

文章编号: 1005-0523(2025)04-0037-11



基于车辆振动响应的轨道不平顺卡尔曼滤波反演

周生通^{1,2}, 刘怡辰¹, 肖乾¹, 罗志翔², 程玉琦¹, 顾祎昊¹

(1. 华东交通大学机电与车辆工程学院, 江西 南昌 330013; 2. 中车株洲电力机车有限公司重载
快捷大功率电力机车全国重点实验室, 湖南 株洲 412001)

摘要: 利用车辆振动响应反演轨道不平顺是轨道状态检测的重要手段, 是实现轨道车辆智能运维的关键环节。为此, 以某运行速度 160 km/h 的轨道车辆为例, 建立了车辆系统的横向、垂向和横垂耦合 3 种动力学模型, 并在车辆系统状态空间下推导了轨道不平顺反演方程, 给出了基于经典卡尔曼滤波(KF)/自适应卡尔曼滤波(AKF)算法的轨道不平顺反演流程, 最后详细探究了卡尔曼滤波算法、车辆动力学模型和观测方案对轨道横向和垂向不平顺反演结果的影响规律。结果显示: 相比于单一横向和垂向模型, 横垂耦合模型在 KF 算法中的轨道不平顺反演效果最佳, 表明横垂耦合模型能够更好地模拟车辆横向和垂向运动行为; AKF 算法在单一横向和垂向模型表现更优, 但在横垂耦合模型中并未发挥出自适应调参优势, 表明对于复杂高维耦合模型自适应策略不能保证一定收敛到最优解, 反而对于更简单低维模型的自适应反演效果更好; 观测方案对轨道不平顺反演结果影响较大, 特别是单一的振动加速度观测难以有效反演轨道不平顺, 应结合实际补充有效振动响应信息。

关键词: 轨道车辆; 振动响应; 轨道不平顺; 反演方程; 卡尔曼滤波

中图分类号: U266; TH113

文献标志码: A

本文引用格式: 周生通, 刘怡辰, 肖乾, 等. 基于车辆振动响应的轨道不平顺卡尔曼滤波反演[J]. 华东交通大学学报, 2025, 42(4): 37-47.

Kalman Filter-Based Inversion of Track Irregularities from Vehicle Vibration Response

Zhou Shengtong^{1,2}, Liu Yichen¹, Xiao Qian¹, Luo Zhixiang², Cheng Yuqi¹, Gu Yihao¹

(1. School of Mechatronics & Vehicle Engineering, East China Jiaotong University, Nanchang 330013, China;

2. The State Key Laboratory of Heavy-Duty and Express High-Power Electric Locomotive,

CRRC Zhuzhou Locomotive Co., Ltd., Zhuzhou 412001, China)

Abstract: The inversion of track irregularity using vehicle vibration responses serves as a vital method for track condition detection and a key part in achieving intelligent operation and maintenance of railway vehicles. To this end, this paper takes a railway vehicle operating at 160 km/h as an example, establishing three dynamic models for the vehicle system: lateral, vertical, and lateral-vertical coupled. The track irregularity inversion equation is derived within the state-space framework of the vehicle system. An inversion process for track irregularity based on the classical Kalman filter (KF) and adaptive Kalman filter (AKF) algorithms is presented. Finally, a detailed investigation is conducted into the influence patterns of the Kalman filter algorithms, vehicle dynamics models,

收稿日期: 2025-07-12

基金项目: 国家自然科学基金项目(52462054, 52372327, 52065022); 江西省自然科学基金项目(20242BAB204122); 江西省教育厅科学技术研究项目(GJJ210638)

and observation schemes on the inversion results of lateral and vertical track irregularities. The results indicate: Compared to single lateral or vertical models, the lateral-vertical coupled model yields the best inversion results under the KF algorithm, demonstrating its superior capability in simulating the lateral and vertical motion behaviors of the vehicle. The AKF algorithm performs better in single lateral and vertical models but fails to leverage its adaptive parameter-tuning advantages in the lateral-vertical coupled model. This suggests that adaptive strategies may not guarantee convergence to optimal solutions for complex high-dimensional coupled models, whereas simpler low-dimensional models benefit more from adaptive inversion. The observation scheme significantly impacts track irregularity inversion results. Specifically, relying solely on vibration acceleration measurements proves inadequate for effective inversion. Therefore, effective vibration responses shall be supplemented in combination with the actual situation.

