

DOI:10.19651/j.cnki.emt.2106110

基于预测滤波的光电跟踪技术研究进展

何秋农^{1,2,3} 段倩文^{1,2,3} 周翕^{1,2,3} 毛耀^{1,2,3}(1. 中国科学院 光束控制重点实验室 成都 610209; 2. 中国科学院 光电技术研究所 成都 610209;
3. 中国科学院大学 北京 100039)

摘要: 随着传动系统的进步以及传感器技术的发展,光电跟踪系统的应用领域不断拓展,系统针对的跟踪目标也从高空、远距离、速度快、运动规律强的传统目标进一步拓展到了低空、距离近、速度慢、运动规律弱的新型目标。面对新型的跟踪目标,光电跟踪系统需考虑进一步提升光电跟踪技术以提高系统的跟踪能力。前馈控制是一种提高系统跟踪能力非常有效的手段,前馈控制的关键在于获取实时准确的目标运动状态,但探测目标的图像传感器一般都存在不可忽略的时间延迟。因此就形成了基于预测滤波的光电跟踪技术研究方向。回顾目前主流的4种基于预测滤波的光电跟踪技术,通过仿真实验分别从频域和时域对比这4种方法性能,然后总结了这4种方法的优缺点并指出此项技术未来的发展方向。

关键词: 光电跟踪技术;预测滤波;前馈控制

中图分类号: TP275;TP273+.3 **文献标识码:** A **国家标准学科分类代码:** 510.801

Research progress of photoelectric tracking technology based on predictive filtering

He Qiunong^{1,2,3} Duan Qianwen^{1,2,3} Zhou Xi^{1,2,3} Mao Yao^{1,2,3}(1. Key Laboratory of Optical Engineering, Chinese Academy of Sciences, Chengdu 610209, China;
2. Institute of Optics and Electronics, Chinese Academy of Sciences, Chengdu 610209, China;
3. University of Chinese Academy of Sciences, Beijing 100039, China)

Abstract: With the development of drive systems and sensor technology, the application field of photoelectric tracking system is expanding. The target tracked by the system has also expanded from the traditional target to the new type of target. Traditional targets have the characteristics of high altitude, long distance, fast speed and strong movement rules. The characteristics of the new type of target are low altitude, short distance, slow speed and weak movement law. Faced with the new type of target, the photoelectric tracking system needs to consider further upgrading the tracking technology to improve the tracking ability of the system. Feed-forward control is an effective means to improve the tracking ability of the system. The key of feed-forward control is to obtain real-time and accurate target motion state, but the image sensor that detects the target generally has a time delay that cannot be ignored. Therefore, the research direction of photoelectric tracking technology based on predictive filtering has been formed. This paper reviews the current mainstream four photoelectric tracking technologies based on predictive filtering, and compares the performance of these four methods from the frequency domain and time domain through simulation experiments. Then, the advantages and disadvantages of these four methods are summarized. Finally, the future research direction of this technology is pointed out.

Keywords: photoelectric tracking technology; predictive filtering; feedforward control

0 引言

光电跟踪系统是集光、机、电为一体的高精密目标跟踪设备,其主要的任务是对目标进行捕获和跟踪^[1-3]。随着系

统结构的优化以及传感器技术的进步,光电跟踪系统应用领域也在不断地拓展,光电跟踪系统所跟踪目标从高空、距离远、角速度小、运动规律强的传统目标,拓展到了低空、距离近、角速度大、运动规律弱的新型目标,例如小型无人

机^[4-6]。装载平台从地基式平台,拓展到了运动平台,如车载、舰载、机载和星载平台,运动平台的兴起推动了光电跟踪系统扰动抑制技术的发展^[7]。目标特性的改变则对光电跟踪技术提出了更高的要求。由于复合轴控制技术引入,系统机械结构特性不再是限制跟踪能力的主要因素^[8-11]。探测目标的图像传感器的时间延迟是目前影响系统跟踪能力的主要因素,因为延迟环节极大地限制了系统闭环带宽。

前馈控制作为一种理论上能够达到零误差跟踪的控制方法,是最直接解决时延问题,提升系统跟踪能力的方法,因此被广泛应用于光电系统的跟踪控制之中^[12-14]。前馈的关键获取目标实时准确的运动状态信息,如目标的位置、速度、加速度等信息。由于目标图像传感器只能提取目标的脱靶量(视轴误差),无法直接获取目标的全局的轨迹信息,因此只能通过与测量系统本身姿态的传感器进行融合来获得目标的轨迹。这种基于融合目标轨迹的前馈控制被称为等效前馈。目前主要的融合方式有3种:1)是编码器与脱靶量融合^[12];2)是陀螺的积分与脱靶量融合^[13];3)是加速度计二次积分与脱靶量融合^[14]。但是无论这3种融合方式中的哪一种,都存在脱靶量的时间延迟与编码器信息不匹配的问题。在融合的时候,需考虑时间轴对齐。因此除了传感器本身存在的噪声以外,融合的时候还会存在融合噪声,融合后的目标轨迹存在一个和脱靶量一样的时延。除了目标融合的轨迹信息存在噪声和时间延迟以外,目标运动模型具有较强的不确定性,难以使用单一模型来进行描述和预测。那么目标观测轨迹存在的噪声、测量时延和目标运动模型的不确定性成为了实现等效前馈需要解决的问题。要解决这些问题采用预测滤波技术。最终随着此研究方向的发展,就逐渐形成了基于预测滤波的光电跟踪技术。

预测滤波技术在光电跟踪系统的应用起源于1960年鲁道夫·卡尔曼提出的一种新的线性滤波和预测方法^[15-18],后来被称为卡尔曼滤波(Kalman filter, KF)。由于估计精度高、实现简单等特点, Kalman 滤波器被美国国家航空航天局(National Aeronautics and Space Administration, NASA)成功地应用于阿波罗的导航系统,并迅速成为最实用的状态估计方法。因此基于预测滤波的光电跟踪技术在早期的工作中,采用融合的目标轨迹作为 Kalman 滤波器的观测信号对目标速度信息进行估计,并将其前馈到系统的速度回路当中。融合的目标轨迹是存在时延的,因此估计的目标速度同样存在延迟,但通过理论的证明和实验验证,这样延迟的补偿方法也能一定程度上提高系统的跟踪能力^[12-13]。在此基础之上,文献[14]进一步提出使用 Kalman 滤波器实现简单的多步预测,利用延迟的融合目标轨迹预测目标当前时刻状态信息,实现实时补偿。另外,基于最小二乘的多项式数据拟合方法也是工程中使用较多的估计目标状态信息的方法,文献[19]引入基于正交多项式的数据拟合方法来预测目标的状态信息,改善传统的最小二乘多项式数据

拟合算法存在的法方程病态和计算不稳定问题,并且此方法不需要目标模型的先验信息。但缺点是预测精度比 Kalman 滤波器低,并且需要选择合适的参数。考虑目标模型变化的问题,文献[20]将交互式多模型算法引入,有效地解决了目标模型的不确定性的问题。但提高估计精度的同时,也伴随着计算复杂度的成倍增长。另外,构造目标模型集所需的先验知识一般也很难获取。这两个缺陷限制了此方法在工程中的应用。为解决此问题,文献[21]进一步提出使用支持向量机对目标运动模型进行实时分类,此方法有效解决了计算量的问题。但目前此项技术还不够成熟,主要问题是训练集的获取与分类特征的选取还存在问题。对于模型不确定性问题,还有一类方法统称为鲁棒状态估计^[22-25],针对光电跟踪系统特有的融合目标轨迹的时延问题加以改进,也能应用到基于预测滤波的光电跟踪技术当中。

本文概要地回顾了基于预测滤波的光电跟踪技术的发展历程,本文剩余内容的组织结构如下:第1节给出基于预测滤波的光电跟踪技术控制结构概述,第2~5节,分别介绍光电跟踪技术中使用的4种主流的预测滤波的方法,第6节对这4种方法进行仿真实验,并分析实验结果。最后全文的总结并指出此项技术未来的研究方向。

