

doi:10.6041/j.issn.1000-1298.2022.10.004

基于滚动时域的无人水稻直播机运动状态估计

武 涛¹ 李彦明¹ 徐长赓¹ 刘汉文¹ 陈小倩² 刘成良¹

(1. 上海交通大学机械与动力工程学院, 上海 200240; 2. 上海上实现代农业开发有限公司, 上海 202183)

摘要: 针对农业机械自动驾驶中非线性车辆模型具有未知干扰输入, 以及测量输出不确定等问题, 提出一种基于滚动时域的车辆运动状态估计方法(MHE)。将状态估计问题转化为固定时域的优化问题并充分考虑约束条件, 从而实现对带约束非线性模型状态的估计。为提高MHE的计算效率并且考虑传感器采样频率不同, 以及可能出现测量值缺失或异常, 设计出一种多线程运行架构, 使MHE更适合实际应用。使用Matlab建立水稻直播机自动驾驶仿真系统, 仿真结果表明, MHE算法能有效补偿系统干扰和消除测量噪声, MHE估计出的横纵位置和航向角相比扩展卡尔曼滤波(EKF)估计出的更接近系统真值。使用MHE状态估计算法对水稻直播机无人作业过程中测得的横向偏差与航向角偏差进行估计。结果表明, 时域窗口N取3~5时, MHE算法对消除状态的稳态误差和抑制测量值的不平稳性具有良好的效果, 同时也能较好地反映状态值的真实变化, 证明了MHE算法在补偿系统干扰和消除测量误差方面的优异性。

关键词: 无人水稻直播机; 自动驾驶; 滚动时域估计; 多线程架构中图分类号: S223.2⁺3; TP242.3 文献标识码: A 文章编号: 1000-1298(2022)10-0036-08

OSID:



Motion States Estimation for Unmanned Rice Seeding Machine Based on Moving Horizon Estimation

WU Tao¹ LI Yanming¹ XU Changgeng¹ LIU Hanwen¹ CHEN Xiaoqian² LIU Chengliang¹

(1. School of Mechanical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China

2. Shangshi Modern Agricultural Development Co., Ltd., Shanghai 202183, China)

Abstract: Aiming at the problems that there is a lot of uncertain disturbance in the nonlinear vehicle model of agricultural machinery, and the measurement is often with noise, the moving horizon estimation (MHE) method for vehicle motion state was proposed. The state estimation problem was transformed into a fixed time domain optimization problem and the constraint conditions were fully considered. In order to improve the computational efficiency of MHE, taking into account the different sampling frequencies of sensors and the possibility of missing or abnormal measurement values, a multi-threading architecture was designed. The multi-threading architecture also can make MHE more suitable for practical applications. The automatic driving simulation system of the rice seeding machine was established by Matlab. The simulation results showed that MHE can effectively suppress system disturbance and measurement noise. The x and y positions and heading angle estimated by MHE were closer to the truth value than those estimated by extended Kalman filter (EKF). MHE was used to estimate the lateral deviation and heading angle deviation measured during the autonomous driving process of the rice seeding machine. The results showed that when the time domain window N was 3~5, the MHE algorithm had a good effect on suppressing the jump of measurement value, and it can also reflect the real trend of state value. It proved that MHE had excellent performance in suppressing system disturbance and measurement noise.

Key words: unmanned rice seeding machine; autonomous driving; moving horizon estimation; multi-threading architecture

收稿日期: 2021-11-25 修回日期: 2021-12-14

基金项目: 国家重点研发计划项目(2021YFD2000602)和上海市科技兴农项目(沪农科推字(2019)第4-3号)

作者简介: 武涛(1996—), 男, 博士生, 主要从事农机自动驾驶与自主作业研究, E-mail: wutaosjtu@sjtu.edu.cn

通信作者: 李彦明(1971—), 男, 副教授, 博士, 主要从事非结构化环境下移动机器人自主导航与自主作业研究, E-mail: yml@sjtu.edu.cn

0 引言

在水稻直播机实际的自主作业过程中,传感器易受到环境状况的干扰导致测量输出不准确或者某些状态难以测得。此外,由于水田环境结构复杂多变,也会给直播机带来许多不确定性扰动^[1-3]。因此,为提高水稻直播机在自动驾驶过程中的抗干扰能力以及得到较为准确合理的状态值,需采取一定的状态估计方法。

许多学者在自动驾驶车辆状态估计方法上进行了大量的探索研究^[4-11]。作为一种基于模型在隐马尔可夫链上的递归贝叶斯估计,卡尔曼滤波(Kalman filter, KF)相关理论已非常成熟^[12-13],被证明是无约束系统最小方差意义下的最优估计,目前是无约束动态系统状态估计应用最普遍的方法^[14-17]。基于线性模型的 KF 针对非线性模型无法实现精确估计,而采取将非线性模型线性化的扩展卡尔曼滤波(Extended Kalman filter, EKF)和基于 UT 变换的无迹卡尔曼滤波(Unscented Kalman filter, UKF)能较精确地实现对无约束非线性模型状态的估计^[18-22]。文献[18]提出一种基于 EKF 的多传感融合通用框架,用于微型飞行器导航定位。该算法理论上能处理无限多类型传感器及其延迟,以及传感器相对或绝对测量,最终对飞行器的状态信息进行估计。文献[20]分别采用 EKF 和 UKF 估计航天器的位置和速度,结果表明 UKF 的平均估计精度较高,因为使用先验测量分布的无迹变换(UKF)比基于线性近似的 EKF 更接近原始分布。文献[22]使用 UKF 融合 GPS、IMU 和车轮编码器的测量值对车辆姿态进行估计,使用 Stanley 控制器作为路径跟踪控制算法,提高了车辆自动驾驶的定位精度和鲁棒性。虽然卡尔曼滤波被广泛应用,但是它不能处理状态量的约束,有可能出现不符合物理实际的估计值,并且它要求系统模型必须准确,否则可能出现发散的情况。