Key words: railway vehicles; vibration responses; track irregularity; inversion equation; Kalman filter

Citation format: ZHOU S T, LIU Y C, XIAO Q, et al. Kalman filter-based inversion of track irregularities from vehicle vibration response[J]. Journal of East China Jiaotong University, 2025, 42(4): 37–47.

轨道不平顺是引起轮轨力动态变化及车辆振动的主要外部激励,直接影响车辆运行安全性、平稳性和乘坐舒适性,因此,及时可靠地检测轨道不平顺状态对保障行车安全、深入研究车辆系统动力学行为及结构强度演化规律至关重要,亦是实现车辆智能运维的关键环节。

轨道不平顺检测的直接方法是使用轨道检测车,然而这类检测车造价昂贵,且检测间隔周期较长。在各种新兴方法中,利用车辆振动响应来估计轨道不平顺的技术因其成本低、效率高而受到人们的普遍关注,成为当前检测轨道线路状态的重要手段,已发展了基于数据驱动的机器学习方法和基于模型驱动的反演估计方法两大类。其中,基于数据驱动的机器学习方法以轨道车辆的历史运行数据为基础,直接建立观测信号与轨道状态之间的非线性映射关系,近年来逐步兴起且发展迅速^[1-3]。然而,数据驱动的方法往往对数据的数量和质量有较高的需求,实际中难以满足。相比之下,基于模型驱动的方法能够利用车辆动力学模型逆向建立轨道状态与车辆振动响应的关系,进而实现轨道不平顺的反演估计。在模型驱动方法中,卡尔曼滤波^[4]因其时效性高、鲁棒性强,被广泛应用于轨道车辆运行监测。例如 Muñoz 等^[5]建立仅含一个轮对和一个构架的简化车辆横向模型,并借助惯性传感器观测实现了基于经典卡尔曼滤波的轨道横向不平顺估计。李振乾等^[6]提出基于卡尔曼滤波算法的轴箱

轴承载荷反演方法,分别建立整车单一垂向和横向模型实现轴承垂向和横向载荷反演。唐嘉等^[7]针对轴承载荷反演过程中卡尔曼滤波参数难以确定,采用自适应小生境遗传算法进行参数优化,提升了反演效果。Guo 等^[8]提出了基于确定性未知输入观测器方法的反演流程,并通过车辆横垂耦合模型以及车体和转向架的动态响应观测量,实现了轨道垂向及横向不平顺的反演。Strano 等^[9]提出基于中心差分卡尔曼滤波的非线性模型估计方法,利用半车体横向模型实现了轮轨横向接触力/力矩和轨道横向不平顺反演。Xiao 等^[10]考虑车桥耦合作用提出了基于车辆动态响应识别铁路桥梁轨道不平顺的卡尔曼滤波算法。柯飙^[11]考虑到经典卡尔曼滤波在噪声矩阵未知情况下估计结果精度较差,故而建立了基于自适应卡尔曼滤波的整车垂向轨道不平顺反演模型,结果精度得到了有效提升。归纳已有研究可知,基于卡尔曼滤波的模型驱动方法已得到普遍应用与验证,但实际运用中仍存在算法参数、模型简化和观测量等选择显著影响估计结果的问题^[7,11-13]。尽管这些问题在一些文献已有所涉及但仍缺乏系统的对比研究,特别是对于不同精细程度的车辆模型以及不同观测方案等对反演结果的影响。