1 基于预测滤波的光电跟踪技术控制结构的概述

基于输入信号的前馈控制与反馈控制构成的复合控制方法,即是在原有反馈控制的基础上,引入输入信号以及输入信号的高阶的微分信号,对被控对象施加一个预先的开环控制,然后根据输出信号与输入信号的偏差进一步采用闭环控制修正。前馈控制的引入能在不改变系统稳定性的条件下提高系统的跟踪能力。但如果前馈控制使用的输入信号存在误差,那么前馈不仅不能改善原系统的跟踪能力,反而会给系统增加一个扰动。当前馈控制使用的输入信号的误差大到一定程度时,系统的跟踪精度反而会下降,甚至有可能导致系统发散。因此实现复合控制最关键的是尽可能地获取准确的输入信号及其高阶的微分信号。随着传感器技术的发展,系统现在可实现基于多种不同传感器的多闭环控制,而根据前馈信号输入系统的位置,可形成不同的前馈,如位置前馈,速度前馈和加速度前馈等,本文仅以典型的速度前馈为例进行论述。图1所示为理想的光电系统速度前馈复合控制框图。




图1 光电跟踪系统理想的速度前馈复合控制框图

图1中, $G_v(s)$ 表示系统的速度被控特性; $C_v(s)$ 和

$C_p(s)$ 分别表示速度闭环的控制器与位置闭环的控制器; R, Y, E 分别表示系统的输入、输出以及误差; $C_f(s)$ 则表示前馈控制器。从图1可得系统的误差传递函数如式(1)所示。

$$\Phi_e(s) = \frac{E(s)}{R(s)} = \frac{1 - C_f(s)G_p(s)}{1 + C_p(s)G_p(s)} \quad (1)$$

其中,

$$G_p(s) = C_v(s)G_v(s) / \{s \cdot [1 + C_v(s)G_v(s)]\}$$

假设系统的速度回路的闭环带宽足够高,即可认为 $C_v(s)G_v(s) / [1 + C_v(s)G_v(s)] \approx 1$, 为了使系统的误差传递函数接近于0,先令 $\Phi_e(s)$ 的分子 $1 - C_f(s)G_p(s) = 0$, 进而可得前馈控制器可设计如下:

$$C_f(s) = \frac{1}{G_p(s)} = \frac{1 + C_v(s)G_v(s)}{C_v(s)G_v(s)} \cdot \frac{s}{1} \approx s \quad (2)$$

从式(2)可得理想的速度前馈控制器可以近似成一个微分,即前馈控制器输入系统的信号可视为 R 的一阶微分 R' 。由于光电跟踪系统采用的目标图像传感器 CCD (charge coupled device) 只能提取存在时延迟的脱靶量,因此目标的位置 R 无法直接获得,另外,理想微分也是物理不可实现的。因此,理想前馈是无法实现的,只能利用间接的方法来等效实现。

图2是光电跟踪系统等效的速度前馈复合控制框图,图中 CCD 的时延用 e^{-Ts} 表示, T 表示延迟时间。由于系统只能获得存在时延的误差信号 E , 因此让其与同样延迟的输出信号 Y 进行融合获得输入信号,并用 \tilde{R} 表示, $\tilde{R} \approx R \cdot e^{-Ts}$ 。得到了存在延迟的目标位置 \tilde{R} 后,则需要使用预测滤波算法(predictive filtering algorithm, PFA)来估计和预测目标实时的速度 $\tilde{R}' \approx R \cdot s$ 。 \tilde{R} 存在几种不同的融合方法,可参考文献[12-14]。而采用不同的预测滤波方法来获取目标实时的状态信息则形成了不同的基于预测滤波的光电跟踪技术。下面的章节重点回顾获取目标实时的状态信息所使用的不同预测滤波方法。




图2 光电跟踪系统等效的速度前馈复合控制框图

2 基于正交多项式数据拟合预测的光电跟踪技术

基于正交多项式数据拟合的预测方法(predictive filtering algorithm based on orthogonal polynomial data fitting, PFA-OPDF),起源于1795年高斯提出的最小二乘估计方法。一般多项式数据拟合方法往往存在法方程组病态问题,导致计算不稳定。而正交多项式数据拟合则可以

在保证得到同样结果的前提下,有效地避免病态问题^[26]。采用基于正交多项式数据拟合的方法来拟合目标的轨迹,能够得到逼近这条轨迹的函数。根据这个函数就可以预测目标的轨迹以及目标速度,加速度等信息。这种方法被称为基于正交多项式数据拟合的预测方法。使用这种预测方法用来实现图2中的PFA部分,则形成了一种基于正交多项式数据拟合预测的光电跟踪技术。

基于最小二乘的多项式数据拟合的一般提法为对于给定的一组数据 $(x_i, y_i) (i = 1, 2, \dots, m)$, 要求在函数类, $\Theta = span\{\varphi_0(x), \varphi_1(x), \dots, \varphi_n(x)\}$ 找到一个函数 $y(x) = s^*(x)$, 使得:

$$\sum_{i=1}^m w(x_i) [y(x_i) - y_i]^2 = \min \sum_{i=1}^m w(x_i) [s(x_i) - y_i]^2 \quad (3)$$

其中, $s(x) = a_0\varphi_0(x) + a_1\varphi_1(x) + \dots + a_n\varphi_n(x)$, $\varphi_0(x), \varphi_1(x), \dots, \varphi_n(x) \in C[a, b]$ 是线性无关的函数族。 $w(x)$ 是 $[a, b]$ 上的权函数, $w(x_i)$ 表示 x_i 数据的重要程度。若拟合函数族, $\varphi_0(x), \varphi_1(x), \dots, \varphi_n(x)$ 是正交函数族,则可求得:

$$a_k = \frac{\sum_{i=1}^m w(x_i) y_i \varphi_k(x_i)}{\sum_{i=1}^m w(x_i) \varphi_k(x_i) \varphi_k(x_i)} \quad (4)$$

正交函数族的构造方法如下:

$$\begin{cases} \varphi_0(x) = 1 \\ \varphi_1(x) = x - \alpha_1\varphi_0(x) \\ \varphi_{k+1}(x) = (x - \alpha_{k+1})\varphi_k(x) - \beta_k\varphi_{k-1}(x) \end{cases} \quad (5)$$

其中,

$$\begin{cases} \alpha_{k+1} = \frac{\sum_{i=1}^m w(x_i) x_i [\varphi_k(x)]^2}{\sum_{i=1}^m w(x_i) [\varphi_k(x)]^2} \\ \beta_k = \frac{\sum_{i=1}^m w(x_i) [\varphi_k(x)]^2}{\sum_{i=1}^m w(x_i) [\varphi_{k-1}(x)]^2} \end{cases} \quad (6)$$

结合式(4)~(6),利用融合的目标轨迹时间序列作为 (x_i, y_i) , 即可实现基于正交多项式数据拟合的预测。此预测方法由于实现简单,不涉及目标模型先验知识,也是工程中使用较多的一种方法。但是此预测方法精度较低,在跟踪要求较高的系统里则需采用其他预测滤波方法。

3 基于 Kalman 预测滤波的光电跟踪技术

基于 Kalman 预测滤波的光电跟踪技术,即用 Kalman 预测滤波算法(predictive filtering algorithm based on Kalman filter, PFA-KF)实现图2中PFA部分。Kalman 滤波器是抑制噪声的最优最小均方滤波器^[15]。相较于其

他的滤波方法,离散 Kalman 滤波算法具有计算复杂度低、精度高和可递归实现等特点。式(7)给出了标准的离散 Kalman 滤波的方程。

$$\begin{cases} \mathbf{x}_k = \mathbf{F}\mathbf{x}_{k-1} + \mathbf{G}u_{k-1} + \mathbf{w}_k \\ \mathbf{y}_k = \mathbf{H}\mathbf{x}_k + \mathbf{v}_k \end{cases} \quad (7)$$

其中, \mathbf{F} 表示状态转移矩阵, \mathbf{H} 表示观测矩阵, \mathbf{w}_k 和 \mathbf{v}_k 分别表示模型噪声和观测噪声。 \mathbf{x} 是状态向量, 包含目标的位置、速度、加速度信息。 \mathbf{y} 表示观测向量, 系统只能提供融合的目标轨迹信息, 因此 \mathbf{y} 是一维的向量。 u 表示系统的驱动输入, 由于系统的驱动输入无法改变目标的位置, 因此在使用 Kalman 滤波器估计目标的状态信息时, $\mathbf{G}u_{k-1}$ 项可以忽略。假设采用零均值一阶马尔可夫过程来预测目标的状态信息, 则系统的状态转移矩阵和观测矩阵可表示如下:

$$\mathbf{F} = \begin{bmatrix} 1 & T & T^2/2 \\ 0 & 1 & T \\ 0 & 0 & 1 \end{bmatrix} \quad (8)$$

$$\mathbf{H} = [1 \ 0 \ 0]$$

式中: T 表示采样周期, 式(9)则表示离散 Kalman 滤波器的递推解。

$$\hat{\mathbf{x}}_k^+ = \hat{\mathbf{x}}_k^- + \mathbf{K}_k(\mathbf{y}_k - \mathbf{H}_k\hat{\mathbf{x}}_k^-) \quad (9)$$

