 陀螺 | 0.189 | 0.066 | 0.049 | 0.064 |
| 平移+小陀螺 | 0.253 | 0.120 | 0.492 | 0.457 |
| 强机动 | 0.983 | 0.699 | 1.366 | 0.630 |

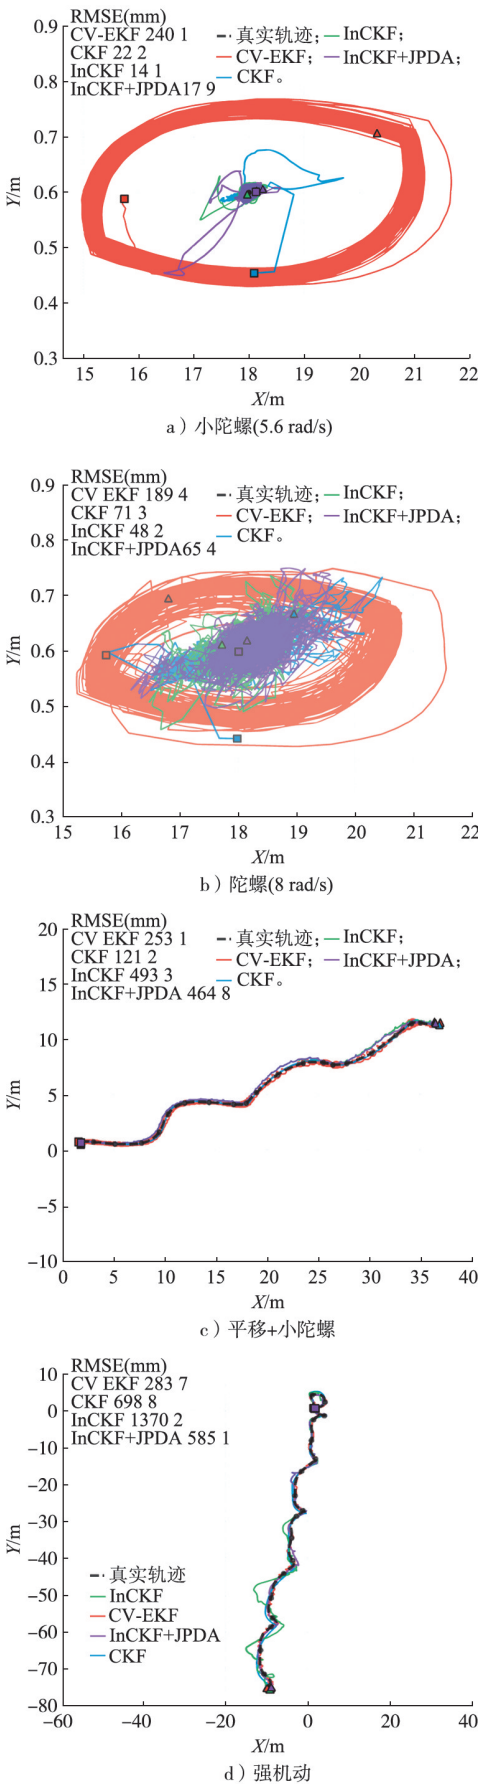


图 3 陀螺场景(8 rad/s)下的滤波轨迹对比

Fig. 3 Comparison of filter trajectories in a spinning scenario (8 rad/s)

2）强机动场景下 JPDA 能够提升估计鲁棒性。强机动场景包含加速度反转和旋转方向切换，轨迹-观测关联高度不确定。此时 JPDA 的软关联优势得以体现：RMSE 从 InEKF＋硬匹配的 1.366 m 降至 InEKF＋JPDA 的 0.630 m，追踪精度改善约 54%。但在以旋转为主的场景（小陀螺、陀螺）中，由于硬匹配已能正确分配（ID 正确率为 99.65%），JPDA 的概率加权反而引入额外噪声。

3）平移场景 CKF＋硬匹配表现最佳。平移场景不含旋转，状态空间全部为欧氏量。此时 CKF＋硬匹配的容积点传播比 InEKF 的一阶线性化更为准确，RMSE 仅为 0.063 m。这表明不同场景适合不同的滤波器，统一框架的价值在于能够灵活切换。