基于滚动优化原理的滚动时域估计(Moving horizon estimation, MHE)通过将状态估计问题转化为固定时域的优化问题,能较好地处理状态量的约束和带有不确定性的非线性系统,目前在跟踪定位、故障诊断、参数估计等领域得到了广泛的研究与应用^[23-30]。文献[25]使用 MHE 状态估计方法解决传感器具有时滞、丢失值和不同频率的问题,此外,还引入了线性模型 MHE 的高效计算方法,但仅适用于可以找到线性 MHE 问题解析解的情况。文献[27]针对移动机器人的位姿估计问题提出一种基于 MHE 高效通用的多传感器融合

方案,此方案基于多线程架构,降低了计算成本。利用仿真和真实实验数据对该方案进行测试,并与 UKF 进行比较,结果表明 MHE 估计性能优于 UKF。文献[30]基于纵滑侧偏联合工况下的八自由度整车模型,并考虑车辆系统现实存在的物理约束,使用 MHE 对车辆的速度等参数进行了估计,估计结果较为符合实际情况。

针对无人水稻直播机自动驾驶过程中难以获得精确的车辆模型以及传感器测量存在误差等问题,本文设计一种基于滚动时域的车辆运动状态估计方法,在每个采样区间内通过求解优化问题的极小值估计出车辆在当前时刻的状态值:横向偏差和航向角偏差,以提高车辆的抗干扰能力和路径跟踪控制精度。

1 滚动时域估计原理

基于模型预测滚动优化原理来讨论 MHE 的数学原理,受扰动离散的非线性状态空间表达式为

$$\begin{cases} \mathbf{x}(k+1) = \mathbf{f}(\mathbf{x}(k), \mathbf{u}(k)) + \mathbf{w}(k) \\ \mathbf{z}(k) = \mathbf{h}(\mathbf{x}(k)) + \mathbf{v}(k) \end{cases} \quad (1)$$

式中 k —采样时刻 $\mathbf{x}(k)$ —状态变量
 $\mathbf{u}(k)$ —控制输入 $\mathbf{w}(k)$ —外部干扰
 $\mathbf{z}(k)$ —测量向量 $\mathbf{v}(k)$ —测量噪声
 \mathbf{f}, \mathbf{h} —非线性过程和测量模型

状态值和测量值历史序列为

$$\begin{cases} \mathbf{X} = (\mathbf{x}(0), \mathbf{x}(1), \dots, \mathbf{x}(k)) \in \mathbf{X}^{k+1} \\ \mathbf{Z} = (\mathbf{z}(1), \mathbf{z}(2), \dots, \mathbf{z}(k)) \in \mathbf{Z}^k \end{cases} \quad (2)$$

假设系统初始状态为 $\hat{\mathbf{x}}(0)$, \mathbf{P}_0 为初始时刻对称正定的协方差矩阵,反映对初始估计的信心。 $\check{\mathbf{x}}(i)$ 为 i 时刻使用 MHE 估计出的系统状态值,同时也是优化变量, $\hat{\mathbf{x}}(i)$ 是利用 $i-1$ 时刻系统状态估计值和控制输入根据系统模型计算出的 i 时刻状态的预测值。对当前时刻 k 的系统状态进行估计,全信息滚动时域估计可描述为以下优化问题

$$\min J(\check{\mathbf{X}}, \mathbf{Z}) = \| \check{\mathbf{x}}(0) - \hat{\mathbf{x}}(0) \|_{\mathbf{P}_0^{-1}}^2 + \sum_{i=1}^k \left\{ \| \check{\mathbf{x}}(i) - \hat{\mathbf{x}}(i) \|_{\mathbf{Q}_i^{-1}}^2 + \| \mathbf{z}(i) - \mathbf{h}(\check{\mathbf{x}}(i)) \|_{\mathbf{R}_i^{-1}}^2 \right\} \quad (3)$$

式中 $\mathbf{Q}_i, \mathbf{R}_i$ —正定的惩罚矩阵,反映对模型干扰和测量噪声的程度,通常为方差的对角矩阵

$\check{\mathbf{X}}$ —系统状态估计值

通过最小化式(3)可以求出历史所有状态的估计值,只取最后一个估计值作为当前时刻的状态值。新的采样时刻到来,将新的测量数据补充进测量序

列,在线重新求解式(3)。但随着时间的增加,数据越来越多,优化问题越来越复杂,直至不可解。并且随着时间的推移,过久的数据对当前状态的影响逐渐降低,因此,引入固定时域窗口 N ,考虑固定窗口的滚动时域估计,只使用最近 N 个状态值和测量值,有

$$\begin{cases} \check{\mathbf{X}}_N := (\check{\mathbf{x}}(k-N), \check{\mathbf{x}}(k-N+1), \dots, \check{\mathbf{x}}(k)) \in \mathbf{X}^{N+1} \\ \mathbf{Z}_N := (\mathbf{z}(k-N+1), \mathbf{z}(k-N+2), \dots, \mathbf{z}(k)) \in \mathbf{Z}^N \end{cases} \quad (4)$$