其中, $\hat{\mathbf{x}}_k^- = \mathbf{F}\hat{\mathbf{x}}_{k-1}^+$ 表示 k 时刻状态向量的先验估计, $\hat{\mathbf{x}}_k^-$ 表示根据 k 时刻测量值修正后的后验估计, \mathbf{K}_k 叫做 Kalman 增益, 它的计算方式如下:

$$\begin{cases} \mathbf{P}_k = \mathbf{F}_k\mathbf{P}_{k-1}^+\mathbf{F}_k^T + \mathbf{Q}_{k-1} \\ \mathbf{P}_k^+ = [(\mathbf{P}_k^-)^{-1} + \mathbf{H}_k^T\mathbf{R}_k\mathbf{H}_k]^{-1} \\ \mathbf{K}_k = \mathbf{P}_k^-\mathbf{H}_k^T(\mathbf{H}_k\mathbf{P}_k^-\mathbf{H}_k^T + \mathbf{R}_k)^{-1} \end{cases} \quad (10)$$

其中, \mathbf{Q} 和 \mathbf{R} 分别表示模型噪声和过程噪声的协方差矩阵, 这是需要设置的参数, 可以通过统计的方法获得或者自行设置。 \mathbf{P}_k 和 \mathbf{P}_k^- 分别表示先验的估计误差协方差和后验的估计误差协方差, 是计算 \mathbf{K}_k 的中间变量。基于式(7)~(10), 给定初值 $\hat{\mathbf{x}}_0^+$ 和 \mathbf{P}_0^- , 根据 k 时刻的观测值 \mathbf{y}_k , 就可以递推得计算 k 时刻状态估计 $\hat{\mathbf{x}}_k^+$ 了。由于融合的目标轨迹是引入了 CCD 测量延迟, 使用 k 时刻的观测值 \mathbf{y}_k , 实际上是得到 $k-d$ 时刻的状态估计 $\hat{\mathbf{x}}_{k-d}^+$, d 表示 CCD 的延迟帧数, 要获得真正的 $\hat{\mathbf{x}}_k^-$, 则需要进行预测^[12-13]。使用上述的离散 Kalman 滤波算法来实现前馈控制器, 只能一定程度上增强系统的低频跟踪能力。文献[14]则提出一种基于 Kalman 滤波器的预测当前时刻 k 的 $\hat{\mathbf{x}}_k^+$ 简化估计方法。虽然会损失一定的精度, 但计算复杂度低, 利于工程实现, 该方法才算是一种 Kalman 预测滤波算法。文献[27]也提出了一种基于外推的 Kalman 预测滤波方法, 但是计算复杂度偏高, 不利于工程实现。文献[28]则提供了一种 \mathbf{Q} 和 \mathbf{R} 参数对 Kalman 滤波器带宽影响的分析方法。文献[29]提出了一种稳态的 Kalman 滤波器, 保证基本性能的同时进一步优化滤波器的计算复杂度。

4 基于交互式多模型预测滤波的光电跟踪技术

Kalman 预测滤波依赖于目标的运动模型, 当面临目标运动模型变化时, 传统的单模型 Kalman 滤波算法估计精度也会下降。为进一步提升估计精度, 就有学者提出多模型算法(multiple model, MM), 同时采用多个模型来计算, 最后通过加权输出对目标的状态进行估计。后续又有学者对多模型算法提出进一步改进, 其中最具有影响力的是交互式多模型算法(interacting multiple model, IMM), 该算法假设各模型之间服从马尔可夫过程, 通过模型与模型之间的转移概率来实现模型切换。而这个转移概率通过每次估计之后的残差序列来进行实时更新, 最后利用各模型与滤波器进行巧妙地加权输出, 滤波器使用的主要还是 Kalman 滤波器。如果 Kalman 滤波器都替换成第3节所述的 Kalman 的预测滤波算法, 那么就形成了基于交互式多模型预测滤波算法(predictive filtering algorithm based on interacting multiple model, PFA-IMM)。基于交互式多模型预测滤波的光电跟踪技术则是采用 PFA-IMM 去实现图2中的 PFA 部分, 设模型集中有 m 模型, 对应有 m 个 Kalman 滤波器, 交互式多模型算法可描述为如下4个步骤^[4,30]。

第1步: 输入交互

交互获得 i 模型的 $k-1$ 时刻的后验估计, 用于求 i 滤波器的 k 时刻的先验估计:

$$\hat{\mathbf{x}}_{i0}^+(k-1) = \sum_{j=1}^m \hat{\mathbf{x}}_j^+(k-1) \cdot \mu_{ji}(k-1) \quad (11)$$

以 i 模型为例, Kalman 滤波器在 k 时刻对状态向量 $\hat{\mathbf{x}}_i^+(k)$ 进行估计时, 需要用到 $k-1$ 时刻的状态向量的后验估计 $\hat{\mathbf{x}}_i^+(k-1)$ 来对 k 时刻的状态向量先进行一个先验估计得到 $\hat{\mathbf{x}}_i^-(k)$, 而在交互式多模型算法中, 在获得 k 时刻的状态向量先进行一个先验估计 $\hat{\mathbf{x}}_i^-(k)$ 时, 并非直接使用 $k-1$ 时刻的最终的状态向量的后验估计 $\hat{\mathbf{x}}_i^+(k-1)$, 而是通过 $k-1$ 时刻每个模型的后验估计 $\hat{\mathbf{x}}_1^+(k-1), \hat{\mathbf{x}}_2^+(k-1), \dots, \hat{\mathbf{x}}_m^+(k-1)$ 交互获得一个 $\hat{\mathbf{x}}_{i0}^+(k-1)$, 然后使用交互获得的 $\hat{\mathbf{x}}_{i0}^+(k-1)$ 来对 k 时刻的状态向量先验估计得到 $\hat{\mathbf{x}}_i^-(k)$ 。式(11)中 $\mu_{ji}(k-1)$ 表示 j 模型到 i 模型的后验转移概率。

交互获得 i 模型的 $k-1$ 时刻的后验估计误差协方差 $\mathbf{P}_{i0}^+(k-1)$, 用于求 i 滤波器的 k 时刻的先验的估计误差协方差、后验的估计误差协方差以及 Kalman 增益。

$$\mathbf{P}_{i0}^+(k-1) = \sum_{j=1}^m \mu_{ji}(k-1) \cdot \{\mathbf{P}_j^+(k-1) + [\hat{\mathbf{x}}_j^+(k-1) - \hat{\mathbf{x}}_{i0}^+(k-1)] \times [\hat{\mathbf{x}}_j^+(k-1) - \hat{\mathbf{x}}_{i0}^+(k-1)]^T\} \quad (12)$$

式中: $\mu_{ji}(k-1) = (1/\bar{c}_i) \cdot \rho_{ji} \cdot \mu_j(k-1)$, ρ_{ij} 表示的是先验统计的模型转移概率, $\mu_{ji}(k-1)$ 表示的是一种后验概

率,它表示是如果 $k-1$ 时刻的模型已经是 i ,它是从 j 模型转移到 i 模型的概率。 $\sum_{j=1}^m \rho_{ij} = 1, 0 < \rho_{ij} < 1, \mu_i(k-1)$ 表示 $k-1$ 时刻的模型 i 的概率,归一化常量 $\bar{c}_i = \sum_{j=1}^m \rho_{ji} \cdot \mu_j(k-1)$ 。与获得 $k-1$ 时刻的交互式状态向量后验估计类似,式(12)给出的是获得 $k-1$ 时刻的交互式误差协方差后验估计。

第2步:Kalman 滤波过程

基于式(11)、(12)获得的 $k-1$ 时刻交互式状态向量后验估计 $\hat{x}_{i0}^+(k-1)$ 以及交互式误差协方差后验估计 $\mathbf{P}_{i0}^+(k-1)$, 进行 k 时刻的 Kalman 迭代滤波。

$$\hat{x}_i^-(k) = \mathbf{F}_i(k-1)\hat{x}_{i0}^+(k-1) \quad (13)$$

式中: $\mathbf{F}_i(k-1)$ 表示第 i 个模型 $k-1$ 时刻的状态转移矩阵。

$$\mathbf{P}_i^-(k) = \mathbf{F}_i(k-1)\mathbf{P}_{i0}^+(k-1) \times \mathbf{F}_i^T(k-1) + \mathbf{Q}_i(k-1) \quad (14)$$