4）InEKF 并非在所有运动模式下均最优。在平移＋小陀螺场景中，InEKF＋硬匹配的 RMSE（0.492）高于 CKF＋硬匹配（0.120）。其原因在于该场景同时包含目标中心平移和装甲板绕竖轴旋转，观测变化由平移误差、旋转相位变化和装甲板周期性显隐共同决定。InEKF 的优势主要体现在旋转状态的几何一致性建模上，但硬匹配仍可能在观测切换和遮挡条件下产生误关联。当错误观测被用于滤波更新时，InEKF 的状态估计仍会被拉偏，从而导致 RMSE 增大。相比之下，CKF 通过容积点传播非线性状态，在以平移和弱旋转耦合为主的场景中具有较好的数值表现。

为进一步评价滤波结果的一致性，本文补充统计了不同滤波器在各运动场景下的归一化估计误差平方（NEES）指标。NEES 越接近状态误差维度，说明滤波器给出的协方差估计与实际误差更一致。不同场景下滤波器一致性 NEES 对比如表 6 所示。结果表明，在平移场景中 CKF＋硬匹配的 NEES 为 6.12，具有较好的一致性；在小陀螺和陀螺场景中，InEKF＋硬匹配的 NEES 分别为 5.92 和 6.18，说明李群误差建模能够较好地刻画旋转状态的不确定性；在强机动场景中，InEKF＋硬匹配的 NEES 增大至 12.84，而引入 JPDA 后降低至 7.58，说明概率关联能够缓解误匹配导致的协方差不一致问题。平移＋小陀螺场景下 InEKF 的 NEES 偏高，也进一步印证了该复合运动场景中存在运动模型和观测关联耦合误差。

表 6　不同场景下滤波器一致性 NEES 对比

Tab. 6　NEES comparison of filters in different scenarios

| 场　景 | CKF＋硬匹配 | InEKF＋硬匹配 | InEKF＋JPDA |
|---|---|---|---|
| 平移 | 6.12 | 6.85 | 6.81 |
| 小陀螺 | 6.34 | 5.92 | 6.08 |
| 陀螺 | 6.71 | 6.18 | 6.43 |
| 平移＋小陀螺 | 6.48 | 9.76 | 9.21 |
| 强机动 | 8.35 | 12.84 | 7.58 |

### 5.2.3　协方差实验结果分析

在 SE(3) 场景下采用 InEKF 对 3 种协方差表示方式进行了对比测试，结果如表 7 所示。理论上 3 种协方差表示的估计结果应完全相同，差异仅在于数值稳定性和计算效率。RMSE 和 NEES 确实完全一致，验证了框架正交解耦设计的准确性。计算周期方面，直接存储最快，平方根因子最慢，差距为 0.45 μs，对整体延迟影响可忽略。实验结果说明，Uni-KF 的统一框架能够实现滤波算法与协方差表示方式之间的有效解耦。

表 7　SE(3)场景下 InEKF 的 3 种协方差表示对比

Tab. 7　Comparison of three covariances representations of InEKF in the SE(3) scenario

| 表示方式 | RMSE/m | NEES | 周期/μs |
|---|---|---|---|
| 直接存储（$\boldsymbol{P}$） | 0.087 4 | 6.00 | 1.06 |
| 平方根因子（$\boldsymbol{S}$） | 0.087 4 | 6.00 | 1.51 |
| UDU 分解 | 0.087 4 | 6.00 | 1.18 |

### 5.2.4　系统延迟实验结果分析

各模块的单帧耗时如表 8 所示。由表可知，匹配模块（JPDA 匹配＋Viterbi 平滑）为 41 μs，InEKF 滤波约 49 μs，合计不足 0.1 ms。弹道补偿通过离线建立的弹道补偿查找表实现，单次查询约 0.15 ms。整个跟踪与预测流水线的端到端延迟低于 0.3 ms，可满足 100 Hz 以上相机输入的实时处理需求。综合测试结果表明，系统端到端延迟满足高频实时目标跟踪需求，能够稳定运行于高动态视觉跟踪实验平台的实际部署环境中。

表 8　各模块的单帧耗时

Tab. 8　Computational overhead of each module

| 模　块 | 复杂度 | 单帧耗时/μs |
|---|---|---|
| 硬匹配（DataAssociator） | $O(mn)$ | 18 |
| JPDA 匹配 | $O(m!)$ | 27 |
| Viterbi 平滑 | $O(\lvert\mathcal{A}\rvert^2 w)$ | 14 |
| CKF 滤波 | $O(n^3)$ | 29 |
| InEKF 滤波 | $O(n^3)$ | 49 |
| 弹道补偿查找表 | $O(1)$ | 150 |