鉴于此,本文以某轨道车辆为例,分别建立3种车辆系统动力学模型,并在状态空间下推导轨道不平顺反演方程,给出基于经典/自适应卡尔曼滤波算法的轨道不平顺反演流程,最后探究不同卡尔曼滤

波算法、不同车辆模型和不同观测方案对轨道横向和垂向不平顺反演结果的影响规律,以期对轨道状态实时监测和智能运维管理提供技术支持。

1 轨道车辆系统动力学模型

基于车辆振动响应反演轨道不平顺的重要前提是建立有效的车辆系统动力学模型。本文以某运行速度 160 km/h 的轨道车辆为例,建立 3 种车辆动力学模型,即整车横垂耦合模型、垂向模型和横向模型。图 1 所示是轨道车辆系统动力学模型结构示意,由车体、前构架、后构架和四条轮对的左右车轮组成。




图1 轨道车辆系统动力学模型

Fig. 1 Dynamic model of railway vehicle system

若考虑车辆各部件的横向和垂向运动(忽略伸缩自由度),则模型中车体和前后构架均具有 5 个自由度(横移 \$y\$、浮沉 \$z\$、侧滚 \$\phi\$、点头 \$\beta\$、摇头 \$\psi\$),且每个车轮(区分左轮 \$L\$、右轮 \$R\$)位置受到横向和垂向轨道不平顺激励(\$y_{Li}, z_{Li}, y_{Ri}, z_{Ri}, i=1, 2, 3, 4\$)作用。于是,当不考虑轮轨接触特性,并假设车轮始终与轨道表面接触,不发生跳轨现象,则车辆系统动力学方程可表达为

$$\mathbf{M}\ddot{\mathbf{Z}} + \mathbf{C}\dot{\mathbf{Z}} + \mathbf{K}\mathbf{Z} = \mathbf{D}\mathbf{U} + \mathbf{E}\dot{\mathbf{U}} \quad (1)$$

式中: \$\mathbf{M}\$、\$\mathbf{C}\$、\$\mathbf{K}\$ 分别是车辆系统的质量、阻尼、刚度矩阵,维数 \$15 \times 15\$; \$\mathbf{D}\$、\$\mathbf{E}\$ 分别是轨道不平顺的位移和速度作用矩阵,维数 \$15 \times 16\$; 限于篇幅这里省略具体表述,详见文献[14]; \$\mathbf{Z}\$ 是车辆振动位移状态向量,由车体和前后构架共计 15 个自由度组成,即

$$\mathbf{Z} = [y_c, \psi_c, \phi_c, z_c, \beta_c, y_{f1}, \psi_{f1}, \phi_{f1}, z_{f1}, \beta_{f1}, y_{f2}, \psi_{f2}, \phi_{f2}, z_{f2}, \beta_{f2}]^T \quad (2)$$

\$\mathbf{U}\$ 是轨道不平顺位移激励向量,由四条轮对的左右车轮共计 16 个自由度组成,即

$$\mathbf{U} = [y_{L1}, y_{R1}, z_{L1}, z_{R1}, y_{L2}, y_{R2}, z_{L2}, z_{R2}, y_{L3}, y_{R3}, z_{L3}, z_{R3}, y_{L4}, y_{R4}, z_{L4}, z_{R4}]^T \quad (3)$$

可见,前述车辆系统动力学方程表达的是一个具有 15 自由度的整车横垂耦合模型,在轮对的左右车轮位置受到横向和垂向轨道不平顺激励作用。需要注意的是,从理论上,四条轮对位置的轨道不平顺激励仅存在相位上的差异,但本文将四条轮对位置的 16 条轨道不平顺均看作待反演的未知激励。