式中: $\mathbf{Q}_i(k-1)$ 表示第 i 个模型 $k-1$ 时刻的过程噪声协方差。

$$\mathbf{K}_i(k) = \mathbf{P}_i^-(k)\mathbf{H}_i^T(k) \times [\mathbf{H}_i(k)\mathbf{P}_i^-(k)\mathbf{H}_i^T(k) + \mathbf{R}_i(k)]^{-1} \quad (15)$$

式中: $\mathbf{H}_i(k)$ 和 $\mathbf{R}_i(k)$ 分别表示第 i 个模型 k 时刻的测量矩阵和测量噪声协方差。

$$\hat{x}_i^-(k) = \hat{x}_i^-(k) + \mathbf{K}_i(k)[y(k) - \mathbf{H}_i(k)\hat{x}_i^-(k)] \quad (16)$$

式中: $y(k)$ 表示 k 时刻系统的测量值(由于每个模型都一样,因此不加下标)。

$$\mathbf{P}_i^+(k) = [\mathbf{I} - \mathbf{K}_i(k)\mathbf{H}_i(k)] \cdot \mathbf{P}_i^-(k) \quad (17)$$

式(17)则是计算第 i 个模型(也可以说是第 i 个滤波器) k 时刻的后验估计误差协方差。

第3步:模型概率的更新

$$r_i(k) = y(k) - \mathbf{H}_i(k)\hat{x}_i^-(k) \quad (18)$$

式中: $r_i(k)$ 表示第 i 个模型 k 时刻的滤波残差。

$$\mathbf{S}_i(k) = \mathbf{H}_i(k)\mathbf{P}_i^-(k)\mathbf{H}_i^T(k) + \mathbf{R}_i(k) \quad (19)$$

式中: $\mathbf{S}_i(k)$ 表示第 i 个模型 k 时刻的滤波残差的协方差。

假设第 i 个模型 k 时刻的滤波残差为零均值的高斯白噪声,则似然函数为:

$$\Lambda_i(k) = \sqrt{2\pi|\mathbf{S}_i(k)|} \times \exp\left(-\frac{1}{2}[r_i(k)]^T\mathbf{S}_i(k)[r_i(k)]\right) \quad (20)$$

模型概率的更新为:

$$\mu_i(k) = \frac{\Lambda_i(k)\bar{c}_i}{\sum_{j=1}^m \Lambda_j(k)\bar{c}_j} \quad (21)$$

第4步:状态和协方差的交互估计

$$\hat{x}^+(k) = \sum_{i=1}^m \hat{x}_i^+(k) \cdot \mu_i(k) \quad (22)$$

$$\mathbf{P}^-(k) = \sum_{i=1}^m \mu_i(k) \{ \mathbf{P}_i^+(k) + [\hat{x}_i^+(k) - \hat{x}^+(k)] [\hat{x}_i^+(k) - \hat{x}^-(k)]^T \} \quad (23)$$

基于上述 IMM 算法的主要步骤,在第 3 步添加文献[14]描述的 Kalman 预测滤波方法,即可实现基于交互式多模型预测滤波算法。只要使用合适的目标运动模型集,IMM 算法可取得比 Kalman 滤波更好的效果。但是为了获得最佳的滤波效果,必须使用一个尽可能完全覆盖目标所有运动的模型集,但模型集的增大会使算法的计算量也成倍增长。目前光电跟踪系统单模型的 Kalman 滤波只能在 100 Hz 的中断频率下使用,如果中断频率提升则有可能无法完成运算,因此要实现 IMM 算法则需要降低中断频率,这会导致滤波器实时性下降。因此在目前的光电跟踪系统中无法成功的应用 IMM 算法。为了解决 IMM 算法计算量的问题,文献[21]进一步提出了使用支持向量机对目标的模型进行实时分类,每次只使用一个模型进行计算,在降低计算复杂度的,尽量保证了滤波器的精度。但是此方法目前输入前期的研究仿真阶段,分类的特征选取以及分类的方法选择还不够成熟。

5 基于鲁棒预测滤波的光电跟踪技术

针对目标运动模型变化问题,基于交互式多模型的预测滤波存在计算量随模型集成倍增长的问题,为避免此问题,除了考虑采用机器学习的方法进行分类,也可以考虑引入鲁棒状态估计的方法,将鲁棒状态估计针对光电跟踪系统特意的融合轨迹时延进行改进,即可形成鲁棒的预测滤波算法(predictive filtering algorithm based on robust state estimation, PFA-RSE),本文以文献[25]中的鲁棒状态估计为例进行改进,首先将光电跟踪系统的目标预测滤波问题,描述如下:

$$\begin{cases} \mathbf{x}_{k+1} = \mathbf{A}_k(\boldsymbol{\varepsilon}_k)\mathbf{x}_k + \mathbf{B}_k(\boldsymbol{\varepsilon}_k)\mathbf{w}_k \\ \mathbf{y}_k = \mathbf{C}_{k-d}(\boldsymbol{\varepsilon}_{k-d})\mathbf{x}_{k-d} + \mathbf{v}_k \end{cases} \quad (24)$$

式中: $\mathbf{x}_k \in \mathbb{R}^n$ 表示系统的状态向量,即目标位置,速度和加速度。 $\mathbf{y}_k \in \mathbb{R}^m$ 表示系统的测量向量,即融合目标轨迹, d 表示测量信号的时间滞后帧数, $d \in \mathbb{N}^+$, 模型误差 $\boldsymbol{\varepsilon}_k$ 是一个向量,由 L 个实值标量不确定性 $\varepsilon_{i,k}, i = 1, \dots, L$ 组成。 $\mathbf{A}_k(\boldsymbol{\varepsilon}_k), \mathbf{B}_k(\boldsymbol{\varepsilon}_k)$ 和 $\mathbf{C}_k(\boldsymbol{\varepsilon}_k)$ 是与模型误差 $\boldsymbol{\varepsilon}_k$ 相关且大小分别为 $n \times n, n \times n, m \times n$ 的系统矩阵。

$\mathbf{w}_k \in \mathbb{R}^n$ 和 $\mathbf{v}_k \in \mathbb{R}^m$ 是方差分别为 \mathbf{Q} 和 \mathbf{R} , 互不相关的高斯随机噪声,即:

$$\begin{cases} E[\mathbf{w}_k\mathbf{w}_k^T] = \delta_{kj}\mathbf{Q} \geq 0 \\ E[\mathbf{v}_k\mathbf{v}_k^T] = \delta_{kj}\mathbf{R} \geq 0 \\ E[\mathbf{w}_k\mathbf{v}_k^T] = 0 \end{cases} \quad (25)$$

假设测量滞后帧数 d 已知,且不变,则系统(24)可重新建模为无滞后的增广系统(26)。

$$\begin{cases} \bar{\mathbf{x}}_{k+1} = \mathbf{A}_k(\boldsymbol{\varepsilon}_k)\bar{\mathbf{x}}_k + \bar{\mathbf{B}}_k(\boldsymbol{\varepsilon}_k)\mathbf{w}_k \\ \mathbf{y}_k = \bar{\mathbf{C}}_k(\boldsymbol{\varepsilon}_k)\bar{\mathbf{x}}_k + \mathbf{v}_k \end{cases} \quad (26)$$