### 5.2.5　Uni-KF 对比实验结果分析

命中率对比实验结果如表 9 所示。由表可知，在不同运动场景下，Uni-KF＋JPDA 匹配均取得了高于 CV-EKF＋硬匹配的命中率，说明所提方法能够通过提高状态估计精度来提升实际跟踪与命中效果。图 4 给出了小陀螺运动目标命中率测试场景：红方自主决策哨兵机器人使用 Uni-KF 对以 5.6 rad/s 旋转的蓝方“小陀螺”目标进行状态估计，并结合火控系统射击蓝方步兵装甲板以实现得分。

表 9 命中率对比实验结果

Tab. 9 Experimental results of hit rate comparison

%

| 场 景 | CV-EKF+硬匹配 | Uni-KF+JPDA 匹配 |
|---|---|---|
| 平移 | 60 | 72 |
| 小陀螺 | 50 | 75 |
| 陀螺 | 46 | 69.5 |
| 平移+小陀螺 | 38 | 42 |
| 强机动 | 32 | 40 |

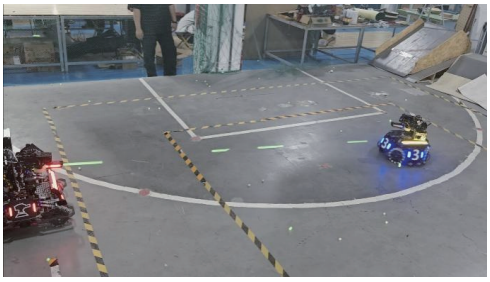

图 4 小陀螺运动目标命中率测试场景

Fig. 4 Hit rate test scenario for small-spinning-target tracking

## 6 结 语

本文针对复杂动态环境下实时跟踪高动态目标中的遮挡、漏检、虚警、干扰、关联歧义、轨迹不连续以及高速旋转状态估计不稳定等问题，提出了一种 JPDA 与 Uni-KF 的实时目标跟踪方法。通过在小规模、高动态、强实时视觉跟踪平台上的实验验证，该方法能够在复杂观测条件下提高目标轨迹连续性和状态估计稳定性。主要结论如下。

1）本文方法可有效降低高速旋转和强机动场景下的跟踪误差，ID 正确率达到 98.50%，跟踪与预测流程端到端延迟低于 0.3 ms。

2）在数据关联方面，马氏距离门控能够显著提高硬匹配的关联准确性，概率关联与时序约束能够有效提升遮挡、漏检和虚警条件下的跟踪稳定性。

3）在状态估计方面，不同运动场景下滤波器表现存在差异。基于李群误差定义的不变滤波方法能够有效避免欧氏空间加法更新带来的旋转几何不一致问题。

4）在强机动场景中，JPDA 软关联能够进一步提升系统鲁棒性。当目标存在快速变向、加速度突变和关联歧义时，概率加权更新比单一硬匹配更适合维持稳定估计。

5）在工程实现方面，本文将滤波算法、协方差表示方式和状态空间几何结构解耦，统一支持 EKF、CKF 等多种滤波器的滤波框架具有较好的模块化和可扩展性。

综上，本文将 JPDA 边缘关联概率与 Viterbi 时序平滑算法相结合，构建了面向高动态视觉跟踪场景的概率数据关联方法，并基于微分空间接口构建了滤波算法、协方差表示方式与状态空间几何结构解耦的统一滤波框架。

但是，本研究仍存在不足：首先，实验主要面向小规模高动态目标跟踪场景，尚未在多类别、大规模工业目标跟踪任务中进行充分验证；其次，JPDA 在目标数量和观测数量增加时仍存在组合复杂度上升问题；最后，复合运动场景下滤波器选择仍依赖人工经验。后续将从 3 个方面开展改进：1）针对目标数量和观测数量增加导致的 JPDA 组合复杂度上升问题，研究基于门控分组、局部假设裁剪和近似边缘概率计算的轻量化关联方法；2）针对多类别工业目标跟踪场景，扩展工件、车辆和低空无人机等多类型目标数据集，验证算法在不同尺度、外观和运动模式下的泛化能力；3）针对复合运动场景下滤波器选择依赖人工经验的问题，引入运动模式识别和自适应滤波器切换机制，实现 CKF、InEKF 与 JPDA 更新策略的在线组合优化。

## 参考文献/References：


[1] 张刚，唐戬，郝红雨，等. 基于改进 SSD-MobileNet 算法的 AGV 动态目标检测方法[J]. 河北工业科技，2024，41(1)：1-9.
Zhang Gang，Tang Jian，Hao Hongyu，et al. AGV dynamic targets detection method based on improved SSD-MobileNet algorithm[J]. Hebei Journal of Industrial Science and Technology，2024，41(1)：1-9.