考虑到轨道车辆垂向运动和横向运动二者的弱耦合性特点,工程实际中亦常作解耦处理,建立单一横向和垂向模型^[14]。对于单一横向模型,主要涉及车体和前后构架的横移 \$y\$、摇头 \$\psi\$ 和侧滚 \$\phi\$ 自由度, \$\mathbf{Z}\$ 和 \$\mathbf{U}\$ 分别为

$$\mathbf{Z} = [y_c, \psi_c, \phi_c, y_{f1}, \psi_{f1}, \phi_{f1}, y_{f2}, \psi_{f2}, \phi_{f2}]^T \quad (4)$$

$$\mathbf{U} = [y_{L1}, y_{R1}, y_{L2}, y_{R2}, y_{L3}, y_{R3}, y_{L4}, y_{R4}]^T \quad (5)$$

对于单一垂向模型,主要涉及车体和前后构架的沉浮 \$z\$、点头 \$\beta\$ 和侧滚 \$\phi\$ 自由度, \$\mathbf{Z}\$ 和 \$\mathbf{U}\$ 分别为

$$\mathbf{Z} = [\phi_c, z_c, \beta_c, \phi_{f1}, z_{f1}, \beta_{f1}, \phi_{f2}, z_{f2}, \beta_{f2}]^T \quad (6)$$

$$\mathbf{U} = [z_{L1}, z_{R1}, z_{L2}, z_{R2}, z_{L3}, z_{R3}, z_{L4}, z_{R4}]^T \quad (7)$$

可以看到,对于单一方向的横向和垂向模型均是具有 9 个自由度的车辆动力学系统,并分别在左右车轮位置单一地受到 8 条横向(或垂向)轨道不平顺激励作用。

从推导的运动方程来看,横向和垂向模型均涉及侧滚方向(\$\phi_c, \phi_{f1}\$ 和 \$\phi_{f2}\$)的动力学方程,因此,横垂耦合模型的横向和垂向运动之间的耦合是通过车辆侧滚动力学方程关联的,在模型精细程度上要优于单一横向和垂向模型,但相应地动力学模型维数增加,模型也变得更复杂。

2 轨道不平顺反演方程

根据卡尔曼滤波原理,车辆动力学方程(1)要改写为系统状态空间表达,包括状态方程和观测方程两部分,

$$\begin{cases} \dot{\mathbf{x}} = \mathbf{A}\mathbf{x} + \mathbf{B}\mathbf{u} & \text{状态方程} \\ \mathbf{y} = \mathbf{H}\mathbf{x} + \mathbf{L}\mathbf{u} & \text{观测方程} \end{cases} \quad (8)$$

式中: \$\mathbf{x} = [\mathbf{Z}^T, \dot{\mathbf{Z}}^T]^T\$ 为车辆振动位移和速度组成的状态向量,是可观测状态量; \$\mathbf{u} = [\mathbf{U}^T, \dot{\mathbf{U}}^T]^T\$ 为轨道不平顺位移和速度组成的输入向量,是待反演的未知量; \$\mathbf{A}\$ 为系统过程矩阵; \$\mathbf{B}\$ 为输入传递矩阵,表示输入对状态的作用; \$\mathbf{y}\$ 为系统状态观测向量; \$\mathbf{H}\$ 为观测矩阵; \$\mathbf{L}\$ 为直连矩阵,表示输入对系统输出的直接

影响。

对于15自由度的横垂耦合模型,其系统过程矩阵 A 和输入传递矩阵 B 具有如下形式

$$A = \begin{bmatrix} \mathbf{0}_{15 \times 15} & \mathbf{I}_{15 \times 15} \\ -\mathbf{M}^{-1}\mathbf{K} & -\mathbf{M}^{-1}\mathbf{C} \end{bmatrix}, \quad B = \begin{bmatrix} \mathbf{0}_{15 \times 16} & \mathbf{0}_{15 \times 16} \\ \mathbf{M}^{-1}\mathbf{D} & \mathbf{M}^{-1}\mathbf{E} \end{bmatrix} \quad (9)$$