其中, $\bar{\mathbf{x}}_k = [\mathbf{x}_k^T, \Delta_k^T, \Delta_{k-1}^T, \dots, \Delta_{k-d+1}^T]^T, \Delta_k = \mathbf{C}_{k-1}(\boldsymbol{\varepsilon}_{k-1})\mathbf{x}_{k-1} - \mathbf{C}_k(\boldsymbol{\varepsilon}_k)\mathbf{x}_k,$

$$\bar{\mathbf{A}}_k(\boldsymbol{\varepsilon}_k) = \begin{bmatrix} \mathbf{A}_k(\boldsymbol{\varepsilon}_k) & \mathbf{0}_{n \times (d-1)m} & \mathbf{0}_{n \times m} \\ \mathbf{C}_k(\boldsymbol{\varepsilon}_k) - \mathbf{C}_{k+1}(\boldsymbol{\varepsilon}_{k+1})\mathbf{A}_k(\boldsymbol{\varepsilon}_k) & \mathbf{0}_{m \times (d-1)m} & \mathbf{0}_{m \times m} \\ \mathbf{0}_{(d-1)m \times n} & \mathbf{I}_{(d-1)m} & \mathbf{0}_{(d-1)m \times m} \end{bmatrix},$$

$$\bar{\mathbf{B}}_k(\boldsymbol{\varepsilon}_k) = \begin{bmatrix} \mathbf{B}_k(\boldsymbol{\varepsilon}_k) \\ -\mathbf{C}_{k+1}(\boldsymbol{\varepsilon}_{k+1})\mathbf{B}_k(\boldsymbol{\varepsilon}_k) \\ \mathbf{0}_{(d-1)m \times n} \end{bmatrix},$$

$$\bar{\mathbf{C}}_k(\boldsymbol{\varepsilon}_k) = [\mathbf{C}_k(\boldsymbol{\varepsilon}_k), \underbrace{\mathbf{I}_{m \times m}, \dots, \mathbf{I}_{m \times m}}_d].$$

将系统状态空间方程重新建模后,考虑系统的模型不确定性,由文献[25,31]可知,Kalman 滤波器可解释为一个递归最小二乘问题的解,如式(27)所示。

$$\begin{aligned} \begin{pmatrix} \hat{\mathbf{x}}_{k|k+1} \\ \hat{\mathbf{w}}_{k|k+1} \end{pmatrix} &= \arg \min_{\mathbf{x}_k, \mathbf{w}_k} [\|\mathbf{x}_k - \hat{\mathbf{x}}_{k|k}\|_{\mathbf{P}_{k|k}}^2 + \|\mathbf{w}_k\|_{\mathbf{Q}_k}^2 + \|\mathbf{y}_{k+1} - \mathbf{C}\mathbf{x}_{k+1}\|_{\mathbf{R}_{k+1}}^2] \\ & \quad (27) \end{aligned}$$

考虑由于模型误差引起的估计性能的恶化,将 Kalman 滤波的代价函数进行改进。新的代价函数如式(28)所示。

$$J(\alpha_k) = E\{\|\mathbf{x}_k - \hat{\mathbf{x}}_{k|k}\|_{\mathbf{P}_{k|k}}^2 + \|\mathbf{w}_k\|_{\mathbf{Q}_k}^2 + \|\mathbf{y}_{k+1} - \bar{\mathbf{C}}_{k+1}(\boldsymbol{\varepsilon}_{k+1})\bar{\mathbf{x}}_{k+1}\|_{\mathbf{R}_{k+1}}^2\} = \|\alpha_k\|_{\boldsymbol{\Phi}_k}^2 + E\{\|\mathbf{H}_k(\boldsymbol{\varepsilon}_k, \boldsymbol{\varepsilon}_{k+1})\alpha_k - \boldsymbol{\beta}_k(\boldsymbol{\varepsilon}_k, \boldsymbol{\varepsilon}_{k+1})\|_{\boldsymbol{\Psi}_k}^2\} \quad (28)$$

其中,

$$\begin{cases} \boldsymbol{\Psi}_k = \mathbf{R}_{k+1}^{-1} \\ \mathbf{H}_k(\boldsymbol{\varepsilon}_k, \boldsymbol{\varepsilon}_{k+1}) = \bar{\mathbf{C}}_k(\boldsymbol{\varepsilon}_{k+1}) \times [\bar{\mathbf{A}}_k(\boldsymbol{\varepsilon}_k) \quad \bar{\mathbf{B}}_k(\boldsymbol{\varepsilon}_k)] \\ \boldsymbol{\beta}_k(\boldsymbol{\varepsilon}_k, \boldsymbol{\varepsilon}_{k+1}) = \mathbf{y}_{k+1} - \bar{\mathbf{C}}_k(\boldsymbol{\varepsilon}_{k+1})\bar{\mathbf{A}}_k(\boldsymbol{\varepsilon}_k)\hat{\mathbf{x}}_{k|k} \\ \boldsymbol{\Phi}_k = \text{diag}\{\mathbf{P}_{k|k}^{-1}, \mathbf{Q}_k^{-1}\} \\ \alpha_k = \text{col}\{\bar{\mathbf{x}}_k - \hat{\mathbf{x}}_{k|k}, \mathbf{w}_k\} \end{cases} \quad (29)$$

式(28)中的代价函数以引入数学期望的方法考虑随机模型误差引起的估计性能下降,而当不存在模型误差时,式(28)的代价函数退化为标准 Kalman 滤波的代价函数。根据矩阵 $\boldsymbol{\Phi}_k$ 和 $\boldsymbol{\Psi}_k$ 的定义,易知代价函数 $J(\alpha_k)$ 是一个严格凸函数, $\partial J(\alpha_k)/\partial \alpha_k = 0$ 处存在全局唯一最小值 $\alpha_{k,opt}$, 将式(28)的代价函数展开,可得:

$$J(\alpha_k) = \alpha_k^T \boldsymbol{\Phi}_k \alpha_k + E\{\alpha_k^T \mathbf{H}_k(\boldsymbol{\varepsilon}_k, \boldsymbol{\varepsilon}_{k+1})^T \boldsymbol{\Psi}_k \mathbf{H}_k(\boldsymbol{\varepsilon}_k, \boldsymbol{\varepsilon}_{k+1}) \boldsymbol{\varepsilon}_k + \boldsymbol{\beta}_k(\boldsymbol{\varepsilon}_k, \boldsymbol{\varepsilon}_{k+1})^T \boldsymbol{\Psi}_k \boldsymbol{\beta}_k(\boldsymbol{\varepsilon}_k, \boldsymbol{\varepsilon}_{k+1}) - \alpha_k^T \mathbf{H}_k(\boldsymbol{\varepsilon}_k, \boldsymbol{\varepsilon}_{k+1})^T \boldsymbol{\Psi}_k \boldsymbol{\beta}_k(\boldsymbol{\varepsilon}_k, \boldsymbol{\varepsilon}_{k+1}) - \boldsymbol{\beta}_k(\boldsymbol{\varepsilon}_k, \boldsymbol{\varepsilon}_{k+1})^T \boldsymbol{\Psi}_k \mathbf{H}_k(\boldsymbol{\varepsilon}_k, \boldsymbol{\varepsilon}_{k+1}) \alpha_k\} \quad (30)$$

对式(30)求 α_k 的偏导,并且令 $\partial J(\alpha_k)/\partial \alpha_k = 0$, 可得:

$$(\boldsymbol{\Phi}_k + E\{\mathbf{H}_k(\boldsymbol{\varepsilon}_k, \boldsymbol{\varepsilon}_{k+1})^T \boldsymbol{\Psi}_k \mathbf{H}_k(\boldsymbol{\varepsilon}_k, \boldsymbol{\varepsilon}_{k+1})\})\alpha_k = E\{\mathbf{H}_k(\boldsymbol{\varepsilon}_k, \boldsymbol{\varepsilon}_{k+1})^T \boldsymbol{\Psi}_k \boldsymbol{\beta}_k(\boldsymbol{\varepsilon}_k, \boldsymbol{\varepsilon}_{k+1})\} \quad (31)$$

将式(30)代入式(31)可得:

$$\begin{aligned} & \left(\begin{bmatrix} \mathbf{P}_{k|k}^{-1} & \mathbf{0} \\ \mathbf{0} & \mathbf{Q}_k^{-1} \end{bmatrix} + E\left\{ \begin{bmatrix} \bar{\mathbf{A}}_k^T(\boldsymbol{\varepsilon}_k) \\ \bar{\mathbf{B}}_k^T(\boldsymbol{\varepsilon}_k) \end{bmatrix} \bar{\mathbf{C}}_{k+1}^T(\boldsymbol{\varepsilon}_{k+1}) \mathbf{R}_{k+1}^{-1} \times \right. \right. \\ & \left. \left. \bar{\mathbf{C}}_{k+1}(\boldsymbol{\varepsilon}_{k+1}) [\bar{\mathbf{A}}_k(\boldsymbol{\varepsilon}_k) \quad \bar{\mathbf{B}}_k(\boldsymbol{\varepsilon}_k)] \right\} \right) \times \begin{bmatrix} \bar{\mathbf{x}}_k - \hat{\mathbf{x}}_{k|k} \\ \mathbf{w}_k \end{bmatrix} = \end{aligned}$$

$$\begin{aligned} & E\left\{ \begin{bmatrix} \bar{\mathbf{A}}_k^T(\boldsymbol{\varepsilon}_k) \\ \bar{\mathbf{B}}_k^T(\boldsymbol{\varepsilon}_k) \end{bmatrix} \bar{\mathbf{C}}_{k+1}^T(\boldsymbol{\varepsilon}_{k+1}) \right\} \mathbf{R}_{k+1}^{-1} \mathbf{y}_{k+1} - \\ & E\left\{ \begin{bmatrix} \bar{\mathbf{A}}_k^T(\boldsymbol{\varepsilon}_k) \\ \bar{\mathbf{B}}_k^T(\boldsymbol{\varepsilon}_k) \end{bmatrix} \bar{\mathbf{C}}_{k+1}^T(\boldsymbol{\varepsilon}_{k+1}) \mathbf{R}_{k+1}^{-1} \right. \\ & \left. \bar{\mathbf{C}}_{k+1}(\boldsymbol{\varepsilon}_{k+1}) \bar{\mathbf{A}}_k(\boldsymbol{\varepsilon}_k) \right\} \hat{\mathbf{x}}_{k|k} \end{aligned} \quad (32)$$