将系统模型作为等式约束,加上状态和控制的不等式约束,用优化问题替代全信息 MHE 问题,有

$$\begin{cases} \min J(\check{\mathbf{X}}_N, \mathbf{Z}_N) = \|\check{\mathbf{x}}(k-N) - \hat{\mathbf{x}}(k-N)\|_{P_{k-N}^{-1}}^2 + \\ \sum_{i=k-N+1}^k \{\|\check{\mathbf{x}}(i) - \hat{\mathbf{x}}(i)\|_{Q_i^{-1}}^2 + \|\mathbf{z}(i) - \mathbf{h}(\check{\mathbf{x}}(i))\|_{R_i^{-1}}^2\} \\ \text{s. t. } \begin{cases} \check{\mathbf{x}}(i) = f(\check{\mathbf{x}}(i-1), \mathbf{u}(i-1)) & (\forall k-N \leq i \leq k) \\ \check{\mathbf{x}}(i) \in X & (\forall k-N \leq i \leq k) \\ \mathbf{u}(i) \in U & (\forall k-N+1 \leq i \leq k) \end{cases} \end{cases} \quad (5)$$

式中 \mathbf{X}, \mathbf{U} 分别为状态值和控制量序列, $\|\check{\mathbf{x}}(k-N) - \hat{\mathbf{x}}(k-N)\|_{P_{k-N}^{-1}}$ 是 MHE 问题的到达代价, P_{k-N} 是第 $k-N$ 步状态的后验估计协方差矩阵,计算式为

$$\mathbf{P}_{k+1} = \mathbf{Q}_k + \mathbf{F}_k \mathbf{P}_k \mathbf{F}_k^T - \mathbf{F}_k \mathbf{P}_k \mathbf{H}_k^T (\mathbf{R}_k + \mathbf{H}_k \mathbf{P}_k \mathbf{H}_k^T)^{-1} \mathbf{H}_k \mathbf{P}_k \mathbf{F}_k^T \quad (6)$$

其中

$$\begin{cases} \mathbf{F}_k = \frac{\partial f}{\partial \mathbf{x}} \Big|_{x=\check{\mathbf{x}}_k} \\ \mathbf{H}_k = \frac{\partial \mathbf{h}}{\partial \mathbf{x}} \Big|_{x=\check{\mathbf{x}}_k} \end{cases} \quad (7)$$

式中 $\mathbf{F}_k, \mathbf{H}_k$ ——系统模型和测量模型雅可比矩阵

由此,通过 MHE 算法将状态估计问题转换成固定时域的优化问题,处理了系统约束、模型干扰和非线性以及测量噪声,能提高估计的合理性和准确性。

2 基于 MHE 的直播机运动状态估计器

2.1 带扰动的直播机运动学模型

要控制车辆首先要对车辆的运动建立数学模型,模型越精确对车辆的运动描述就越精确。由于在高度非结构化水田环境下,直播机动力学模型参数难以获取,因此建立简单易用的运动学模型。不考虑车辆在垂直方向的运动,假设车身系统为刚性,左右侧车轮具有相同的转向角度和速度,忽略车辆动力学特性,将直播机简化为二轮车模型,如图 1 所示。图中, $M(x_m, y_m)$ 为车体控制点; $A(x_a, y_a)$ 、 $B(x_b, y_b)$ 为期望路径 P 上的两点; θ_e 为航向角的期

望值。用横向偏差、航向角偏差、前轮转角、行驶速度和前后轮轴距等参数建立直播机的运动学模型,从而描述直播机的运动状态。

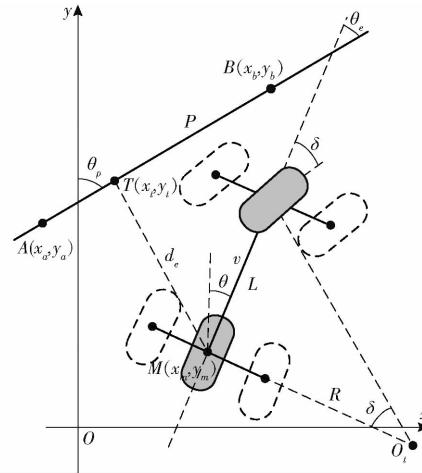


图 1 水稻直播机运动学模型

Fig. 1 Kinematic model of rice seeding machine

由于期望路径 AB 固定,所以航向角偏差的导数与航向角速度相等,即

$$\dot{\theta}_e = \dot{\theta} = \frac{v}{R} \quad (8)$$

式中 v ——速度, m/s

R ——转弯半径, m

θ ——航向角,(°)

θ_e ——航向角偏差,(°)

由图 1 中几何关系可得

$$R = \frac{L}{\tan \delta} \quad (9)$$

式中 L ——前后轮轴距, m

δ ——前轮转角, 控制输入,(°)

因此

$$\dot{\theta}_e = \frac{v \tan \delta}{L} \quad (10)$$

横向偏差的导数即为速度 v 在该方向上的分量,即

$$\dot{d}_e = v \sin \theta_e \quad (11)$$

式中 d_e ——横向偏差, m

以横向偏差 d_e 和航向角偏差 θ_e 为状态变量,同时考虑水田中地况复杂多变具有许多不确定性干扰,为避免未知干扰导致建模不准确,引入复合干扰项:横向位置干扰 $|w_1| \leq P$ 和航向角干扰 $|w_2| \leq K$, P 和 K 为干扰的最大值,由式(10)、(11)可得带干扰的直播机运动学模型为

$$\begin{cases} \dot{d}_e = v \sin \theta_e + w_1 \\ \dot{\theta}_e = \frac{v \tan \delta}{L} + w_2 \end{cases} \quad (12)$$

