

DOI: 10.13382/j.jemi.B2306904

基于 DFFRLS-AUKF 的单轨吊车动态倾角 辨识方法研究*

刘泽朝¹ 李敬兆¹ 郑昌陆² 王国锋³

(1. 安徽理工大学电气与信息工程学院 淮南 232000; 2. 上海申传电气股份有限公司 上海 201800;
3. 淮河能源集团煤业有限责任公司 淮南 232000)

摘要:为保障单轨吊车在深部矿井复杂轨道工况环境下行驶的安全控制性能,需提高单轨吊车动态倾角辨识的精度及可靠性。因此,本文提出了基于 DFFRLS-AUKF 算法的单轨吊车动态倾角辨识方法。首先,利用自适应平滑滤波算法对实时采集的加速度和速度数据进行滤波处理,避免环境噪声的干扰,保证数据的完整性;其次,通过建立轨道曲率模型实现对轨道全工况的精准分析,在滤波处理后的数据基础上,再结合带有动态遗忘因子的递归最小二乘(DFFRLS)算法得到可靠地轨道曲率值;最终,在计算出的轨道曲率基础上,利用 Sage-Husa 噪声估计器对无迹卡尔曼滤波(UKF)进行改进,实现了对动态倾角辨识结果地自适应动态调整,提高了动态倾角辨识地精准度。实验表明,单轨吊车在单轨路段1和单轨路段2测试期间,所提的 DFFRLS-AUKF 算法与传统算法相比动态倾角辨识精度分别平均提升了 25.25% 和 39.5%,表明了 DFFRLS-AUKF 算法在不同轨道工况下具有良好的精准性及可靠性,有效保障了单轨吊车在复杂轨道工况下行驶的安全性。

关键词:单轨吊车;轨道曲率模型;递归最小二乘;自适应无迹卡尔曼滤波;动态倾角

中图分类号: TN98; TH213 **文献标识码:** A **国家标准学科分类代码:** 510.40

Dynamic inclination angle of monorails crane based on DFFRLS-AUKF research on identification method

Liu Zechao¹ Li Jingzhao¹ Zheng Changlu² Wang Guofeng³

(1. School of Electrical and Information Engineering, Anhui University of Science and Technology, Huainan 232000, China;
2. Shanghai Shenchuan Electric Co., Ltd., Shanghai 201800, China;
3. Coal Industry Company, Huaihe Energy Holding Group Co., Huainan 232000, China)

Abstract: To guarantee the safety control performance of monorail cranes operating in complex track conditions within deep mines, enhancing the accuracy and reliability of dynamic inclination recognition for monorail cranes is necessary. Therefore, this paper proposes a dynamic inclination recognition method of monorail crane based on DFFRLS-AUKF algorithm. Firstly, an adaptive smoothing filtering algorithm is used to filter the acceleration and velocity data collected in real-time to avoid the interference of environmental noise and ensure the integrity of the data. Secondly, the track curvature model is established to achieve the accurate analysis of the entire working conditions of the track, and based on the filtered data, a reliable track curvature value is obtained by combining the dynamic recursive least squares of forgetting factor (DFFRLS) algorithm with the dynamic forgetting factor. Finally, based on the calculated track curvature, the unscented Kalman filter (UKF) is improved by using the Sage-Husa noise estimator, which achieves the self-adaptation of the dynamic Adaptive adjustment of dynamic inclination recognition, and the accuracy of emotional inclination recognition is improved. Experiments show that the proposed DFFRLS-AUKF algorithm improves the dynamic inclination recognition accuracy by 25.25% and 39.5% on average compared with the traditional algorithm during the testing of monorail crane in monorail section 1 and monorail section 2, which demonstrates that the DFFRLS-AUKF algorithm has good accuracy and reliability under different track conditions, and effectively guarantees the safety of monorail crane driving under complex track conditions.

Keywords: monorail crane; orbit curvature model; recursive least squares; adaptive unscented Kalman filter; dynamic dip angle

收稿日期: 2023-09-19 Received Date: 2023-09-19

* 基金项目: 科技部国家重点研发计划(2020YFB1314100)、国家自然科学基金(52374154)、安徽理工大学博士研究生创新基金(2022CX1008)项目资助

0 引言

单轨吊车作为工矿企业进行物料和人员运输的主要运输设备,因其具有十分优异的运输性能,能实现人员和物料的一站式到达,对工矿企业的安全高效生产起到十分关键的作用^[1-2]。随着智慧矿山的不断建设,基于无人驾驶技术的单轨吊车得到逐步应用^[3],但在现有复杂地质条件的深部矿井环境下,单轨吊车会出现控制性能差,能量损失高,甚至安全性能低等问题,这些问题极大地限制了无人驾驶单轨吊车的发展。而单轨吊车动态倾角的变化情况对其安全控制性能和节能都具有极其重要的影响;因此,如何提高单轨吊车动态倾角辨识地精准性及可靠性成为了解决上述问题的关键。

目前关于车辆动态倾角辨识的研究主要有外接惯性传感器,基于车辆动力学模型和基于数据驱动的智能算法 3 类方法^[4]。基于外接传感器的直接测量方法主要包含了基于倾角位移传感器、捷联惯性导航系统(strapdown inertial navigation system, SINS)和全球定位系统(global positioning system, GPS)等^[5-6]。在单轨吊行驶过程中,由于角位移传感器易受到车辆加速和轨道坡度变化影响,使用角位移传感器在测量时,无法实时精准地获取动态倾角^[7]。文献[8]提出基于 GPS 系统测得道路纵向坡度,进而近似得到动态倾角;由于在深部矿井环境下信号被屏蔽,在短时间内仍依赖惯性导航,其测量精度较好;但在长时间下会导致动态倾角测量值产生很大误差。文献[9-10]提出基于 SINS 系统解决信号被屏蔽问题,但环境和车辆行驶的不稳定性,会导致量测误差的变化,并逐渐累积导致偏差变大。

通过外接传感器进行直接测量的方式都具有一定的局限性,在深部矿井环境中并不适用。基于数据驱动的智能算法,如神经网络、机器学习方法等;此类方法仅靠历史数据即可预测系统的状态;但该类方法辨识时严重依赖于模型参数,若要提高状态估计精度,必须消耗大量的算力,以便实时训练更新模型参数,因此,导致该种方法的实时性较差^[11-12]。

以动力学模型为基础,利用卡尔曼滤波(Kalman filter, KF)、扩展卡尔曼(extended Kalman filter, EKF)及容积分卡尔曼滤波(cubature Kalman filter, CKF)等多感融合方法有效解决了状态辨识运算开销大和实时性差的问题^[13-15]。文献[16]提出基于车辆动力学模型,采用扩展卡尔曼滤波(extended Kalman filter, EKF)对路况倾角坡度值进行辨识,但在单轨吊紧急制动时,此时所建立的力学模型无法有效对车辆状态进行估计,导致倾角坡度值辨识精度会大大降低,产生较大的倾角误差。基于车辆运动学、惯性传感器和状态观测器等三者相结合的方

式进行动态倾角估计,可避免制动控制所带来的影响。文献[17]采用置信因子将加速度量测值和动力学量测值加权得到路况坡度,但由于实际路况的曲率变化难以计算,导致无法应用于整车控制器中。文献[18]提出在无迹卡尔曼滤波(unscented Kalman filter, UKF)基础上,通过遗忘因子对噪声协方差矩阵进行在线自适应调整,以实现行驶状态下车辆状态参数的实时在线估计,但该遗忘因子的固定性难以适应轨道坡度的复杂变化,导致自适应估计的精度不高。