对于简化的9自由度单一横向和垂向模型,矩阵 A 和 B 具有与横垂耦合模型一致的形式,仅在矩阵维数和自由度类型上有所差异。

对式(8)离散化,有离散状态空间方程

$$\begin{cases} \mathbf{x}(k+1) = \mathbf{F}\mathbf{x}(k) + \mathbf{G}\mathbf{u}(k) \\ \mathbf{y}(k) = \mathbf{H}\mathbf{x}(k) + \mathbf{L}\mathbf{u}(k) \end{cases} \quad (10)$$

式中: $\mathbf{F} = (\mathbf{I} + \mathbf{A} \cdot \Delta T)$, $\mathbf{G} = \Delta T \cdot \mathbf{B}$, ΔT 为采样时间间隔。由于卡尔曼滤波仅对状态向量 $\mathbf{x}$ 进行反演估计,因此,为了反演轨道不平顺输入向量 $\mathbf{u}$,这里对系统状态进行扩维,即引入扩维状态向量

$$\mathbf{X}(k) = \begin{bmatrix} \mathbf{x}(k) \\ \mathbf{u}(k) \end{bmatrix} = \begin{bmatrix} \mathbf{Z}(k) \\ \dot{\mathbf{Z}}(k) \\ \mathbf{R}(k) \\ \dot{\mathbf{R}}(k) \end{bmatrix} \quad (11)$$

于是,扩维离散状态空间方程为

$$\begin{cases} \mathbf{X}(k+1) = \mathbf{A}\mathbf{X}(k) + \mathbf{v}(k) \\ \mathbf{Y}(k) = \mathbf{H}_1\mathbf{X}(k) + \omega(k) \end{cases} \quad (12)$$

其中,

$$\begin{cases} \mathbf{A} = \begin{bmatrix} \mathbf{F} & \mathbf{G} \\ \mathbf{0} & \mathbf{\Omega} \end{bmatrix}, \quad \mathbf{H}_1 = [\mathbf{H} \quad \mathbf{L}] \\ \mathbf{v}(k) \sim \mathbf{N}(\mathbf{0}, \mathbf{Q}), \quad \omega(k) \sim \mathbf{N}(\mathbf{0}, \mathbf{R}) \end{cases} \quad (13)$$

式中: $\mathbf{v}(k)$, $\omega(k)$ 分别假设为服从高斯白噪声的系统噪声和观测噪声; $\mathbf{Q}$ 和 $\mathbf{R}$ 是相应的协方差矩阵; $\mathbf{\Omega}$ 为系统输入向量 $\mathbf{u}$ 在 $k+1$ 时刻和 k 时刻间的联系矩阵,若假设一个采样周期 ΔT 中轨道不平顺变化速率基本保持不变^[11],则有

$$\mathbf{\Omega} = \begin{bmatrix} \mathbf{I} & \text{diag}(\Delta T) \\ \mathbf{0} & \mathbf{I} \end{bmatrix} \quad (14)$$

$\mathbf{Y}(k)$ 为系统状态观测向量,因为本文仅通过观测车辆振动响应反演轨道不平顺,故有直连矩阵 $\mathbf{L}$ 为 $\mathbf{0}$ 。若观测车辆的振动位移和速度状态 $\mathbf{x}$,则有观测矩阵 $\mathbf{H}$ 为单位矩阵。若完整观测车辆的振动位移、速度和加速度响应信息,则需重写观测方程为

$$\mathbf{Y}(k) = \begin{bmatrix} \bar{\mathbf{Z}}(k) \\ \bar{\dot{\mathbf{Z}}}(k) \\ \bar{\ddot{\mathbf{Z}}}(k) \end{bmatrix} = \mathbf{H}_1 \begin{bmatrix} \mathbf{Z}(k) \\ \dot{\mathbf{Z}}(k) \\ \mathbf{R}(k) \\ \dot{\mathbf{R}}(k) \end{bmatrix} + \omega(k) \quad (15)$$