在实际应用中使用的是车辆离散模型,因此需对连续模型进行离散化。令采样周期为 T , 对

式(12)进行前向欧拉离散化得

$$\begin{cases} d_e(k+1) = d_e(k) + T v(k) \sin \theta_e(k) + w_1(k) \\ \theta_e(k+1) = \theta_e(k) + \frac{T v(k) \tan \delta(k)}{L} + w_2(k) \end{cases} \quad (13)$$

式(13)离散模型的状态量是基于横向偏差和航向角偏差,可由车辆装载的 RTK-GPS 传感器测出的位姿信息与期望位姿信息计算,由此得测量模型

$$\begin{cases} d_e = \frac{x_a(y_b - y_m) + x_b(y_m - y_a) + x_m(y_a - y_b)}{\sqrt{(x_a - x_b)^2 + (y_a - y_b)^2}} + v_1 \\ \theta_e = \theta - \arctan \frac{y_b - y_a}{x_b - x_a} + v_2 \end{cases} \quad (14)$$

式中 v_1, v_2 —测量噪声

2.2 MHE 估计器方案

式(13)、(14)为直播机离散的非线性状态空间表达式,可代入式(1),通过 MHE 的求解公式(5)进行直播机运动状态:横向偏差和航向角偏差的估计。可得 MHE 算法流程:

(1) 初始化 $\hat{x}(0)、P_0、Q、R$ 和 N ,当 $k \leq N$ 时,根据式(3)求解全信息 MHE 问题,估计出当前时刻 k 的状态 $\check{x}(k)$:横向偏差和航向角偏差。

(2) 当 $k > N$ 时,根据式(5)求解固定时域 MHE 问题,估计出窗口 N 内的状态 \check{x} :横向偏差和航向角偏差,把时刻 k 处的估计值作为当前时刻的状态值。

(3) 根据式(6)、(7)计算时刻 k 处状态的后验估计协方差矩阵 P_k 。

(4) 在 $k+1$ 时刻,得到新状态的测量值,更新窗口 N 内的数据,重复步骤(2)、(3)。

优化问题(式(5))的计算成本高度依赖于窗口 N 的大小,如果计算时间超过了传感器的最大采样周期,估计出的状态则不是当前采样时刻的,需采取一定方法提高 MHE 的计算效率。如图 2 所示,提出一种基于多线程的系统架构,为 M 个主要传感器的数据接收、分析与处理开辟单独的线程,用来构建测量矩阵,最后传递给 MHE 求解线程进行优化问题的求解。多个线程并行工作,可减少 MHE 总体计算时间,提高 MHE 采样频率。

如图 3 所示(图中 τ 为所有测量传感器采样周期最大值),该多线程架构也能解决多个传感器具有不同的测量频率。图中不同多边形代表每个传感器产生的有效值,虽然不同传感器的数据可能会在不同时刻收到,但每个传感器线程都会在有新数据到达时更新数据,因此传给 MHE 求解线程的数据

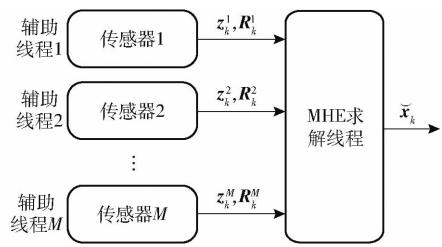


图 2 多线程 MHE 求解架构

Fig. 2 Multi-threading architecture of MHE

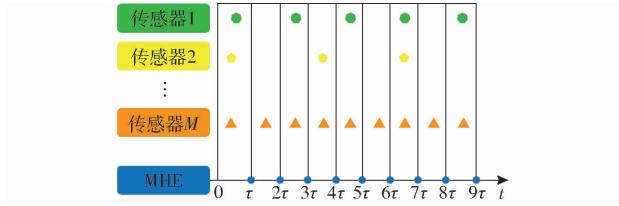


图 3 多频率传感器解决方案

Fig. 3 Solution of multi-frequency sensors

都是最新窗口内的。针对传感器出现的异常值使用马氏距离阈值法进行检验剔除,计算式为

$$\varepsilon_k^j = \| z_k^j - \hat{z}_k^j \|_{R^{-1}} \leq \zeta^j \quad (j = 1, 2, \dots, M) \quad (15)$$

式中 ε_k^j —马氏距离

ζ^j —马氏距离阈值

3 仿真验证

使用 Matlab 仿真验证 MHE 状态估计算法的有效性。根据图 4 控制系统结构图建立相应的仿真模型。控制算法采用文献[3]提出的快速终端滑模控制器,控制车辆从起点移动到终点,通过向直播机运动学模型和状态值加高斯白噪声来模拟系统干扰和测量误差。使用 MHE 和 EKF 对带噪声的状态进行估计并与系统状态真值比较,观察 MHE 和 EKF 的估计效果。直播机系统控制仿真参数同文献[3],MHE 仿真参数选取如表 1 所示。

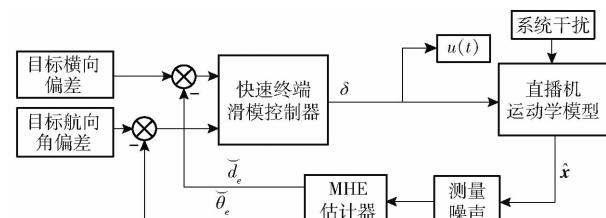


图 4 控制系统结构图

Fig. 4 Block diagram of control system

考虑 MHE 计算时间不能超过传感器采样周期 0.05 s,经过仿真测试选取时域窗口值 N 等于 5,单次计算所需时间约为 0.01 s,满足在线实时估计要求。使用高效的优化控制软件 CasADi 表述优化问题,然后使用内点法求解该优化问题。图 5、6 是整个行驶过程中车辆横纵坐标和航向角变化,蓝色曲线是仿真得到的系统真值,红色曲线