为简单表示,定义如下矩阵:

$$\begin{cases} \mathbf{H}_{k+1} = E\left\{ \begin{bmatrix} \bar{\mathbf{A}}_k^T(\boldsymbol{\varepsilon}_k) \\ \bar{\mathbf{B}}_k^T(\boldsymbol{\varepsilon}_k) \end{bmatrix} \bar{\mathbf{C}}_{k+1}^T(\boldsymbol{\varepsilon}_{k+1}) \mathbf{R}_{k+1}^{-1} \times \right. \\ \left. \bar{\mathbf{C}}_{k+1}(\boldsymbol{\varepsilon}_{k+1}) [\bar{\mathbf{A}}_k(\boldsymbol{\varepsilon}_k) \quad \bar{\mathbf{B}}_k(\boldsymbol{\varepsilon}_k)] \right\} \\ \mathbf{H}_{k+2} = \begin{bmatrix} \bar{\mathbf{A}}_k^T(\boldsymbol{\varepsilon}_k) \\ \bar{\mathbf{B}}_k^T(\boldsymbol{\varepsilon}_k) \end{bmatrix} \bar{\mathbf{C}}_{k+1}^T(\boldsymbol{\varepsilon}_{k+1}) \\ \mathbf{H}_{k+3} = \mathbf{H}_{k+1} [\mathbf{I}_{(n+dm) \times (n+dm)} \quad \mathbf{0}_{(n+dm) \times n}]' \end{cases} \quad (33)$$

最后,等式(32)可简化为:

$$(\boldsymbol{\Phi}_k + \mathbf{H}_{k+1})\alpha_k = \mathbf{H}_{k+2} \mathbf{R}_{k+1}^{-1} \mathbf{y}_{k+1} - \mathbf{H}_{k+3} \hat{\mathbf{x}}_{k|k} \quad (34)$$

注意:在所提出的鲁棒预测滤波方法中,关键点是 \mathbf{H}_{k+1} 和 \mathbf{H}_{k+2} 可以离线计算,而实际参数则受到模型误差 $\boldsymbol{\varepsilon}_k$ 的任意影响。假设 $\boldsymbol{\varepsilon}_k$ 的统计特性已知,则可以通过直接代数运算来求解 \mathbf{H}_{k+1} 和 \mathbf{H}_{k+2} 。否则可采用随机模拟^[32]的方式计算 \mathbf{H}_{k+1} 和 \mathbf{H}_{k+2} 。根据式(34)的代价函数,可得出此鲁棒预测滤波的递归程序。

第 1 步:初值估计

$$\begin{cases} \hat{\mathbf{x}}_{0|0} = \mathbf{P}_{0|0} E\{\bar{\mathbf{C}}_0(\boldsymbol{\varepsilon}_0)\} \mathbf{R}_0^{-1} \mathbf{y}_0 \\ \mathbf{P}_{0|0} = (\bar{\boldsymbol{\Pi}}_0^{-1} + E\{\bar{\mathbf{C}}_0^T(\boldsymbol{\varepsilon}_0) \mathbf{R}_0^{-1} \bar{\mathbf{C}}_0(\boldsymbol{\varepsilon}_0)\})^{-1} \end{cases} \quad (35)$$

其中, $\bar{\boldsymbol{\Pi}}_0 = E\{(\bar{\mathbf{x}}_0 - E(\bar{\mathbf{x}}_0))(\bar{\mathbf{x}}_0 - E(\bar{\mathbf{x}}_0))^T\}$ 。

第 2 步:参数修正

$$\begin{aligned} \mathbf{G}_k &\triangleq \mathbf{H}_{k+1} - \begin{bmatrix} \bar{\mathbf{A}}_k^T(0) \\ \bar{\mathbf{B}}_k^T(0) \end{bmatrix} \bar{\mathbf{C}}_{k+1}^T(0) \times \\ & \mathbf{R}_{k+1}^{-1} \bar{\mathbf{C}}_{k+1}(0) [\bar{\mathbf{A}}_k(0) \quad \bar{\mathbf{B}}_k(0)] = \begin{bmatrix} \mathbf{G}_{k+1} & \mathbf{G}_{k+2} \\ \mathbf{G}_{k+2}^T & \mathbf{G}_{k+3} \end{bmatrix} \end{aligned} \quad (36)$$

式中: \mathbf{G}_k 为 $(2n+md) \times (2n+md)$ 的矩阵, \mathbf{G}_{k+1} 、 \mathbf{G}_{k+2} 和 \mathbf{G}_{k+3} 分别为 $(n+md) \times (n+md)$ 、 $(n+md) \times n$ 和 $n \times n$ 的矩阵。

定义矩阵 $\hat{\bar{\mathbf{A}}}_k(0)$ 、 $\hat{\bar{\mathbf{B}}}_k(0)$ 、 $\hat{\mathbf{P}}_{k|k}$ 和 $\hat{\mathbf{Q}}_k$ 如式(37)所示。

$$\begin{cases} \hat{\mathbf{P}}_{k|k} = (\mathbf{P}_{k|k}^{-1} + \mathbf{G}_{k+1})^{-1} \\ \hat{\mathbf{Q}}_k = (\mathbf{Q}_k^{-1} + \mathbf{G}_{k+2} - \mathbf{G}_{k+2}^T \hat{\mathbf{P}}_{k|k} \mathbf{G}_{k+2})^{-1} \\ \hat{\bar{\mathbf{B}}}_k(0) = \bar{\mathbf{B}}_k(0) - \bar{\mathbf{A}}_k(0) \hat{\mathbf{P}}_{k|k} \mathbf{G}_{k+2} \\ \hat{\bar{\mathbf{A}}}_k(0) = (\bar{\mathbf{A}}_k(0) - \hat{\bar{\mathbf{B}}}_k(0) \hat{\mathbf{Q}}_k \mathbf{G}_{k+2}^T) \times \\ (\mathbf{I}_{n+md} - \hat{\mathbf{P}}_{k|k} \mathbf{G}_{k+1}) \end{cases} \quad (37)$$

第 3 步:状态估计和估计方差更新,分别计算 $\hat{\mathbf{x}}_{k+1|k+1}$ 和 $\mathbf{P}_{k+1|k+1}$

$$\begin{aligned} \hat{x}_{k+1|k+1} &= \hat{A}_k(0)\hat{x}_{k|k} + P_{k+1|k+1} \times \\ & (P_{k+1|k}^{-1}(\hat{A}_k(0)\hat{P}_{k|k}[\mathbf{I}_{n+md} \quad \mathbf{0}_{(n+md) \times n}]) + \\ & \hat{B}_k(0)\hat{Q}_k\hat{B}_k^T(0)[-G_{k12}^T\hat{P}_{k|k} \quad \mathbf{I}_n])H_{k2}R_{k-1}^{-1}y_{k-1} - \\ & \bar{C}_{k+1}^T(0)R_{k+1}^{-1}\bar{C}_{k+1}(0)\hat{A}_k(0)\hat{x}_{k|k} \end{aligned} \quad (38)$$