式中: $\bar{\mathbf{Z}}(k)$, $\bar{\dot{\mathbf{Z}}}(k)$, $\bar{\ddot{\mathbf{Z}}}(k)$ 是车辆状态观测测量;

$$\mathbf{H}_1 = \begin{bmatrix} \mathbf{I} & \mathbf{0} & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{I} & \mathbf{0} & \mathbf{0} \\ -\mathbf{M}^{-1}\mathbf{K} & -\mathbf{M}^{-1}\mathbf{C} & \mathbf{M}^{-1}\mathbf{D} & \mathbf{M}^{-1}\mathbf{E} \end{bmatrix} \quad (16)$$

实际中,观测方案往往依赖于传感器布置,此时仅需保留观测量所对应的自由度方程即可实现观测方程(15)重构,实现不同观测方案的不平顺反演。

在离散扩展状态方程(12)基础上,基于卡尔曼滤波算法即可实现系统扩展状态 $\mathbf{X}(k)$ 的估计 $\hat{\mathbf{X}}(k)$,进而得到轨道不平顺的反演值 $\hat{\mathbf{u}}(k)$ 。图2给出了考虑系统噪声协方差矩阵 $\mathbf{Q}$ 和测量噪声协方差矩阵 $\mathbf{R}$ 更新的自适应卡尔曼滤波算法流程。可以看到,该算法通过建立的系统状态空间模型,利用测量的观测数据不断迭代更新状态估计结果,包括预测和更新两个阶段,使其逐渐逼近系统的真实状态,达到状态估计的目的。算法中矩阵 $\mathbf{Q}$ 和 $\mathbf{R}$ 的合理设定是卡尔曼滤波性能优化的关键^[7,11]。若整个算法迭代过程中 $\mathbf{Q}_k = \mathbf{Q}_0$, $\mathbf{R}_k = \mathbf{R}_0$,则退化为经典卡尔曼滤波(KF)算法;若按照一定规则动态调整 $\mathbf{Q}_k$ 和 $\mathbf{R}_k$,则称为自适应卡尔曼滤波(AKF)算法,本文采用改进Sage-Husa自适应策略^[14-15],以使滤波器自动适应环境变化,

$$\mathbf{Q}_k = (1 - d_{k1})\mathbf{Q}_{k-1} + d_{k1}(\hat{\mathbf{X}}_k - \hat{\mathbf{X}}_{k-1})(\hat{\mathbf{X}}_k - \hat{\mathbf{X}}_{k-1})^T \quad (17)$$

$$\mathbf{R}_k = (1 - d_{k2})\mathbf{R}_{k-1} + d_{k2}(\mathbf{Y}_k - \mathbf{H}_1\hat{\mathbf{X}}_k)(\mathbf{Y}_k - \mathbf{H}_1\hat{\mathbf{X}}_k)^T \quad (18)$$




图2 考虑 $\mathbf{Q}$ 和 $\mathbf{R}$ 更新的自适应卡尔曼滤波算法流程
Fig. 2 Flow of adaptive Kalman filter algorithm with $\mathbf{Q}$ and $\mathbf{R}$ updates

式中: d_{k1} 和 d_{k2} 是平滑因子,取值为 0~1,被定义为 $d_{k1} = (1 - b_1)/(1 - b_1^{k+1})$, $d_{k2} = (1 - b_2)/(1 - b_2^{k+1})$, $b_1, b_2 \in [0.95, 0.99]$ 。AKF 算法能够有效减小 KF 算法中的计算复杂度,并保持滤波降噪计算的实时性和自适应性,能够有效提高信号的降噪精度。