表 1 MHE 仿真参数

Tab. 1 Simulation parameters of MHE

参数	数值
$v/(m \cdot s^{-1})$	1.5
L/m	2
起点坐标/m	(0, 0)
终点坐标/m	(6, 6)
$\theta/(^\circ)$	-90
采样周期 T/s	0.05
ζ_{GPS}/m	1
$\zeta_\theta/(^\circ)$	20
位置噪声 σ_{GPS}/m	0.3
航向角噪声 $\sigma_\theta/(^\circ)$	4

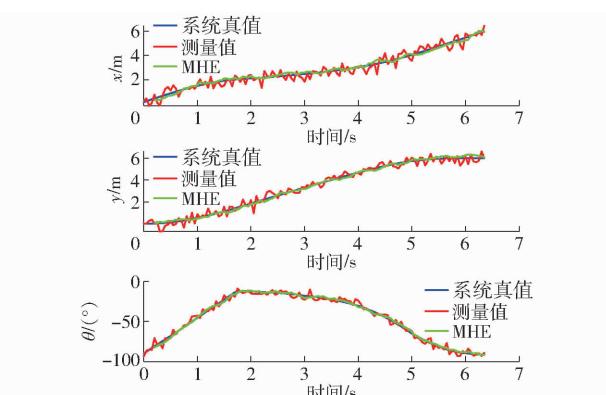


图 5 MHE 状态估计结果

Fig. 5 States estimation results with MHE

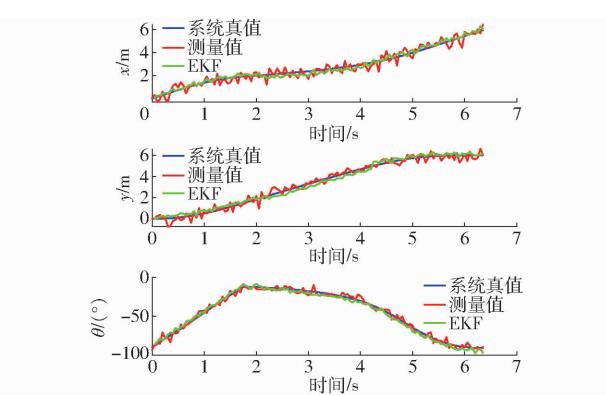


图 6 EKF 状态估计结果

Fig. 6 States estimation results with EKF

是带噪声的测量值,绿色曲线在图 5、6 中分别是使用 MHE 和 EKF 估计出的状态值。可以看出,测量值具有很大的不确定性,在真值附近波动,使用 MHE 和 EKF 能有效地从测量值中估计出较为准确的状态值。

图 7 为 MHE 和 EKF 状态估计绝对误差散点图,平均绝对误差如表 2 所示。可以看出,MHE 和 EKF 状态估计误差总体上比测量值误差小很多,说明二者具备从不确定信息中提取精确信息的能力。此外,MHE 状态估计误差也比 EKF 状态估计误差小,说明基于优化方法求解的滚动时域状态估计优

于传统的基于估计误差协方差的状态估计,证明了本文所提 MHE 状态估计算法的有效性。

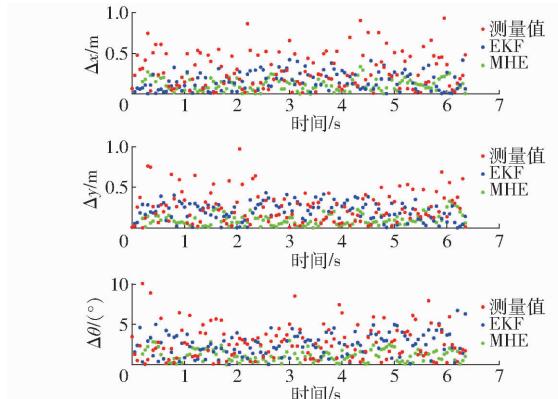


图 7 MHE 与 EKF 状态估计绝对误差

Fig. 7 Estimation error of MHE and EKF

表 2 状态估计平均绝对误差

Tab. 2 Mean absolute error of states estimation

类型	$\Delta x/m$	$\Delta y/m$	$\Delta \theta/(^\circ)$
测量值	0.3047	0.3052	3.1513
MHE	0.1378	0.1118	1.2777
EKF	0.1805	0.2067	2.3835

4 试验验证

4.1 试验平台

试验采用中国洋马农机有限公司生产的 YR10D 型水稻直播机,对该型号直播机进行自动驾驶改造,如图 8 所示。自动驾驶系统主控制器采用装载 Linux 系统的工业计算机,具有 4 核 1.6 GHz 高性能处理器、1 GB DDR3 运行内存、4 路带隔离的 3 线 RS-232 串口,1 路 CAN 总线以及 1 路 100 M 以太网等通信接口。上位机主控制器通过 CAN/RS-232 的通信方式与车身各子系统进行数据交互与协作,完成直播机自动驾驶和自主作业。下位机控制器为自行设计的 STM32 嵌入式控制器,具备 CAN/RS-232 通信方式。采用北京天海科公司生产的 DWQT-CAN-360-G 型转角传感器,精度为 0.1° ,通信方式为 CAN 总线。RTK-GPS 使用 4G 网络差分基站,动态定位精度在 ± 0.02 m,数据刷新率为 20 Hz,通信方式为 RS-232。方向盘使用直流电机驱动,采用位置-速度双闭环控制,通信方式为 RS-232。