针对上述问题,本文提出了基于 DFFRLS-AUKF 算法的单轨吊车动态倾角辨识方法。针对复杂的深部矿井轨道路况环境,通过自适应滤波处理避免了路况环境所带来的辨识干扰,并通过建立轨道曲率模型,结合带有动态遗忘因子的递归最小二乘(dynamic recursive least squares of forgetting factor, DFFRLS)算法,实现在轨道全工况下的轨道曲率值实时可靠分析。在得到精准分析的轨道曲率值的基础上,通过自适应 Sage-Husa 算法对 UKF 算法进行改进,实现了对 UKF 算法测量噪声矩阵的动态修正,保证了单轨吊动态倾角地精准辨识。

1 轨道曲率模型

1.1 轨道曲率模型

深部矿井轨道坡度变化情况对单轨吊的安全驾驶具有重要的影响。鉴于现有矿井轨道坡度的连续变化,不可避免地造成单轨吊动态倾角识别精度较低的问题,而曲率作为衡量坡度变化的重要指标,对动态倾角辨识起到关键作用^[19]。因此,本节建立轨道曲率模型计算出当前曲率值,为间接精准识别动态倾角奠定重要基础。轨道曲率识别示意图如图 1 所示。




图 1 轨道曲率辨识示意图

Fig. 1 Schematic diagram of track curvature identification

单轨吊车由于运行速度缓慢,数据更新频率高,传感器数据每次更新时所通过的路程很短,行驶距离不超过 1 m。因此,每个数据更新时间间隔内,可认为单轨吊车行驶的距离和实际的弧线距离是相等的。

图 1 中上端 S 曲线为巷道顶板,下端 S 曲线为工字钢轨轨,轨道与巷道顶板之间通过防摆链条进行固定连接,以保障轨道不会前后左右晃动。单轨吊依次经过位

置点 1 和位置点 2, 其中行驶的距离为 Δl 。在位置点 1 和位置点 2 处的轨道角度分别为 α_1, α_2 。

基于单轨吊车行驶特性, 根据轨道坡度角定义和三角几何关系, 可得:

$$\tan(\beta) = \tan(\Delta\alpha) \approx \Delta l/R \quad (1)$$

式中: R 为纵向轨道曲率半径, $\Delta\alpha$ 为两位置点之间轨道坡度的角度变化, β 为两位置点曲率半径的夹角。

将式(1)中的角度变化信息进一步展开, 得到:

$$\begin{cases} \tan(\Delta\alpha) = \frac{\tan(\alpha_2) - \tan(\alpha_1)}{1 + \tan(\alpha_2)\tan(\alpha_1)} \\ \tan(\Delta\alpha) = \frac{\theta_2 - \theta_1}{1 + \theta_2\theta_1} = \theta_2 - \theta_1 = \Delta\theta \end{cases} \quad (2)$$

式中: $\theta_1 = \tan(\alpha_1)$ 为位置 1 处坡度变化角 α_1 所对应的轨道坡度, $\theta_2 = \tan(\alpha_2)$ 为位置 2 处坡度变化角 α_2 所对应的轨道坡度, 由于坡度变化角自身很小, $\tan(\alpha_2)\tan(\alpha_1)$ 可忽略。

将式(1)和(2)结合, 可得:

$$\Delta\theta = \Delta l/R \quad (3)$$

式(3)两边取极限, 可得:

$$\lim_{\Delta t \rightarrow 0} \frac{\Delta\theta}{\Delta t} = \lim_{\Delta l \rightarrow 0} \frac{\Delta l}{\Delta t} \cdot \frac{1}{R} \quad (4)$$

工字钢轨道是根据矿井巷道顶板条件进行设计安装的, 轨道坡度是连续变化的, 轨道坡度变化率与轨道曲率的关系表达式为:

$$\theta' = \rho v \quad (5)$$

以上的公式是建立在加速度计所采集的加速度数据基础之上, 因此, 根据加速度计定义式来建立轨道曲率模型。基于微分后的加速度定义式, 将该公式代入式(5)中, 可得:

$$a'_{sen} - a'_v = gvp \quad (6)$$

轨道曲率可由传感设备所采集的参数根据式(6)计算得出。

1.2 自适应平滑滤波处理

为解决加速度一阶导滤波问题, 基于一阶导惯性低通滤波算法, 通过将每次的采样值与上次滤波输出值进行加权, 并将加权结果反馈给输入值, 不断调整以得到实时的滤波值^[20]。具体算法描述如下:

$$Y(n) = m \cdot \psi(n) + (1 - m)Y(n - 1) \quad (7)$$

式中: $Y(n)$ 为滤波输出值; m 为滤波系数, 其值大小决定了平滑的效果, 通常远小于 1; $\psi(n)$ 为本次采样值; $Y(n-1)$ 为上次滤波输出值。

滤波的截至频率计算公式为:

$$f_L = \frac{m}{2\pi\Delta t} = \frac{mf_s}{2\pi} \quad (8)$$

式中: f_L 为截止频率; m 为滤波系数; Δt 为采样间隔时

间; f_s 为采样频率。

在对加速度数据进行滤波过程中, 由于该算法模拟的是具有较大的惯性, 使得在对静止加速度数据进行处理时有良好的效果, 而在运动时, 会产生较明显的相位延迟。

为了解决上述问题, 引入判定运动状态的条件阈值 Γ_a , 根据式(9)进行判断, 并修改滤波系数 m , 即:

$$\begin{cases} \Gamma = Y(n) - Y(n - 1) > \Gamma_a \\ m = (1 - \Gamma_a/\Gamma) \cdot \tau_0 \end{cases} \quad (9)$$

式中: Γ 为本次滤波输出与上次滤波输出的差值; Γ_a 为判定运动状态的条件阈值, 由静止状态时的标准偏差求解; τ_0 为初始滤波参数。

初始滤波参数与运动状态的关系可采用分段函数描述为:

$$\tau_m = \begin{cases} \tau_0, & 1 < \Gamma/\Gamma_0 \leq \delta_1 \\ \tau_0 + \Delta\tau_1, & \delta_1 < \Gamma/\Gamma_0 \leq \delta_2 \\ \tau_m + \Delta\tau_2, & \delta_2 < \Gamma/\Gamma_0 \end{cases} \quad (10)$$

式中: $\Delta\tau_1, \Delta\tau_2, \delta_1, \delta_2$ 均是与运动状态相关的常值。 $\Gamma/\Gamma_0 \leq 1$, 单轨吊车处于静止状态, 当前输出值取决于上次滤波值, 滤波系数初值取为 0.1~0.2; 当 $1 < \Gamma/\Gamma_0 \leq \delta_1$ 时, 单轨吊车处于上坡低速状态, 当前输出值由上次滤波值和当前测量值加权得到; δ_1, δ_2 表示单轨吊车运行速度的快慢, 当 Γ/Γ_0 大于 δ_1 和 δ_2 时, τ_0 也相应地增加 $\Delta\tau_1$ 和 $\Delta\tau_2$, 以提高灵敏度。

2 基于轨道曲率模型的坡度估计

2.1 基于 DFFRLS 的轨道曲率估计

基于传统的 RLS 算法对参数识别时, 会导致数据堆叠, 并降低了估计精度, 通过带有遗忘因子的递推最小二乘(recursive least squares with forgetting factor, FFRLS)算法进行参数估计时, 虽能克服递推过程中数据的堆叠问题, 但无法快速收敛^[21]。而带有多遗忘因子的递推最小二乘(recursive least squares with multiple forgetting factors, RLS-MFF)算法进行参数估计时易导致发散。因此, 本节对 FFRLS 算法进行改进, 通过引入了反馈环节, 将实际参数值与模型实时输出值的差值带入系统中利用比例控制对误差值进行修正, 保证参数估计的精准性和收敛性。

坡度变化率模型中式(6)进行重新定义, 表达如下:

$$y = hp \quad (11)$$

式中: y 为系统的输出量, $y = a'_{sen} - a'_v$; ρ 为待识别的坡度变化率参数; h 为输入量, 为已知的参数量, $h = gv$ 。