3 3种模型下KF和AKF算法反演对比

3.1 问题描述

本节分别基于 KF 和 AKF 算法对 3 种模型(横向、垂向和横垂耦合)下的轨道不平顺位移进行反演和结果对比,具体方案如图 3 所示。首先,以前述某运行速度 160 km/h 的轨道车辆为对象,考虑到真实车辆振动响应和轨道不平顺激励难以完备跟踪,故而借助模型校正方法建立有效的 UM 仿真模型作为该车辆的虚拟样机,简称虚拟车辆。其次,在该虚拟车辆基础上,一方面通过施加已知的德国谱轨道不平顺激励获得车辆状态的仿真振动响应,分别作为轨道不平顺实际值和车辆状态观测值,用于后续轨道不平顺的反演估计和对比;另一方面,基于校正的虚拟车辆 UM 模型建立更准确的等价车辆系统动力学单一横向、单一垂向或横垂耦合模型方程,即式(1),进而通过改写和扩维得到轨道不平顺反演模型。最后,基于经典或自适应的卡尔曼滤波算法,并以与观测数据一致的时间间隔 0.1 ms 迭代得到轨道不平顺的最优反演估计量,与实际轨道不平顺作对比分析,验证有效性。




图3 轨道不平顺反演过程

Fig. 3 Inversion procedure of track irregularity

为了更好地评价轨道不平顺反演结果,本文采用绝对误差和均方根误差(RMSE)来度量估计值与实际值之间的差异。其中,绝对误差 $E_{abs,i}$ 定义为估计值 $X_{est,i}$ 减去实际值 $X_{rel,i}$ 的绝对值,即

$$E_{abs,i} = |X_{est,i} - X_{rel,i}|, i = 1, 2, \dots, n \quad (19)$$

RMSE 定义为估计值与实际值误差平方和的平均值再开平方根,即

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_{est,i} - X_{rel,i})^2}{n}} \quad (20)$$

显然,绝对误差和均方根误差越小,轨道不平顺的反演估计结果就越准确。

3.2 基于KF算法的反演结果

图 4~图 6 给出了基于 KF 算法的 3 种模型在一位轮对左侧轨道的不平顺反演结果和绝对误差。可以看到,3 种模型的轨道不平顺反演估计值与实际值在趋势上保持了良好的一致性,特别是较好地捕捉了轨道不平顺的低频变化趋势。从图 4 中绝对误差来看,垂向模型反演的垂向不平顺绝对误差最大值不超过 8 mm,横向模型反演的横向不平顺误差最大值接近 10 mm;而横垂耦合模型反演的垂向




图4 基于垂向模型的轨道垂向不平顺KF算法反演结果
Fig. 4 Inversion of vertical track irregularity using KF algorithm based on vertical model




图5 基于横向模型的轨道横向不平顺KF算法反演结果
Fig. 5 Inversion of lateral track irregularity using KF algorithm based on lateral model




图6 基于横垂耦合模型的轨道不平顺KF算法反演结果
Fig. 6 Inversion of track irregularity using KF algorithm based on lateral-vertical coupling model

不平顺最大绝对值误差小于6 mm,相比单一垂向模型下降25%,横向不平顺最大绝对值小于3 mm,相比单一横向模型下降70%。可见,KF算法时横垂耦合模型的轨道不平顺反演误差明显比单一的横向或垂向模型更小,表明复杂高维的横垂耦合模型比单一方向模型更能有效地模拟车辆的横向和垂向运动行为。

进一步,基于RMSE评价3种模型在不同轮对位置下的轨道不平顺反演精度,如图7和图8所示。可以看到,在四条轮对的左右轨位置,无论是横向还是垂向轨道不平顺,基于横垂耦合模型的反演RMSE均比单一方向模型更低,特别是对于横向不平顺反演工况,其在横垂耦合模型的RMSE范围[0.73, 0.92] mm,显著低于纯横向模型的RMSE范围[3.11, 3.82] mm。这表明考虑横垂耦合效应后,基于KF算法的轨道不平顺反演精度明显提高,这一规律与前文基于绝对值误差的比较结论一致。

其次,同一轨道不平顺在四条轮对位置处的反演结果RMSE各不相同,这主要是由模型误差造成的。事实上,受真实车辆车体及车载设备的影响,本文所构造的虚拟车辆UM模型是前后非对称性,导致轨道不平顺激励对不同轮对位置的车辆振动影响具有非一致性,而在状态方程建模时又是以简