该无人水稻直播机具备自动驾驶作业、精量播种、种箱容量检测及堵塞报警、自动倒车和全地块封边作业等功能。同时在阿里云服务器上搭建云监控管理系统,能实现远程监控、路径规划及多机协同作业管理。贯彻了“智慧在云,智能在端,管控在屏”的未来无人农场设计理念。



图 8 无人驾驶水稻直播机

Fig. 8 Unmanned rice seeding machine

4.2 水稻直播机水田无人作业试验

为验证本文所提 MHE 估计算法对无人水稻直播机运动状态的估计效果, 在上海市崇明区上实现现代农业开发有限公司建立的无人农场里使用图 8 所示直播机进行实际无人播种作业。图 9 为直播机一次试验时部分作业轨迹, 可以看出, 虽然直播机行驶轨迹总体较为平稳, 但由于水田中具有许多不确定性干扰以及传感器测量带有噪声, 直播机行驶轨迹在某些区域也会出现一定抖动。为了获取更加准确的状态值从而抑制这些抖动, 获取 8 段直线行驶路径的直播机运动状态 d_e 和 θ_e , 使用 MHE 算法进行估计。

选取路径 4 分析时域窗口 N 的大小对 MHE 估

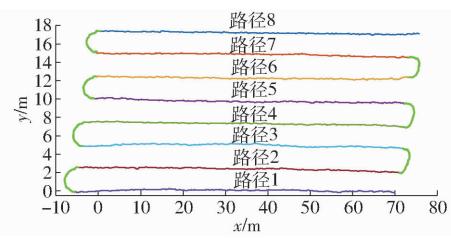


图 9 直播机作业轨迹

Fig. 9 Driving paths of rice seeding machine

计效果的影响。图 10 为 N 等于 1、3、5、10 时, 使用 MHE 对横向偏差与航向角偏差的估计结果。可以看出, 由于水田中具有许多不确定性干扰以及传感器测量带有噪声, 测量值在短时间内存在较大跳变, 控制器算出的控制量也会不稳定, 从而导致车辆发生抖振。可以看出, MHE 估计后的状态变化相比测量值更加平稳, 具有一定抑制干扰的能力。根据 MHE 的原理可知, N 等于 1 时 MHE 算法是一种 EKF 算法, 此时估计值与测量值基本吻合, 只在波峰波谷处对测量值的不稳定具有一定的抑制作用。 N 越大对系统干扰和测量误差的抑制能力越强, 但过大不能反映正常的状态变化, 因为随着时间的推移, 越早的数据对当前时刻的参考意义越小。如 N 等于 10 时, MHE 估计值偏离测量值过多, 不符合实际情况。因此, 为保证 MHE 对系统干扰和测量误差的抑制具有良好的效果, 同时也能较好地反映状态的真实变化, 一般 N 取 3~5, 此时整体估计效果也优于 EKF 算法 ($N=1$)。