其中 $P_{k+1|k}$, $R_{e,k+1}$, $P_{k+1|k+1}$ 的更新公式,如式(39)所示。

$$\begin{cases} P_{k+1|k} = \bar{A}_k(0)\hat{P}_k\bar{A}_k^T(0) + \hat{B}_k(0)\hat{Q}_k\hat{B}_k^T(0) \\ R_{e,k+1} = R_{e,k} + \bar{C}_{k+1}(0)P_{k+1|k}\bar{C}_{k+1}^T(0) \\ P_{k-1|k+1} = P_{k-1|k} - P_{k+1|k}\bar{C}_{k+1}^T(0)R_{e,k+1}^{-1} \times \\ \bar{C}_{k+1}(0)P_{k+1|k} \end{cases} \quad (39)$$

以上3步则为基于文献[25]的鲁棒状态估计改进的鲁棒预测滤波算法的递归程序全部内容,递归程序的推导与文献[25]中的推导过程类似,因此本文省略。此鲁棒预测滤波算法与Kalman类似,也是进行一些矩阵运算,但是如式(37)~(39)所示,此算法的递归程序会涉及到一些求逆运算,并且由于系统矩阵的扩维,求逆矩阵的维度也会随融合目标轨迹延迟帧数的增大而增大,因此方法只适合如光电跟踪系统这种目标轨迹延迟帧数较小的场景。

6 仿真实验

上述的这4种预测滤波算法计算复杂度不同,无法全部都在实际的实验平台实现。因此取实际实验平台的被控对象进行仿真实验。由于两轴的相似性,本实验吊舱实验平台的方位轴的速度开环对象进行仿真实验,如图3和4所示,它们分别为吊舱实验平台实物图和吊舱实验平台方位轴的速度开环对象频域拟合图。

根据图4的拟合结果,吊舱实验平台方位轴的速度开环对象如式(40)所示。

$$G_v(s) = \frac{5.321 \cdot e^{-0.00023s}}{(3.1831s + 1)(0.01s + 1)} \quad (40)$$

参照文献[12-13]的控制器设计方法,将系统速度回路控制器和位置回路控制器设计。




图3 吊舱实验平台实物




图4 吊舱实验平台速度开环对象频域拟合(方位轴)

$$C_v(s) = \frac{44.297 \cdot (0.0073s + 1)}{(0.0061s + 1)(0.00045s + 1)} \quad (41)$$

$$C_p(s) = \frac{15.609 \cdot (0.066s + 1)}{0.046s + 1} \quad (42)$$

基于式(40)~(42)提供的被控对象以及控制器,同时考虑陀螺的延迟和CCD的延迟,利用MATLAB Simulink工具箱设计基于预测滤波的光电跟踪技术仿真实验如图5所示。图中PFA表示前馈控制器模块,分别用本文提到的4种预测滤波算法来实现。

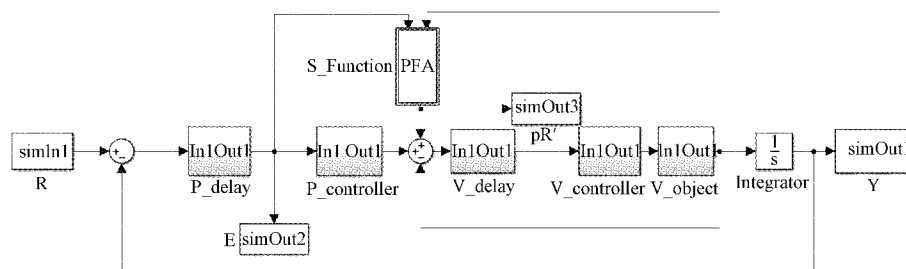


图5 基于预测滤波的光电跟踪技术 Simulink 仿真

图6从频域展示了5种方法的误差抑制特性对比结果,这里的误差抑制特性是指跟踪误差与目标轨迹的幅值比,曲线越低跟踪性能越好。图中①表示未添加前馈控制

的传统位置-速度双闭环控制(dual-closed loop, DCL),②、③、④和⑤分别表示采用PFA-OPDF、PFA-KF、PFA-IMM和PFA-RSE算法来实现仿真实验中的前馈控制器。根据

图 6 的结果可知,4 种基于预测滤波的等效速度前馈方法能够在传统位置-速度闭环基础上提升系统的跟踪性能。其中在低频(3 Hz 以下),PFA-KF 的性能是所有参与对比的方法中最好的。PFA-RSE 则次之。PFA-IMM 和 PFA-OPDF 则最差。而在中高频(3 Hz 以上),DCL 和 PFA-OPDF, PFA-RSE 则次之,最差的是 PFA-KF 和 PFA-IMM。PFA-RSE 在全频段的性能都属于较好的第 2 档,是一种均衡性较好的方法。




图 6 5 种方法的误差抑制特性

注:本仿真实验中 Kalman 滤波采用匀加速模型和文献[14]使用的预测方法;交互式多模型算法模型只包含匀加速模型和匀加速模型,模型概率分别设置为 0.5;基于正交多项式数据拟合的预测算法选用的数据点个数为 10,多项式的阶数为 3。

图 7 所示为时域的目标轨迹和模拟的融合轨迹,图中实线是由匀速模型添加模型不确定性随机产生的目标轨迹,虚线是添加了时延和噪声的模拟融合轨迹。图 8 所示为这 5 种跟踪方法对图 7 给出的目标轨迹进行跟踪之后的跟踪误差时域曲线。为使对比效果更明显,分别取 5 种跟踪方法的 20 s 的数据来进行对比。根据图 8 所示的实验结果,4 种基于预测滤波的等效速度前馈控制均能够进一步提升系统的跟踪能力。其中 PFA-OPDF 的跟踪较 DCL 的提升效果并不显著,其余的 3 种方法较 DCL 的提升效果明显,且提升效果基本相当。下面使用统计方式进一步对比。

表 1 中第 2 列表示每种跟踪方法的跟踪误差标准差,用于评价各种跟踪方法的时域跟踪性能。PFA-KF 的跟踪误差标准差是最小的,PFA-IMM 和 PFA-RSE 的跟踪误差标准差较 PFA-KF 稍微偏大,可以说 PFA-KF 效果相当。然后 DCL 外,最差的 PFA-OPDF。表 1 中第 3 列表示每种预测滤波算法每一帧的平均运算时间,是利用每种预测滤波算法所占用的总时间除以整个实验的总帧数计算得到(本实验采样时间为 0.01 s,总时间为 100 s,因此总帧数是 10 000 帧),用于评价对比各种预测滤波算法的计算复杂度。计算复杂度最低是 PFA-KF,PFA-OPDF 与其相当(PFA-OPDF 的运算时间取决于用于拟合的数据点个数,本实验选取的数据点个数为 10,因此计算量较小)。本

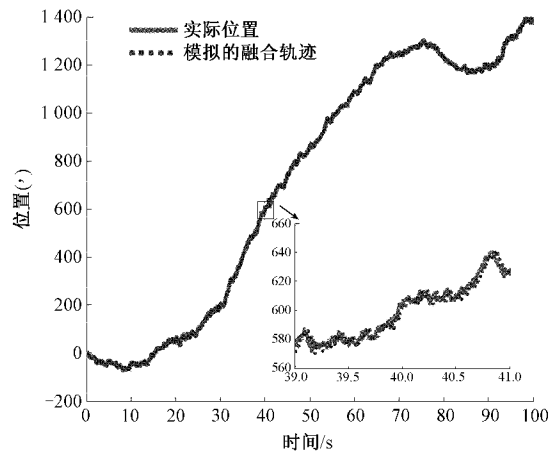


图 7 目标轨迹和模拟的融合轨迹




图 8 5 种方法的跟踪误差对比

实验中 PFA-IMM 的模型集只有两个模型,在交互计算时还需用到一些额外计算量。因此表 1 中 PFA-IMM 每一帧的平均运算时间是 PFA-KF 的 2.65 倍是合理的。PFA-RSE 相较于模型集只有两个模型的 PFA-IMM 复杂度稍高,主要原因是 PFA-RSE 对系统矩阵做了扩维,并且在迭代滤波时会用几个矩阵求逆运算。但一旦 PFA-IMM 的模型集扩大,PFA-RSE 的计算复杂度会低于 PFA-IMM。

表 1 跟踪误差及计算复杂度对比

方法	跟踪误差标准差/($^{\circ}$)	每一帧的平均运算时间/ms
①DLC	18.937 7	
②PFA-OPDF	11.380 5	0.029 032
③PFA-KF	3.700 3	0.021 832
④PFA-IMM	3.974 0	0.057 855
⑤PFA-RSE	4.210 5	0.065 520