其次, 对 FFRLS 算法进行改进, 构建动态遗忘因子为:

$$\begin{cases} \Delta(k+1) = |y(k+1) - h(k+1)\rho(k)| \\ \lambda(k+1) = \delta + (1 - \delta)e^{-\sigma\Delta(k+1)} \end{cases} \quad (12)$$

式中: $\Delta(k+1)$ 为轨道曲率实际值与识别值在 $k+1$ 时刻的差值, $\lambda(k+1)$ 为动态遗忘因子在 $k+1$ 时刻的值, 且满足 $0.95 \leq \lambda \leq 1$, 初始值为 0.98; ϑ 、 σ 是可调参数。

最终, 递归过程为:

$$\begin{cases} \rho(k) = \rho(k-1) + K(k)(y(k) - h^T(k)\rho(k-1)) \\ \mathbf{P}(k) = \frac{(\mathbf{I} - K(k)h^T(k))\mathbf{P}(k-1)}{\lambda(k-1)} \\ K(k) = \frac{\mathbf{P}(k-1)h(k)}{(\lambda(k-1) + h^T(k)\mathbf{P}(k-1)h(k))} \end{cases} \quad (13)$$

式中: $\rho(k)$ 为 k 时刻轨道曲率更新值; $K(k)$ 为 k 时刻参数辨识增益; \mathbf{I} 为单位矩阵; $\mathbf{P}(k)$ 为 k 时刻协方差更新矩阵。

2.2 UKF 动态倾角估计

基于 DFFRLS 算法得到的轨道曲率值, 传感设备所采集的加速度和速度数据, 通过 UKF 算法对三者进行融合计算, 与 EKF 算法相比, UKF 能更加精准地得到倾角角度。

根据式(9)所建立的轨道曲率方程, 结合加速度、速度和轨道曲率数据, 选取状态向量 $\mathbf{x} = [a, \theta']^T$, 量测向量 $\mathbf{z} = [a, a'_{sen}]$ 。系统的微分方程为:

$$\begin{cases} \dot{a}'(k) = a'_{sen}(k) - gv(k)\rho(k) \\ \dot{\theta}'(k) = \rho(k)v(k) \end{cases} \quad (14)$$

对式(14)进行前向欧拉处理, 得到的离散化空间状态方程为:

$$\mathbf{x}_k = \mathbf{A}\mathbf{x}_{k-1} + \mathbf{B}u_{k-1} + \mathbf{w}_{k-1} \quad (15)$$

$$\mathbf{z}_k = \mathbf{C}\mathbf{x}_k + q_k \quad (16)$$

式中: \mathbf{x}_k 为 k 时刻状态变量的向量值; \mathbf{z}_k 为 k 时刻观测变量的向量值; $\mathbf{A} = \begin{bmatrix} 1 & -g\Delta t \\ 0 & 1 \end{bmatrix}$, $\mathbf{B} = \begin{bmatrix} \Delta t & 0 \\ 0 & \Delta t \end{bmatrix}$, $\mathbf{u} = \begin{bmatrix} a_{sen} \\ 0 \end{bmatrix}$,

$\mathbf{C} = [1, 0]$; \mathbf{w}_{k-1} 为状态噪声, q_{k-1} 为测量噪声。

初始化状态变量的均值和协方差:

$$\begin{cases} \bar{\mathbf{x}}_0 = E(\mathbf{x}_0) \\ \mathbf{P}_0 = [(\mathbf{x}_0 - \bar{\mathbf{x}}_0)(\mathbf{x}_0 - \bar{\mathbf{x}}_0)^T] \end{cases} \quad (17)$$

式中: \mathbf{x}_0 为初始状态变量; $\bar{\mathbf{x}}_0$ 为初始状态变量均值; \mathbf{P}_0 为初始状态协方差矩阵, $E(\cdot)$ 为求均值的函数。

通过无迹变换产生 Sigma 点的公式为:

$$\mathbf{x}^j = \begin{cases} \bar{\mathbf{x}}^j, j = 0 \\ \bar{\mathbf{x}}^j + (\sqrt{(n+\varphi)\mathbf{P}_0}), j = 1, 2, \dots, n \\ \bar{\mathbf{x}}^j - (\sqrt{(n+\varphi)\mathbf{P}_0}), j = n+1, \dots, 2n \end{cases} \quad (18)$$

式中: \mathbf{x}^j 为第 j 个 Sigma 点; $\bar{\mathbf{x}}^j$ 为第 j 个采样点的平均值; φ 是缩放参数, 用于减小辨识误差值, $\varphi = \xi^2(n+\kappa) - L$; L 为状态维数; ξ 值决定了 Sigma 点偏离状态值的程度, 取值为 0.97; κ 为副尺度参数, 用于保证矩阵 $(n+\varphi)\mathbf{P}_k$ 为

半正定矩阵, 取值为 $\kappa = 3 - n$ 。

权重值计算如下:

$$\begin{cases} \omega_m^j = \varphi/n + \varphi, j = 0 \\ \omega_c^j = \omega_m^j + (1 - \sigma^2 - \eta), j = 0 \\ \omega_m^j = \omega_c^j = 1/2(n + \varphi), j = 1, \dots, 2n \end{cases} \quad (19)$$

式中: ω_m^j 为第 j 个 Sigma 采样点的均值; ω_c^j 为协方差加权值; η 为非负权系数, 取 $\eta = 2$ 。

在 k 时刻, 按式(15)构造 $2n+1$ 个采样点集:

$$\mathbf{x}_{k/k}^j = [\bar{\mathbf{x}}_{k/k}, \bar{\mathbf{x}}_{k/k} + \sqrt{(n+\varphi)\mathbf{P}_{k/k}}, \bar{\mathbf{x}}_{k/k} - \sqrt{(n+\varphi)\mathbf{P}_{k/k}}] \quad (20)$$

式中: $\mathbf{x}_{k/k}^j$ 表示当前状态下的采样点的集合。

计算一步预测所产生的 $2n+1$ 采样点:

$$\mathbf{x}_{k+1/k}^j = f(\mathbf{x}_{k/k}^j, u_k), j = 0, \dots, 2n \quad (21)$$

式中: $\mathbf{x}_{k+1/k}^j$ 为 $2n+1$ 个采样点对应的值, u_k 为输入变量在 k 时刻的观测控制量。

预测系统状态变量均值和协方差:

$$\bar{\mathbf{x}}_{k+1/k} = \sum_{j=0}^{2n} \omega_m^j \mathbf{x}_{k+1/k}^j \quad (22)$$

$$\mathbf{P}_{k+1/k} = \sum_{j=0}^{2n} \omega_c^j (\mathbf{x}_{k+1/k}^j - \bar{\mathbf{x}}_{k+1/k}) \cdot (\mathbf{x}_{k+1/k}^j - \bar{\mathbf{x}}_{k+1/k})^T + \mathbf{Q}_k \quad (23)$$

式中: $\bar{\mathbf{x}}_{k+1/k}$ 为状态变量均值预测值; $\mathbf{P}_{k+1|k}$ 为状态协方差矩阵预测值; \mathbf{Q}_k 是 k 时刻过程噪声协方差。

根据一步预测值, 再次使用无迹变换生成一个新的采样点集^[22]:

$$\mathbf{X}_{k+1/k}^j = [\bar{\mathbf{x}}_{k+1/k}^j, \bar{\mathbf{x}}_{k+1/k}^j + ((\sqrt{(n+\varphi)\mathbf{P}_{k+1/k}})), \bar{\mathbf{x}}_{k+1/k}^j - ((\sqrt{(n+\varphi)\mathbf{P}_{k+1/k}}))] \quad (24)$$

式中: $\mathbf{X}_{k+1/k}^j$ 为新生成的 Sigma 点集。

计算 Sigma 点集的观测预测值为:

$$\mathbf{Z}_{k+1/k}^j = F(\mathbf{X}_{k+1/k}^j), j = 1, 2, \dots, 2n+1 \quad (25)$$