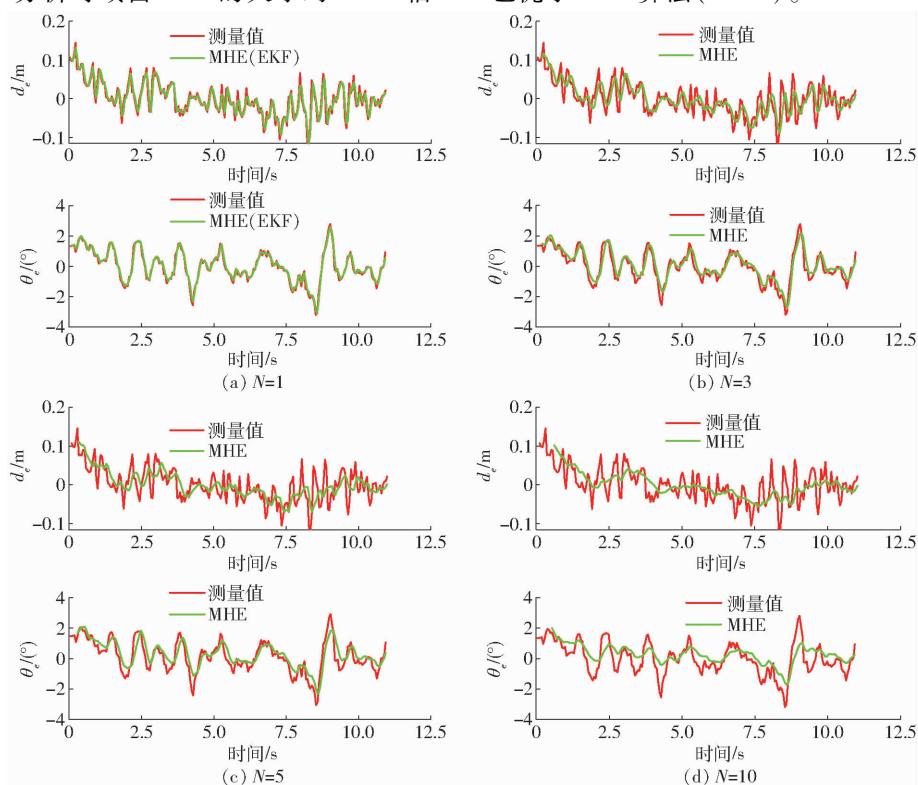


图 10 横向偏差与航向角偏差估计结果

Fig. 10 Estimation results of lateral deviation and heading angle deviation

图11为 $N=3$ 时,使用MHE算法对直播机8段路径横向偏差与航向角偏差的估计结果。可以看出,8段路径中横向偏差基本保持在 $-0.1 \sim 0.1$ m,航向角偏差基本保持在 $-2^\circ \sim 2^\circ$,但横向偏差测量值出现全程不平稳现象。MHE估计算法能有效改善这种现象,使得状态值变化平稳同时也能反映出实际变化趋势。说明MHE能有效消除系统干扰和测量误差对横向偏差的影响。相对来说航向角偏差变化较平稳,没有较多噪声,MHE估计算法对减小其变化幅值起到一定作用。对试验数据分析发现,每段路径相对于理想轨迹都会有一定的横向位置和航向角稳态偏差。如表3,各段路径稳态偏差基本一致,其中横向稳态偏差均值为 -0.0688 m,航向角稳态偏差均值为 -1.4670° 。使用MHE估计后各稳态偏差大幅下降,横向稳态偏差与航向角稳态偏差均值分别为 -0.0194 m和 -0.3665° ,说明MHE估计算法能消除干扰给状态带来的稳态偏差。

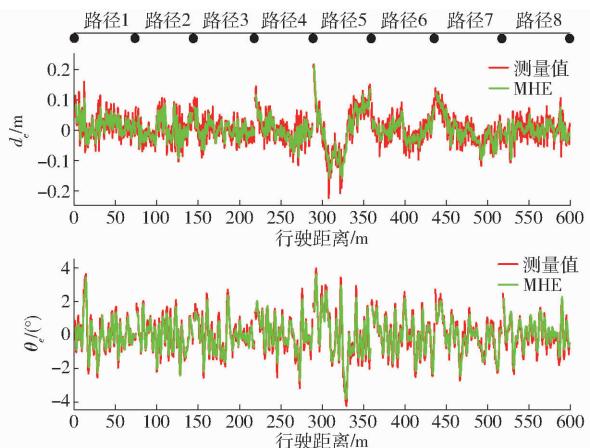


图11 所有路径横向偏差与航向角偏差估计结果

Fig. 11 Estimation results of lateral deviation and heading angle deviation of all driving path

各段路径估计结果显示,本文提出的基于滚动时域的水稻直播机运动状态估计算法能从不确定的状态信息中得到较为准确的状态值,能较好地消除系统干扰和测量误差,对下一环节的精确控制具有

表3 各段路径横向与航向角稳态偏差

Tab. 3 Steady-state error of lateral and heading angle

路径	横向稳态偏差/m		航向角稳态偏差/(°)	
	测量值	MHE	测量值	MHE
1	-0.0645	-0.0163	-1.5203	-0.3423
2	-0.0784	-0.0198	-1.5342	-0.3651
3	-0.0634	-0.0215	-1.5176	-0.4125
4	-0.0662	-0.0189	-1.3254	-0.3324
5	-0.0779	-0.0206	-1.5344	-0.4254
6	-0.0608	-0.0186	-1.5166	-0.4013
7	-0.0756	-0.0221	-1.3578	-0.3246
8	-0.0633	-0.0171	-1.4294	-0.3287

实际意义。

5 结论

(1) 基于带系统扰动的非线性水稻直播机运动学模型和带噪声的测量模型,提出一种基于滚动时域的无人水稻直播机运动状态估计算法。同时,为提高MHE状态估计算法的计算效率和解决传感器采样频率不同的问题,提出一种基于多线程的MHE求解架构。使用Matlab/CasADi进行系统仿真,结果表明,本文提出的MHE状态估计算法能有效补偿系统干扰和消除测量噪声,得到接近理论真值的状态,而且MHE的估计效果优于EKF。

(2) 在上海市崇明区无人农场进行了水稻直播机无人作业试验,使用MHE算法对某段直线路径中测得的横向偏差和航向角偏差值进行估计。试验结果显示,时域窗口 N 取 $3 \sim 5$ 时,MHE对补偿系统干扰和消除测量误差具有良好的效果,同时也能较好地反映状态值的真实变化。

(3) 使用MHE状态估计算法对水稻直播机8段路径的横向偏差与航向角偏差进行估计。结果显示,MHE算法对消除横向位置、航向角的稳态误差和抑制测量值的不平稳性具有良好的效果,同时也能反映出实际状态变化趋势,证明了MHE状态估计算法在补偿系统干扰和消除测量误差方面的优异性。

参 考 文 献

- [1] 张漫,季宇寒,李世超,等.农业机械导航技术研究进展[J].农业机械学报,2020,51(4):1~18.
ZHANG Man, JI Yuhuan, LI Shichao, et al. Research progress of agricultural machinery navigation technology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(4):1~18. (in Chinese)
- [2] 武涛,李彦明,林洪振,等.基于干扰观测器的直播机路径跟踪快速终端滑模控制[J].农业机械学报,2021,52(12):24~31.
WU Tao, LI Yanming, LIN Hongzhen, et al. Fast terminal sliding mode control for autonomous rice seeding machine based on disturbance observer[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(12):24~31. (in Chinese)
- [3] 胡静涛,高雷,白晓平,等.农业机械自动导航技术研究进展[J].农业工程学报,2015,31(10):1~10.
HU Jingtao, GAO Lei, BAI Xiaoping, et al. Review of research on automatic guidance of agricultural vehicles[J]. Transactions of the CSAE, 2015, 31(10):1~10. (in Chinese)