根据本次仿真实验的结果,在低频和模型不确定性较小的情况下,采用 PFA-KF 是比较恰当的,该方法频域上

低频误差抑制特性、时域的跟踪误差以及计算复杂度均表现出色。但该方法的缺陷是面临目标存在极强的模型不确定性,跟踪精度易受到影响。PFA-IMM在低频的误差抑制特性算是4种方法中较差的,主要原因模型集和模型概率的设计不符,但此方法在时域表现出色,跟踪精度与PFA-KF相当,这是由于时域实验的目标轨迹与PFA-IMM使用的模型集和模型概率匹配度较高,但计算复杂度是PFA-KF的2.65倍。除非是对目标模型集以及模型概率非常了解的情况下,否则不推荐使用此方法。PFA-OPDF在时域和频域的表现都很一般,主要原因是数据拟合的方法相较于滤波器而言精度本来就不高,并且数据点个数和多项式的阶数这两个参数的选择很重要。这种方法优点在于它不需要知道目标模型,不过它的缺点也是当目标处于不同的模型的时,应该选用不同的数据点个数和多项式的阶数。算法的复杂度与数据点个数的选择有关。PFA-RSE方法的本质是对Kalman滤波考虑预测和模型不确定性进行改进,从频域的特性可看出,此方法综合性较强,全频段的性能都相对较好。时域上看,跟踪性能与PFA-KF相当。但其在PFA-KF的基础上考虑模型不确定性,当目标的模型不确定性较强时,它会表现出比PFA-KF更好的鲁棒性能。不过此方法的运算复杂度略高且只适用于短时间的预测。

7 结 论

本文对基于预测滤波的光电跟踪技术进行了回顾,主要介绍了4种主流的预测滤波算法。然后分别从频域和时域对比这4种基于预测滤波的光电跟踪技术,分析了这4种方法的优缺点,可供控制器的设计者参考和选择。随着目标机动性的不断增强,目标运动规律将会越来越弱,这将导致目标的运动模型难以确定。目标运动模型不确定性的增强将会使依赖于模型的预测滤波算法失效。由于目标当前的运动模型以及模型误差等统计特性通常是无法提前得知的,如果继续沿用依赖于模型的预测滤波算法,则需要考虑在线识别模型和变模型的预测滤波算法。另一方面基于数据驱动的无模型预测滤波算法也将会是未来发展的方向。

参考文献

- [1] 马佳光. 捕获跟踪与瞄准系统的基本技术问题[J]. 光电工程, 1989(3): 1-10.
- [2] 唐涛, 马佳光, 陈洪斌, 等. 光电跟踪系统中精密控制技术进展[J]. 光电工程, 2020, 47(10): 3-31.
- [3] 胡钦涛, 周国忠. 光电跟踪设备 EMC 滤波技术研究[J]. 国外电子测量技术, 2017, 36(2): 104-107.
- [4] 曹政. 基于时滞补偿的机动目标跟踪技术研究[D]. 北京: 中国科学院大学(中国科学院光电技术研究所), 2017.
- [5] 陈丹琪, 金国栋, 谭力宁, 等. 一种基于KL-AEPF的无人
- 机侦察移动目标定位算法[J]. 仪器仪表学报, 2019, 40(9): 227-236.
- [6] 林跃, 梁立容, 王凤, 等. 基于STC12C5A60S2的无人机遥控器的设计与实现[J]. 电子测量技术, 2017, 40(8): 212-216.
- [7] 邓超. 运动平台预测跟踪技术研究[D]. 北京: 中国科学院大学(中国科学院光电技术研究所), 2018.
- [8] BARNARD T W, FENCIL C R. Digital laser ranging and tracking using a compound axis servomechanism [J]. Applied Optics, 1966, 5(4): 497-505.
- [9] 傅承毓, 马佳光, 叶步霞, 等. 复合轴控制系统应用研究[J]. 光电工程, 1998, 25(4): 1-12.
- [10] 王毅, 高伟志, 王贵文, 等. 光电精密跟踪的双重复合轴伺服系统[J]. 光学精密工程, 1996, 4(4): 58-61.
- [11] 王红红, 陈方斌, 寿少峻, 等. 基于FSM的高精度光电复合轴跟踪系统研究[J]. 应用光学, 2010, 31(6): 909-913.
- [12] 黄永梅, 马佳光, 付承毓. 目标速度预测在光电跟踪控制系统中的应用[J]. 红外与激光工程, 2004(5): 477-481.
- [13] TANG T, TIAN J, ZHONG D J, et al. Combining charge couple devices and rate sensors for the feedforward control system of a charge coupled device tracking loop[J]. Sensors, 2016, 16(7): 968.
- [14] HE Q, LUO Y, MAO Y, et al. An acceleration feed-forward control method based on fusion of model output and sensor data[J]. Sensors and Actuators A: Physical, 2018, 284: 186-193.
- [15] KALMAN R E. A new approach to linear filtering and prediction problems[J]. Transactions of the ASME—Journal of Basic Engineering, 1960, 82(1): 35-45.
- [16] 燕必希, 朱立夫, 董明利, 等. 卡尔曼滤波在单目相机运动目标定位中的研究[J]. 仪器仪表学报, 2018, 39(8): 220-229.
- [17] 沈飞, 李荣冰, 刘建业, 等. 基于卡尔曼滤波的北斗接收机高灵敏度跟踪算法研究[J]. 电子测量技术, 2017, 40(9): 88-94.
- [18] 王建平, 郑成强, 徐晓冰, 等. 基于卡尔曼滤波的微电网同步并网研究[J]. 电子测量与仪器学报, 2017, 31(5): 809-815.
- [19] DENG C, MAO Y, REN W, et al. Feedforward control based on orthogonal least square for a charge-coupled device-based tracking loop[C]. 2017 Chinese Automation Congress(CAC), 2017: 6877-6881.
- [20] CAO Z, MAO Y, DENG C, et al. Research of maneuvering target prediction and tracking technology based on IMM algorithm[C]. International Symposium on Advanced Optical Manufacturing & Testing

- Technologies: Optical Test, International Society for Optics and Photonics, 2016.
- [21] MAO Y, HE Q, ZHOU X, et al. A feedforward method based on support vector machine[C]. 2018 Chinese Automation Congress(CAC), 2018.
- [22] KHARGONEKAR P P, NAGPAL K M. Filtering and smoothing in an H/sup infinity/setting[C]. IEEE Conference on Decision & Control, IEEE, 2002, 36(2):152-166.
- [23] BERTSEKAS D P, RHODES I B. Recursive state estimation for a set-membership description of uncertainty [J]. IEEE Transactions on Automatic Control, 2003, 16(2):117-128.
- [24] JAIN B N. Guaranteed error estimation in uncertain systems [J]. IEEE Transactions on Automatic Control, 1975, 20(2):230-232.
- [25] LIU H, ZHOU T. Robust state estimation for uncertain linear systems with random parametric uncertainties[J]. Science China Information Sciences, 2017, 60(1):1-13.
- [26] 常锦才,赵龙,杨倩丽. 基于正交多项式的数据拟合方法[J]. 河北理工大学学报(自然科学版),2011,33(4):79-84.
- [27] 毕进,雷璐,郭敏. 基于卡尔曼滤波的机动目标外推预测的研究[J]. 现代电子技术,2012,35(11):42-45,48.
- [28] HE Q, MAO Y, ZHOU X, et al. An improved feedforward controller design method [C]. 9th International Symposium on Advanced Optical Manufacturing and Testing Technologies: Optical Test, Measurement Technology, and Equipment, 2019.
- [29] 王强,傅承毓,陈科,等. 预测轨迹修正单检测型复合轴控制方法[J]. 光电工程, 2007, 34(4):17-21.
- [30] 陆建山. 水面武器操瞄系统稳定平台姿态测量及控制技术研究[D]. 南京:南京理工大学,2013.
- [31] BEST R A, NORTON J P. A new model and efficient tracker for a target with curvilinear motion[J]. IEEE Transaction on Aerospace and Electronic System, 1997, 33(31): 1030-1037.
- [32] RUBINSTEIN R Y, KROESE D P. Simulation and the monte carlo method[M]. New York:John Wiley & Sons, 2008.

作者简介

何秋农,在读博士研究生,主要研究方向为基于预测滤波技术的光电跟踪控制技术。

E-mail:heqiunong_ioe@163.com

毛耀(通信作者),研究员,博导,主要研究方向为光束控制。

E-mail:maoyao@ioe.ac.cn