式中: $\mathbf{Z}_{k+1/k}^j$ 观察到的预测价值; $F(\cdot)$ 为非线性观测方程函数。

通过加权求和得到系统预测的均值、残差协方差矩阵和实测值协方差矩阵^[23]:

$$\bar{\mathbf{Z}}_{k+1/k} = \sum_{j=0}^{2n} \omega_c^j \mathbf{Z}_{k+1/k}^j \quad (26)$$

$$\mathbf{P}_{\bar{\mathbf{X}}_k \bar{\mathbf{Z}}_k} = \sum_{j=0}^{2n} \omega_c^j [\mathbf{X}_{k+1/k}^j - \bar{\mathbf{x}}_{k+1/k}] \cdot [\mathbf{Z}_{k+1/k}^j - \bar{\mathbf{Z}}_{k+1/k}]^T \quad (27)$$

$$\mathbf{P}_{\bar{\mathbf{Z}}_k \bar{\mathbf{Z}}_k} = \sum_{j=0}^{2n} \omega_c^j [\mathbf{Z}_{k+1/k}^j - \bar{\mathbf{Z}}_{k+1/k}] \cdot [\mathbf{Z}_{k+1/k}^j - \bar{\mathbf{Z}}_{k+1/k}]^T + \mathbf{R}_k \quad (28)$$

式中: $\bar{\mathbf{Z}}_{k+1/k}$ 为系统预测均值; $\mathbf{P}_{\bar{\mathbf{X}}_k \bar{\mathbf{Z}}_k}$ 为测量协方差; $\mathbf{P}_{\bar{\mathbf{Z}}_k \bar{\mathbf{Z}}_k}$ 为残差协方差; \mathbf{R}_k 为测量噪声协方差。

卡尔曼增益矩阵 \mathbf{K} 为:

$$K_{k+1} = P_{x_k z_k} \cdot (P_{z_k z_k})^{-1} \quad (29)$$

倾角坡度的状态估计更新和协方差更新为:

$$\bar{x}_{k+1/k+1} = \bar{x}_{k+1/k} + K_{k+1} [Z_{k+1} - \bar{Z}_{k+1/k}] \quad (30)$$

$$P_{k+1/k+1} = P_{k+1/k} - K_{k+1} P_{z_k z_k} K_{k+1}^T \quad (31)$$

式中: $\bar{x}_{k+1/k+1}$ 为更新的状态变量的平均值; $P_{k+1/k+1}$ 为更新后的状态协方差; Z_{k+1} 是输出变量。

2.3 基于 AUKF 的动态倾角估计

在实际单轨吊车行驶过程中,由于受到外界环境噪声干扰,UKF 模型中的观测噪声和激励噪声变化无法得到实时精准计算。为此,在 UKF 算法的基础上引入 Sage-Husa 噪声估计器。该估计器在实时动态修正协方差矩阵 Q_k 和 R_k 的同时,对状态方程的噪声 q_k 和量测方程的 r_k 也同步进行更新和调整。该估计器增强了时变噪声跟踪的有效性^[24],有效提高了 UKF 算法的抗干扰能力,实现了动态倾角角度的高精度识别。算法改进部分如下。通过 UKF 算法计算得到动态倾角偏差值为 $\varepsilon_{k+1} = Z_{k+1/k}^j - z(k+1)$ 。

调节因子计算为:

$$d_{k+1} = (1 - b) / (1 - b^{k+1}) \quad (32)$$

式中: d_{k+1} 为自适应缩放参数; b 为调节因子,取值范围为 0.95~1, $b=0.97$ 。

改进后的状态噪声 q_k 为:

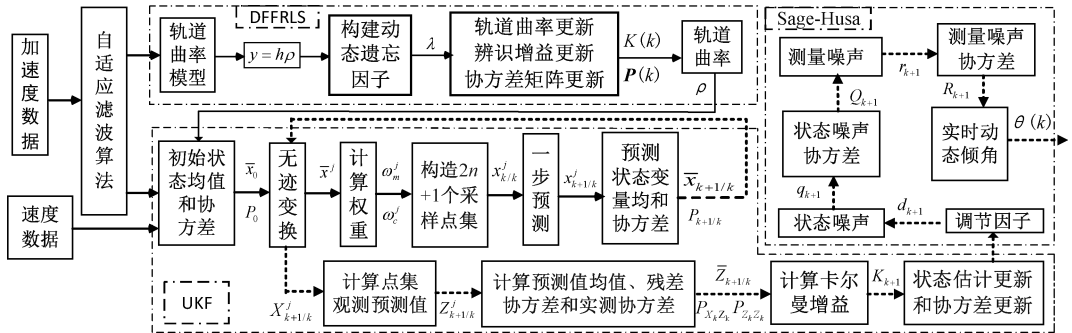


图2 动态倾角联合辨识流程

Fig. 2 Process of joint identification of dynamic dip angles

$$q_{k+1} = (1 - d_{k+1})q_k + d_{k+1}(\bar{x}_{k+1} - \sum_{j=0}^{2n} \omega_m^j x_{k+1/k}^j) \quad (33)$$

改进的状态噪声协方差 Q_{k+1} 为:

$$Q_{k+1} = (1 - d_{k+1})Q_k + d_{k+1} [K_{k+1} \varepsilon_{k+1} \varepsilon_{k+1}^T + P_{k+1} - \sum_{j=0}^{2n} \omega_c^j (x_{k+1/k}^j - \bar{x}_{k+1/k}) \cdot (x_{k+1/k}^j - \bar{x}_{k+1/k})^T] \quad (34)$$

改进后的测量噪声 r_k 为:

$$r_{k+1} = (1 - d_{k+1})r_k + d_{k+1}(z(k+1) - \sum_{j=0}^{2n} \omega_m^j Z_{k+1/k}^j) \quad (35)$$

改进后的测量噪声协方差 R_{k+1} 为:

$$R_{k+1} = (1 - d_{k+1})R_k + d_{k+1} [\varepsilon_{k+1} \varepsilon_{k+1}^T - \sum_{j=0}^{2n} \omega_c^j (Z_{k+1/k}^j - \bar{Z}_{k+1/k}) (Z_{k+1/k}^j - \bar{Z}_{k+1/k})] \quad (36)$$

3 动态倾角辨识联合估计策略

基于轨道曲率模型,结合滤波处理后的加速度和速度数据,通过 DFFRLS 算法计算出实时地动态轨道曲率值,并基于所辨识地轨道曲率值,通过改进地 UKF 算法辨识出精准地动态倾角坡度值。DFFRLS-AUKF 算法动态倾角联合流程如图 2 所示。

4 单轨吊车载实验验证及分析

4.1 实验介绍

实验车辆、试验轨道及设备如图 3 所示。实验测试平台由 DX80/176Y 单轨吊车、深部矿井 I140E 型上下坡轨道、感知和处理硬件设备等组成。感知和处理硬件设备主要由加速度计、陀螺仪、SPC5643LMQ1 处理器、天线、E6A2-CWZ3E 速度传感器和无线基站等组成。实测车辆为上海申传电气有限公司生产的 DX80/176Y 型电动单轨吊车,主要由前后驾驶室、8 个驱动单元、锂电池

车等组成。该实测单轨吊的主要参数为:驱动摩擦轮夹紧力为 10 MPa,单轨吊空载最大速度为 2.4 m/s,最大牵引力为 80 kN,牵引电机功率为 60 kW,制动力范围为 120~160 kN。陀螺仪与加速度计位于电液控车厢内部,数据更新频率为 100 Hz。速度传感器位于驱动轮下侧的转动轴附近,用于检测驱动轴的转速。速度、加速度等数据由微控制器 SPC5643LMQ1 处理,并由 CAN 总线发布。