- [4] JULIER S J, UHLMANN J K. Unscented filtering and nonlinear estimation[J]. Proceedings of the IEEE, 2004, 92(3): 401–422.
- [5] JULIER S J, UHLMANN J K. New extension of the Kalman filter to nonlinear systems[C]//Signal processing, sensor fusion, and target recognition VI. International Society for Optics and Photonics, 1997: 182–193.
- [6] KHALEGHI B, KHAMIS A, KARRAY F O, et al. Multisensor data fusion: a review of the state-of-the-art[J]. Information Fusion, 2013, 14(1): 28–44.
- [7] DUAN P, TIAN G, WU H. A multi-sensor-based mobile robot localization framework[C]//2014 IEEE International Conference on Robotics and Biomimetics (ROBIO 2014), 2014: 642–647.
- [8] LU W, ZHANG J, ZHAO X, et al. Multimodal sensory fusion for soccer robot self-localization based on long short-term memory recurrent neural network[J]. Journal of Ambient Intelligence and Humanized Computing, 2017, 8(6): 885–893.
- [9] MAGRIN C E S, TODT E. Hierarchical sensor fusion method based on fingerprint KNN and fuzzy features weighting for indoor localization of a mobile robot platform[C]//2016 XIII Latin American Robotics Symposium and IV Brazilian Robotics Symposium (LARS/SBR), 2016: 305–310.
- [10] OSMAN M, ALONSO R, HAMMAM A, et al. Multisensor fusion localization using extended H_∞ filter using pre-filtered sensors measurements[C]//2019 IEEE Intelligent Vehicles Symposium (IV), 2019: 1139–1144.
- [11] CADENA C, CARLONE L, CARRILLO H, et al. Past, present, and future of simultaneous localization and mapping: toward the robust-perception age[J]. IEEE Transactions on Robotics, 2016, 32(6): 1309–1332.
- [12] MAHMOUD M S, SHI P, ISMAIL A. Robust Kalman filtering for discrete-time Markovian jump systems with parameter uncertainty[J]. Journal of Computational and Applied Mathematics, 2004, 169(1): 53–69.
- [13] HUANG M, DEY S. Stability of Kalman filtering with Markovian packet losses[J]. Automatica, 2007, 43(4): 598–607.
- [14] RAMSBOTTOM M, BAKER H. Kalman filtering for monitoring and control in driveline applications[R]//SAE World Congress & Exhibition, 2003.
- [15] NUSHOLTZ G S, CATTANI L C, EAGLE P J. Use of a Kalman filter to improve the estimation of ATD response during impact [J]. SAE Technical Papers, 1999: 1092–1097.
- [16] CHEN L, HU H, MCDONALD-MAIER K. EKF based mobile robot localization[C]//2012 Third International Conference on Emerging Security Technologies, 2012: 149–154.
- [17] MARIN L, VALLES M, SORIANO Á, et al. Multi sensor fusion framework for indoor-outdoor localization of limited resource mobile robots[J]. Sensors, 2013, 13(10): 14133–14160.
- [18] LYNEN S, ACHTELIK M W, WEISS S, et al. A robust and modular multi-sensor fusion approach applied to MAV navigation [C]//2013 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2013: 3923–3929.
- [19] MOORE T, STOUCH D. A generalized extended Kalman filter implementation for the robot operating system[C]//Intelligent Autonomous Systems 13. Springer, Cham, 2016: 335–348.
- [20] GIANNITRAPANI A, CECCARELLI N, SCORTECCI F, et al. Comparison of EKF and UKF for spacecraft localization via angle measurements[J]. IEEE Transactions on Aerospace and Electronic Systems, 2011, 47(1): 75–84.
- [21] YOUSUF S, KADRI M B. Information fusion of GPS, INS and odometer sensors for improving localization accuracy of mobile robots in indoor and outdoor applications[J]. Robotica, 2021, 39(2): 250–276.
- [22] JAIN A, ROY B. Simultaneous vehicle steering and localization using UKF[C]//Advances in Control and Instrumentation Systems, Springer, 2020: 77–87.
- [23] MEHREZ M W, MANN G K I, GOSINE R G. Nonlinear moving horizon state estimation for multi-robot relative localization [C]//2014 IEEE 27th Canadian Conference on Electrical and Computer Engineering (CCECE), 2014: 1–5.
- [24] SIMONETTO A, BALZARETTI D, KEVICZKY T. A distributed moving horizon estimator for mobile robot localization problems[J]. IFAC Proceedings Volumes, 2011, 44(1): 8902–8907.
- [25] DUBOIS R, BERTRAND S, EUDES A. Performance evaluation of a moving horizon estimator for multi-rate sensor fusion with time-delayed measurements[C]//2018 IEEE 22nd International Conference on System Theory, Control and Computing (ICSTCC), 2018: 664–669.
- [26] WANG S, CHEN L, GU D, et al. An optimization based moving horizon estimation with application to localization of autonomous underwater vehicles[J]. Robotics and Autonomous Systems, 2014, 62(10): 1581–1596.
- [27] OSMAN M, MEHREZ M W, DAOUD M A, et al. A generic multi-sensor fusion scheme for localization of autonomous platforms using moving horizon estimation[J]. Transactions of the Institute of Measurement and Control, 2021, 43(15): 3413–3427.
- [28] 杨建. 滚动时域估计及其在多UVU 协同定位中的应用[D]. 哈尔滨: 哈尔滨工程大学, 2015.
YANG Jian. Moving horizon estimation and application on the cooperation localization of multiple unmanned underwater vehicles[D]. Harbin: Harbin Engineering University, 2015. (in Chinese)
- [29] TYLER M L, ASANO K, MORARI M. Application of moving horizon estimation based fault detection to cold tandem steel mill [J]. International Journal of Control, 2000, 73(5): 427–438.
- [30] 李森. 基于滚动时域的车辆速度估计[D]. 长春: 吉林大学, 2009.
LI Miao. The estimation of vehicle speed based on moving horizon estimation[D]. Changchun: Jilin University, 2009. (in Chinese)