[2] 李浩，马晓，周万珍. 基于改进 YOLOv5 的驾驶员疲劳状态检测[J]. 河北工业科技，2024，41(1)：17-26.
Li Hao，Ma Xiao，Zhou Wanzhen. Driver fatigue state detection based on improved YOLOv5[J]. Hebei Journal of Industrial Scienceand Technology，2024，41(1)：17-26.

[3] Kalman R E. A new approach to linear filtering and prediction problems[J]. Journal of Basic Engineering，1960，82(1)：35-45.

[4] Revach G，Shlezinger N，Ni Xiaoyong，et al. KalmanNet：Neural network aided Kalman filtering for partially known dynamics [J]. IEEE Transactions on Signal Processing，2022，70：1532-1547.

[5] Ge Yixiao，Delama G，Scheiber M，et al. The difference between the left and right invariant extended Kalman filter[J]. Control Engineering Practice，2026，167：106656.

[6] Zha Jirong，Fan Yuxuan，Li Kai，et al. DIMM：Decoupled multi-hierarchy Kalman filter for 3D object tracking [PP/OL]. (2025-05-18) [2026-07-22]. https://arxiv.org/abs/2505.12340.

[7] Gu Hao，Zhao Zihe，Di Hao，et al. Design and development of real-time automatic tracking and decision system for RoboMaster competition robot using convolutional neural networks [C]//2023 International Conference on Advanced Robotics and Mechatronics (ICARM)，2023：291-296.

[8] Zhang Yifu, Sun Peize, Jiang Yi, et al. ByteTrack: Multi-object tracking by associating every detection box[C]//Computer Vision-ECCV 2022, 2022: 1-21.

[9] 王洪玺，计泽贤，张兰勇. 基于卡尔曼滤波的目标识别跟踪与射击系统设计[J]. 兵器装备工程学报，2022，43(11)：286-296.
Wang Hongxi, Ji Zexian, Zhang Lanyong. Design of target recognition tracking and attack system based on Kalman filter [J]. Journal of Ordnance Equipment Engineering, 2022, 43 (11): 286-296.

[10] Aharon N, Orfaig R, Bobrovsky B Z. BoT-SORT: Robust associations multi-pedestrian tracking [PP/OL]. (2022-06-29) [2026-07-22]. https://arxiv.org/abs/2206.14651.

[11] Barrau A, Bonnabel S. The invariant extended Kalman filter as a stable observer [J]. IEEE Transactions on Automatic Control, 2017, 62(4): 1797-1812.

[12] Du Yunhao, Lei Cheng, Zhao Zhicheng, et al. iKUN: Speak to trackers without retraining[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2024: 19135-19144.

[13] Zeng Fangao, Dong Bin, Zhang Yuang, et al. MOTR: End-to-end multiple-object tracking with transformer [C]// Computer Vision-ECCV 2022, 2022: 659-675.

[14] Cai Jiarui, Xu Mingze, Li Wei, et al. MeMOT: Multi-object tracking with memory[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2022: 8080-8090.

[15] Gao Ruopeng, Qi Ji, Wang Limin. Multiple object tracking as ID prediction[C]//2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2025: 27883-27893.

[16] Lu Zijia, Shuai Bing, Chen Yanbei, et al. Self-supervised multi-object tracking with path consistency[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2024: 19016-19026.

[17] 朱金达，董建国，张卫民，等. 一种基于光电自准直法的装甲战车原位校炮系统[J]. 河北工业科技，2024，41(2)：148-153.
Zhu Jinda, Dong Jianguo, Zhang Weimin, et al. An in-situ artillery calibration system for armored vehicles based on photoelectric self-collimation method [J]. Hebei Journal of Industrial Science and Technology, 2024, 41(2): 148-153.

[18] Dendorfer P, Ošep, A, Milan A, et al. MOTChallenge: A benchmark for single-camera multiple target tracking [J]. International Journal of Computer Vision, 2021, 129 (4): 1415-1437.