在实际应用中各个参数选取的过程为:在轨道曲率方面,首先选取实时获取地加速度和速度值;然后,通过 DFFRLS 算法基于加速度和速度值计算出轨道曲率,并根据轨道曲率偏差大小,自适应对动态遗忘因子做出调

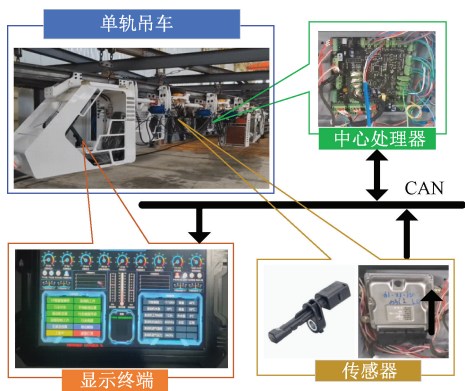


图 3 单轨吊测试实物图

Fig. 3 Physical drawing of monorail crane test

整;最终,在初始协方差矩阵基础上,计算出参数辨识增益,通过不断迭代得出精准地轨道曲率。在动态倾角方面,通过选取车速微分量和倾角微分值作为状态向量,并选取车速微分量和加速度计获取的加速度微分值为观测向量,建立系统微分方程;通过 AUKF 算法对微分方程进行离散化处理,得到状态变量的向量值和观测变量的向量值;并基于初始化状态变量的均值和协方差;通过无迹变换产生 Sigma 点,构造 $2n+1$ 个点集,得到实时的动态倾角值,进一步通过一步预测,采用无迹变换,得到新的动态倾角值;并基于 Sage-Husa 估计器,实现对倾角的动态调整。各传感器相关参数如表 1 所示。各传感器检测误差符合测量需求,不会对实验结果造成影响。

表 1 各传感器的相关参数说明


Table 1 Parameters of each sensor

传感器名称	参数	测量值
加速度计	范围	$\pm 6/g$
	随机噪声	$0.1 \text{ mg}/\sqrt{\text{Hz}}$
	零漂	0.00978 m/s^2
	随机游动	$0.058 \text{ m/s}/\sqrt{h}$
速度传感器	范围	$0 \sim 10 \text{ m/s}$
	线性度精度	1%
	灵敏度	$1500 \sim 200 \text{ mV/m/s}$
陀螺仪	常值漂移	$0.5^\circ/h$
	角度随机游走	$0.14^\circ/\sqrt{h}$

实验测试路线选取的是在淮南矿区某深部矿井主巷道进行,主巷道包含了上下坡轨道,每 200 m 左右布放一个基站。单轨吊车在行驶过程中,动态倾角近似平行于单型轨道。在实验测试前,对测试路线的轨道坡度情况进行人工尺度测量的方式进行获取,并结合倾角仪检测数据共同作为倾角角度辨识参考值,以验证基于 DFFRLS-AUKF 算法所辨识的动态倾角角度精准性。试验轨道的路况分为两种,试验单轨段 1 由下坡段和水平轨道段组成,试验单轨段 2 由上坡段和水平轨道段组成;

试验巷道的轨道坡度均为 30° 及以下,测试进行时长为 300 s。

实验测试路线及实景图如图 4 所示。



(a) 上下坡线路 (b) 水平线路
(a) Uphill and downhill lines (b) Horizontal lines

图 4 实验测试路线实景图

Fig. 4 Real map of the experimental test route

为验证 DFFRLS 算法在轨道段 1 与轨道段 2 轨道曲率估计的收敛性,通过 DFFRLS 算法公式 (13) 所得到的轨道段 1 与轨道段 2 的轨道曲率估计值与实际值的误差绝对值大小来反映收敛性能的优异。DFFRLS 算法轨道曲率估计误差绝对值曲线如图 5 所示。




图 5 DFFRLS 算法轨道曲率估计误差绝对值曲线
Fig. 5 Curve of absolute value of orbit curvature estimation error of DFFRLS algorithm

通过图 5, DFFRLS 算法公式 (13) 递推所得到的轨道曲率估计值与实际值的误差绝对值随着递推次数的增加,其误差绝对值曲线均在快速下降,并收敛明显,收敛值趋于 0,表明该算法具有良好的收敛性。在左边局部放大图中, DFFRLS 算法在轨道段 1 的收敛速度快于在轨道段 2 的收敛速度;在右边局部放大图中,该算法在轨道段 1 与轨道段 2 的收敛值都最终趋于一致。表明 DFFRLS 算法具有良好的收敛性能。

4.2 自适应平滑滤波效果分析

为验证自适应平滑滤波效果,从数据存储中读取 300 s 的纵向速度和加速度数据进行测试。单轨段 1 期间,速度和加速度数据的滤波效果如图 6 所示。在水平线路行驶期间,单轨吊车行驶速度较缓,单轨吊车行驶前进方向的速度为 0.575 m/s,加速度稳定在 0.1 m/s²。在 70 s 时,单轨吊行驶入下坡段,由于受重力下滑力因素,速度出现波动并显著增加;由于自主感知到动态倾角变化,为保障行驶安全,随后自主采取电制动控制,闸瓦压力增加,速度快速下降,并最终稳定在 0.525 ~ 0.545 m/s;在单轨段 1 期间,加速度和速度滤波数据无失真和丢失现象发生,表明该算法滤波效果良好。单轨段 2 期间,速度和加速度数据的滤波效果如图 7 所示。

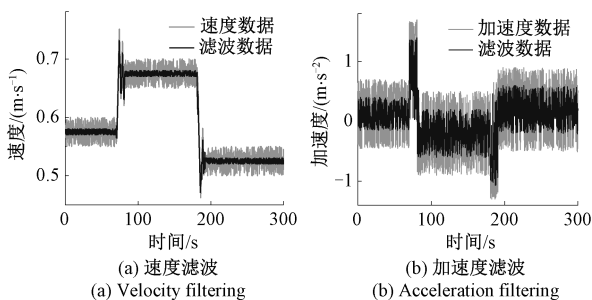


图 6 单轨段 1 滤波数据

Fig. 6 Filtered data for monorail segment 1

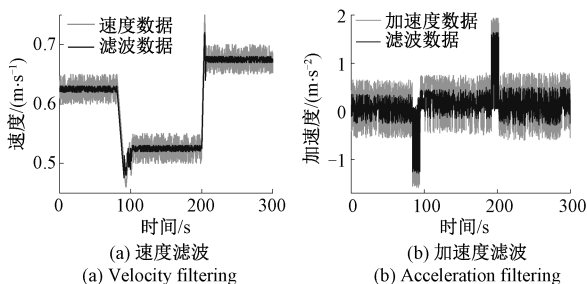


图 7 单轨段 2 滤波数据

Fig. 7 Filtered data for monorail segment 2

单轨段 2 期间的速度和加速度数据滤波效果如图 7 所示。单轨吊车在水平直轨段速度稳定;加速度在 -0.25 ~ 0.25 m/s² 范围内波动。在 81 s 时,单轨吊车驶入上坡段,因重力因素,单轨吊车速度快速下降;为保障单轨吊车行驶安全,其采取智能控制,减小闸瓦压力,并同时增加牵引驱动力;随之单轨吊车速度增加,加速度也增大,最终速度维持在 0.675 ~ 0.695 m/s。

4.3 实验测试及结果分析

1) 单轨段 1 动态倾角辨识分析

单轨段 1 由下坡段和水平无坡段组成。在轨道段 1 实车测试期间,单轨吊载重 10 t,初始坡度为 0°,制动系

统闸瓦压力为 8 MPa,挡位固定在前挡位,无中途停车。为验证 DFFRLS 算法的轨道曲率辨识效果,将其辨识结果与 RLS-MFF、FFRLS 算法等辨识结果一同与实测轨道曲率进行比较。各算法轨道曲率辨识及误差分析如图 8 所示。

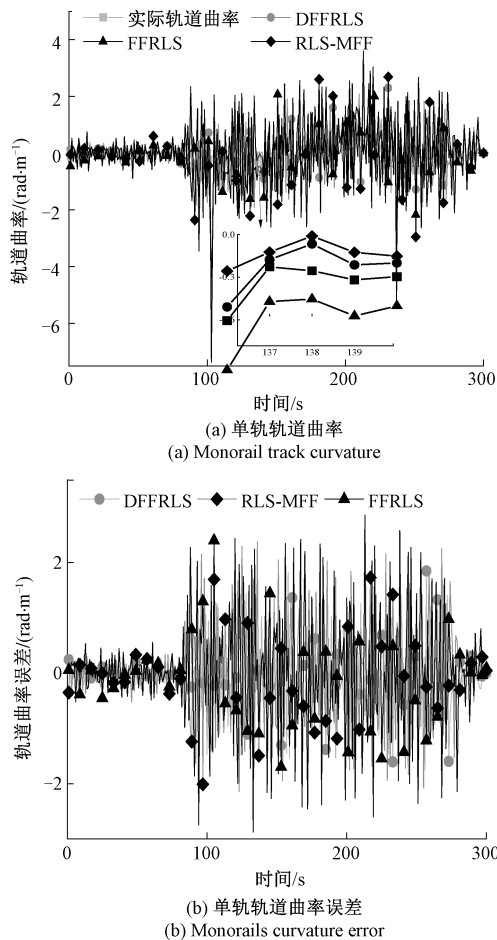
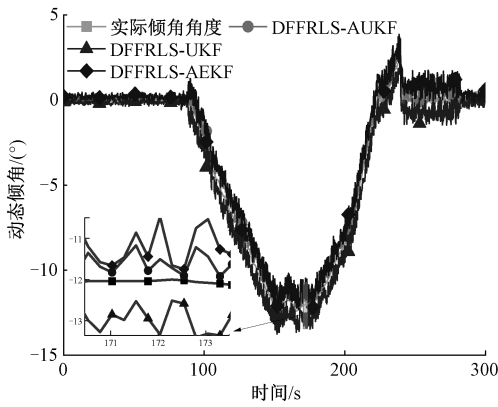


图 8 轨道段 1 轨道曲率辨识结果及误差

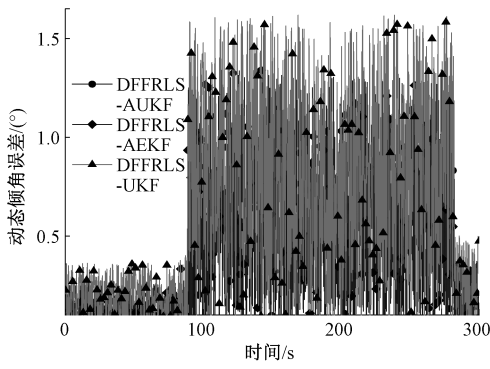
Fig. 8 Results and errors of track curvature identification for track segment 1

在单轨段 1 期间,各算法的轨道曲率辨识结果如图 8 所示。在图 8(a) 中,在平直无坡度阶段,各算法跟随效果良好;在 80 s 时,单轨吊车进入下坡段,各算法轨道曲率辨识值均波动明显;在局部放大图中,DFFRLS 跟随效果最好,辨识性能优于 FFRLS 及 RLS-MFF 算法,表明其可靠性最高。在图 8(b) 中,DFFRLS 轨道曲率辨识误差值整体较小,并且误差值低于 FFRLS 和 RLS-MFF 算法,说明其辨识精度最高。轨道段 1 各算法动态倾角辨识结果及误差分析如图 9 所示。

如图 9 所示,在单轨段 1 期间,各算法都能较好地跟随单轨吊动态倾角变化。图 9(a) 中,各算法在水平无坡度段辨识值均较为稳定;在下坡段期间,辨识值有所波



(a) 动态倾角角度辨识结果
(a) Dynamic dip angle identification results



(b) 动态倾角角度辨识误差
(b) Dynamic dip angle identification error

图 9 单轨段 1 各算法倾角角度辨识结果及误差

Fig. 9 Monorail inclination angle section 1 each algorithm identification results and error

动,但整体辨识结果较为稳定;在上坡坡度变化较大轨道段,基于局部放大图,DFFRLS-AUKF 算法跟随效果最好,表明其可靠性最高。图 9(b)中,DFFRLS-UKF 算法和 DFFRLS-AEKF 算法的动态倾角误差均大于 DFFRLS-AUKF 算法动态倾角误差,进一步表明 DFFRLS-AUKF 算法具有良好的动态倾角辨识性能。

为进一步量化在单轨道段 1 期间各算法所辨识的动态倾角精准度和时间复杂度,采用平均绝对误差(mean absolute error, MAE)和均方根误差(root mean square error, RMSE)作为评价指标进行评估^[22]。时间复杂度的关键指标体现在算法执行时间方面,因此,根据不同算法的执行时间,进而对各算法的时间复杂度进行判断。单轨道段 1 各算法辨识的动态倾角 MAE、RMSE 值和时间复杂度如表 2 所示。

均方根误差和平均绝对误差计算公式如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N (\hat{\chi}_j - \chi_j)^2} \quad (37)$$

$$MAE = \frac{1}{N} \sum_{j=1}^N |\hat{\chi}_j - \chi_j| \quad (38)$$

式中: N 表示试验测试中所采集的样本数据总数, χ_j 、 $\hat{\chi}_j$ 分别表示第 j 个样本数据的实际值和估计值。

表 2 轨道段 1 动态倾角角度辨识结果的 MAE、RMSE 和时间复杂度

Table 2 MAE, RMSE and time complexity of the dynamic dip Angle identification results for track segment 1

算法名称	MAE	RMSE	执行时间/s
DFFRLS-AUKF	0.385	0.498	1.630
DFFRLS-AEKF	0.500	0.642	1.670
DFFRLS-UKF	0.613	0.778	1.680

基于表 2,DFFRLS-AUKF 算法在单轨道段 1 动态倾角辨识方面,其辨识误差 MAE 及 RMSE 值均最小。DFFRLS-AUKF 的 MAE 值相较于 DFFRLS-AEKF 与 DFFRLS-UKF 算法的 MAE 值分别减小了 23.0% 和 37.1%;DFFRLS-AUKF 算法的 RMSE 值相较于 DFFRLS-AEKF 与 DFFRLS-UKF 算法的 RMSE 值分别减小了 23.8% 和 35.9%;进一步表明了 DFFRLS-AUKF 算法在动态倾角辨识方面具有良好的精准度。在单轨道段 1 各算法执行时间方面,DFFRLS-AUKF 算法执行时间最短,相较于 DFFRLS-AEKF 和 DFFRLS-UKF 算法执行时间分别提升了 2.39% 和 2.97%;表明 DFFRLS-AUKF 算法时间复杂度最低,执行效率最高。


2) 单轨道段 2 动态倾角辨识分析

单轨道段 2 由上坡段和平直无坡段组成。在单轨道段 2 期间,单轨吊负载为 10 t,初始坡度为 0°,制动系统夹紧压力为 9 MPa,档位固定在制动档,无中途停车。单轨吊在测试轨道段 2 期间,采用 FFRLS、RLS-MFF 及 DFFRLS 算法对当前轨道曲率进行辨识,各算法轨道曲率辨识值及误差如图 10 所示。

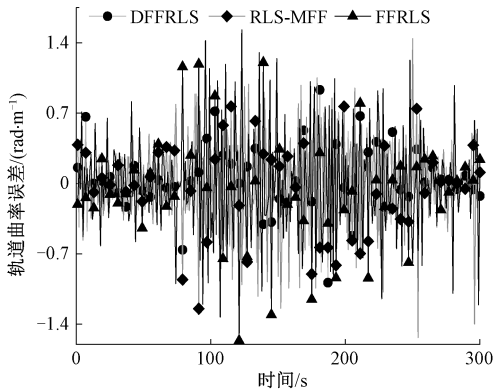
各算法轨道曲率估计值如图 10(a)所示,在单轨道段 2 无坡度平直路段期间,各算法估计值波动较小;在进入上坡路段后,各算法轨道曲率估计值波动快速增大;随着上坡路段坡度变下,各算法轨道曲率估计值波动逐渐平稳;整体上 DFFRLS 算法波动最小,估计稳定性最高。在局部放大图中,DFFRLS 算法跟随实际轨道曲率变化能力明显优于 FFRLS 及 RLS-MFF 算法,说明其可靠性最高。在图 10(b)中,FFRLS 和 RLS-MFF 算法轨道曲率辨识误差值均高于 DFFRLS 算法,表明 DFFRLS 算法估计精度最高。

单轨道段 2 期间,各算法动态倾角辨识结果及误差分析如图 11 所示。

在单轨道段 2 动态倾角识别方面,如图 11(a)所示,在 70 s 进入上坡阶段,由于单轨吊车采取了制动控制,导致各算法动态倾角辨识值波动较大,但 DDFRLS-AUKF 算法与实际动态倾角偏差最小;在 140 s 时,由于上坡坡度



(a) 单轨轨道曲率
(a) Monorail track curvature



(b) 单轨轨道曲率误差
(b) Monorails curvature error

图 10 轨道段 2 轨道曲率辨识结果及误差

Fig. 10 Results and errors of track curvature identification for track segment 2


变化较大,各算法动态倾角辨识值波动明显,但通过局部放大图发现,DFFRLS-AUKF 算法的跟随效果最好,表明其可靠性最高。各算法动态倾角角度辨识误差如图 11 (b)所示,在 11 (b)中,DFFRLS-AUKF 算法角度估计误差小于 DFFRLS-AEKF 与 DFFRLS-UKF 算法,说明 DFFRLS-AUKFF 算法角度识别精度最高。

为进一步量化在单轨道段 2 期间各算法所辨识的动态倾角精准度和时间复杂度,同样也采用平均绝对误差 (mean absolute error, MSE) 和均方根误差 (root mean square error, RMSE) 进行评估。单轨道段 2 各算法辨识的动态倾角 MAE、RMSE 值和时间复杂度如表 3 所示。

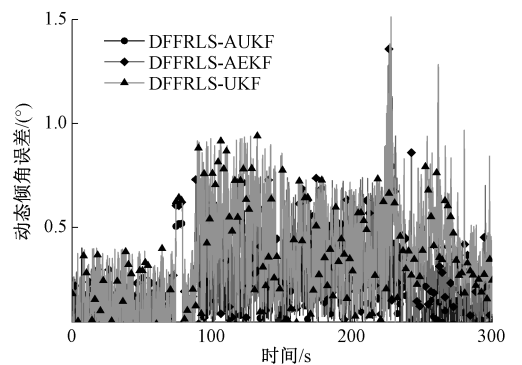
表 3 轨道段 2 动态倾角角度辨识结果的 MAE、RMSE 和时间复杂度

Table 3 MAE, RMSE and time complexity of the dynamic dip Angle identification results for track segment 2

算法名称	MAE	RMSE	执行时间/s
DFFRLS-AUKF	0. 209	0. 269	1. 750
DFFRLS-AEKF	0. 301	0. 369	1. 800
DFFRLS-UKF	0. 360	0. 436	1. 820



(a) 动态倾角角度辨识结果
(a) Dynamic dip angle identification results



(b) 动态倾角角度辨识误差
(b) Dynamic dip angle identification error

图 11 单轨道段 2 各算法倾角角度辨识结果及误差

Fig. 11 Monorail inclination angle section 2 each algorithm identification results and error

基于表 3, DFFRLS-AUKF 算法在单轨道段 2 期间,所辨识的动态倾角 MAE 及 RMSE 依然均最小。DFFRLS-AUKF 算法的 MAE 值相较于 DFFRLS-AEKF 与 DFFRLS-UKF 算法的 MAE 值分别减小了 30.5% 和 41.9%; DFFRLS-AUKF 算法的 RMSE 值相较于 DFFRLS-AEKF 与 DFFRLS-UKF 算法的 RMSE 值分别减小了 27.1% 和 38.3%;表明 DFFRLS-AUKF 算法具有良好的精准性和可靠性。在单轨道段 2 各算法执行时间方面,同样 DFFRLS-AUKF 算法执行时间最短,相比 DFFRLS-AEKF 和 DFFRLS-UKF 算法执行时间分别提升了 2.77% 和 3.84%;表明 DFFRLS-AUKF 算法的时间复杂度依然最低,该算法为单轨吊动态倾角地识别提供了有力保障。

5 结论

针对深部矿井轨道坡度复杂多变,导致单轨吊车动态倾角难以精准辨识的问题;提出了一种基于 DFFRLS-AUKF 算法的动态倾角辨识方法。该方法首先通过自适应滤波平滑滤波处理有效保障了数据的完整性,排除了

环境噪声的干扰,保障了轨道曲率获取地可靠性;并在复杂轨道工况条件下,建立了轨道曲率模型,通过带有动态遗忘因子的递归最小二乘算法(DFFRLS)利用滤波数据实现了轨道曲率的精准分析,与传统的 FFRLS 算法和 RLS-MFF 算法相比,其具有很高的可靠性;最终,利用 Sage-Husa 噪声估计器对无迹卡尔曼滤波(UKF)改进,通过 AUKF 算法破解了深部矿井轨道的坡度动态变化问题,可依据实际轨道情况,实时对当前动态倾角进行调整以获取精准地单轨吊车倾角值。DFFRLS-AUKF 算法对保障单轨吊车的安全行驶性能起到了重要作用。在未来的研究中,将进一步研究车体横向运动对单轨吊车动态倾角辨识精度地影响。

参考文献

- [1] 张文涛,张志勇,侯俊敏. 滑线式高速单轨吊机车的研发与应用前景[J]. 煤炭科学技术, 2020, 48(S2): 264-268.
ZHANG W T, ZHANG ZH Y, HOU J M. Research and development and application prospect of sliding line high-speed monorail crane [J]. Coal Science and Technology, 2020, 48(S2): 264-268.
- [2] 郭梁,宋建成,宁振兵,等. 基于捷联惯性导航的矿用单轨吊机车定位算法[J]. 工矿自动化, 2021, 47(1): 49-54, 86.
GUO L, SONG J CH, NING ZH B, et al. Mining monorails crane car positioning algorithm based on strapdown inertial navigation [J]. Industry and Mine Automation, 2021, 47(1): 49-54, 86.
- [3] 侯刚,王国法,薛忠新,等. 煤矿辅助运输自动驾驶关键技术与装备[J]. 采矿与岩层控制工程学报, 2022, 4(3): 5-17.
HOU G, WANG G F, XUE ZH X, et al. Key technology and equipment of automatic driving for auxiliary transportation in coal mine [J]. Journal of Mining and Rock Formation Control Engineering, 2022, 4(3): 5-17.
- [4] 郝胜强,罗培培,席军强. 基于稳态卡尔曼滤波的车辆质量与道路坡度估计[J]. 汽车工程, 2018, 40(9): 1062-1067, 1075.
HAO SH Q, LUO P P, XI J Q. Vehicle mass and road slope estimation based on steady-state Kalman filter [J]. Automotive Engineering, 2018, 40(9): 1062-1067, 1075.
- [5] 李倩,蒋正华,孙炎,等. 基于因子图的 INS/UWB 室内行人紧组合定位技术[J]. 仪器仪表学报, 2022, 43(5): 32-45.
LI Q, JIANG ZH H, SUN Y, et al. Indoor pedestrian positioning technology based on factor graph INS/UWB [J]. Chinese Journal of Scientific Instrument, 2022, 43(5): 32-45.
- [6] SUN C, LI K. A vehicle-carried INS positioning accuracy improvement method by using lateral constraint in GPS-denied environment [J]. IEEE Transactions on Vehicular Technology, 2022, 72(1): 205-213.
- [7] 孙海滨,赵清武,刘海威. 改进 IGABP 模型补偿倾角传感器温度漂移研究[J]. 电子测量与仪器学报, 2023, 37(3): 246-255.
SUN H B, ZHAO Q W, LIU H W. Research on temperature drift compensation of inclination sensor based on improved IGABP model [J]. Journal of Electronic Measurement and Instrument, 2023, 37(3): 246-255.
- [8] 朱璐瑛,孙炜玮,刘成铭,等. 多传感器组合导航系统的联邦 UKF 算法研究[J]. 电子测量与仪器学报, 2022, 36(7): 91-98.
ZHU L Y, SUN W W, LIU CH M, et al. Research on federated UKF algorithm of multi-sensor integrated navigation system [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(7): 91-98.
- [9] 邱望彦,李荣冰,刘建业. 基于改进自适应渐消卡尔曼滤波的通用航空 GNSS/微惯性组合导航算法研究[J]. 电子测量技术, 2020, 43(10): 95-100.
QIU W Y, LI R B, LIU J Y. Research on GNSS/MINS integrated navigation algorithm of general aviation based on improved adaptive fading Kalman filter [J]. Electronic Measurement Technology, 2020, 43(10): 95-100.
- [10] ZHANG Y, ZHANG Y, AI Z, et al. Estimation of electric mining haul trucks' mass and road slope using dual level reinforcement estimator [J]. IEEE Transactions on Vehicular Technology, 2019, 68(11): 10627-10638.
- [11] 段晨,廖福元. 基于惯性传感器和深度学习的上肢动作识别研究[J]. 国外电子测量技术, 2019, 38(11): 57-61.
DUAN CH, LIAO F Y. Research on upper limb action recognition based on inertial sensor and deep learning [J]. Foreign Electronic Measurement Technology, 2019, 38(11): 57-61.
- [12] 刘铁,段勇. 融合 CNN 和 Transformer 的机器人室内场景识别[J]. 电子测量与仪器学报, 2023, 37(5): 223-229.
LIU T, DUAN Y. Robot indoor scene recognition based on CNN and Transformer [J]. Journal of Electronic Measurement and Instrument, 2023, 37(5): 223-229.
- [13] 刘军,刘克诚,田甜,等. 基于自适应卡尔曼滤波算法的紧组合导航系统的研究[J]. 电子测量技术, 2019, 42(5): 52-55.
LIU J, LIU K CH, TIAN T, et al. Research on tight integrated navigation system based on adaptive Kalman filter algorithm [J]. Electronic Measurement Technology, 2019, 42(5): 52-55.

- [14] 沈跃,王德伟,孙志伟,等. 基于 RP-EKF 的无人机动动力系统参数辨识[J]. 仪器仪表学报,2023,44(4):314-321.
SHEN Y, WANG D W, SUN ZH W, et al. Parameter identification of UAV power system based on RP-EKF [J]. Chinese Journal of Scientific Instrument, 2023, 44 (4): 314-321.
- [15] 崔冰波,吉峰,孙宇,等. 高斯过程改进的鲁棒容积卡尔曼滤波及其组合导航应用[J]. 电子测量与仪器学报,2021,35(9):34-40.
CUI B B, JI F, SUN Y, et al. Gaussian process enhanced robust cubature Kallman filter and application in integrated navigation [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(9) : 34-40.
- [16] FRASER C T, UIRICH S. Adaptive extended Kalman filtering strategies for spacecraft formation relative navigation[J]. Acta Astronautica, 2021, 178: 700-721.
- [17] 冉旭,李亮,赵洵,等. 基于汽车动力学与加速度传感信息的纵向坡度实时识别算法[J]. 机械工程学报,2016,52(18):98-104.
RAN X, LI L, ZHAO X, et al. Real-time recognition algorithm of longitudinal slope based on vehicle dynamics and acceleration sensing information [J]. Chinese Journal of Mechanical Engineering, 2016, 52 (18) : 98-104.
- [18] 冯亦奇,陈勇. 基于遗忘因子的 UKF 车辆状态参数估计算法[J]. 合肥工业大学学报(自然科学版),2020,43(11):1450-1455,1499.
FENG Y Q, CHEN Y. UKF vehicle state parameter estimation algorithm based on forgetting factor [J]. Journal of Hefei University of Technology (Natural Science Edition), 2020, 43(11) : 1450-1455, 1499.
- [19] TIAN S, LUO X, XIAO C, et al. Real-time measurement of track curvature based on vehicle attitude perception [J]. Vehicle System Dynamics, 2023, 61(2) : 375-398.
- [20] 王科平,朱鹏飞,费树岷,等. 基于自适应平滑尺度粒子滤波的目标快速跟踪[J]. 信息与控制,2020,49(5):536-545.
WANG K P, ZHU P F, FEI SH M, et al. Fast target tracking based on adaptive smoothing scale particle filter [J]. Information and Control, 2020, 49(5) : 536-545.
- [21] 赵可沧,江境宏,邓进,等. 基于遗忘因子递推最小二乘法的锂电池等效电路模型参数辨识方法[J]. 电子测量技术,2022,45(16):87-92.
ZHAO K L, JIANG J H, DENG J, et al. Parameter identification method of lithium battery equivalent circuit model based on recursive least squares method with forgetting factor [J]. Electronic Measurement Technology, 2022, 45(16) : 87-92.
- [22] 赵月荷,庞宗强. 基于无迹卡尔曼滤波的动力电池健康状态估计[J]. 国外电子测量技术,2022,41(10):136-141.
ZHAO Y H, PANG Z Q. Health state estimation of power battery based on unscented Kalman filter [J]. Foreign Electronic Measurement Technology, 2022, 41(10) : 136-141.
- [23] 胡晓梅,潘新龙,朱璐瑛,等. 一种抗差自适应 UKF 算法及其在 GNSS/SINS 组合导航系统的应用[J]. 电子测量与仪器学报,2022,36(12):153-160.
HU X M, P X L, ZHU L Y, et al. An anti-error adaptive UKF algorithm and its application in GNSS/SINS integrated navigation system [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(12) : 153-160.
- [24] 张佳宁,李平华,庄须叶. 基于改进的 Sage-Husa 滤波 MEMS 陀螺阵列降噪技术研究[J]. 电子测量与仪器学报,2023,37(4):54-60.
ZHANG J J, LI P H, ZHUANG X Y. Research on MEMS gyroarray noise reduction technology based on improved sage-husa filter [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(4) : 54-60.

作者简介



刘泽朝,2019年于福州大学至诚学院获得学士学位,现为安徽理工大学电气与信息工程学院博士研究生,主要研究方向为矿山辅助运输机器人智能感知及控制。

E-mail: aust_zechao@163.com

Liu Zechao received a B. Sc. degree from Zhicheng College of Fuzhou University in 2019. He is now a Ph. D. candidate at the School of Electrical and Information Engineering of Anhui University of Science and Technology. His research interests include intelligent perception and control of mine auxiliary transportation robots.



李敬兆(通信作者),1986年于安徽理工大学获得学士学位,1992年于中国矿业大学获得硕士学位,2003年于合肥工业大学获得博士学位,现为安徽理工大学二级教授,博士生导师,主要研究方向为工业互联网技术、人工智能、智能控制。

E-mail: aust_iot_ljz@126.com

Li Jingzhao (Corresponding author) received a B. Sc. degree from Anhui University of Science and Technology in 1986, a M. Sc. degree from China University of Mining and Technology in 1992 and a Ph. D. degree from Hefei University of Technology in 2003. He is now a second-level professor and doctoral supervisor at Anhui University of Science and Technology. His main research interests include industrial Internet technology, artificial intelligence and intelligent control.