图7 轨道横向不平顺KF算法反演结果RMSE对比
Fig. 7 RMSE comparison of inversion results of lateral track irregularity using KF algorithm




图8 轨道垂向不平顺KF算法反演结果RMSE对比
Fig. 8 RMSE comparison of inversion results of vertical track irregularity using KF algorithm

化的前后对称车辆推导建模的,所产生的模型误差致使轨道不平顺反演结果在不同轮对位置有所差异。但需要注意的是,这种差异总体不大,侧面证明了卡尔曼滤波算法的鲁棒性。

此外,注意到同一轮对在左右轨位置的反演结果,即:横向不平顺RMSE相同,而垂向不平顺RMSE不同。这主要归结于施加在左右轨的不平顺激励设置有差异,因为本例施加的是德国轨道谱数据,其在左右轨的横向不平顺激励是一致的,而垂向不平顺激励是有不同的。这一现象也侧面证明了基于卡尔曼滤波反演轨道不平顺的方法正确性。

最后,虽然采用横垂耦合模型时,横向和垂向轨道不平顺RMSE值均比单一方向模型时更小,但

是相比于垂向不平顺,横向不平顺的RMSE降幅更明显,这一现象在前述绝对误差比较中也能够发现。这表明所构建的横垂耦合模型能更好地捕捉横向不平顺。事实上,相比于单一的垂向模型,单一的横向模型往往会引入更多简化,而这些简化在横垂耦合模型中能够被大大克服,进而更好地捕捉车辆横向动力学行为,最终在横向不平顺反演中达到更好的精度。

3.3 基于AKF算法的反演结果

图9~图11给出了基于AKF算法的3种模型在一位轮对左轨位置的轨道不平顺反演结果。与前述基于KF算法的反演结果一样,3种模型下AKF算法同样能够良好地反演出轨道不平顺,特别是较好地捕捉了低频变化趋势。不过,在绝对误差方面,与KF算法不同,相比于单一方向模型,AKF算法在横垂耦合模型时并未对反演结果带来很好的提升,甚至有所劣化,例如图9中单一垂向模型的不平顺反演误差最大值接近7 mm,而图11(a)中横垂耦合模型的垂向误差最大值接近9 mm,这表明在基于AKF算法的反演中更精细的横垂耦合模型反而




图9 基于垂向模型的轨道垂向不平顺AKF算法反演结果
Fig. 9 Inversion of vertical track irregularity using AKF algorithm based on vertical model






图10 基于横向模型的轨道横向不平顺AKF算法反演结果
Fig. 10 Inversion of lateral track irregularity using AKF algorithm based on lateral model



(a) 轨道垂向不平顺



(b) 轨道横向不平顺

图11 基于横垂耦合模型的轨道不平顺AKF算法反演结果
Fig. 11 Inversion of track irregularity using AKF algorithm based on lateral-vertical coupling model

没有单一的垂向模型效果好。

进一步,基于RMSE评价3种模型分别利用KF算法和AKF算法反演轨道不平顺的精度,如图12~图14。从图中可以看到,相比于KF,AKF算法在单一横向和垂向模型中的轨道不平顺反演通常能获得更好的RMSE精度,至少能够达到与KF算法结果基本一致的精度,特别是横向不平顺(图12)时各轮对位置RMSE降低达30%~58%。然而,对于横垂耦合模型,基于AKF算法的不平顺反演结果RMSE反而比KF算法有所增大,这表明虽然在算法设计上AKF算法更胜一筹,但面对复杂高维的横垂耦合模型自适应调参的AKF算法并非一定能够收敛到最优解,反而是KF算法手动设置合理的参数后能反演出更优解。

综上所述,相比于更为复杂高维的横垂耦合模型,本例中AKF算法在更为简单低维的单一横向和垂向模型中反演效果更佳。不过,需要注意的是,这并非意味着AKF算法不适用于复杂高维模型,反而在复杂高维模型中更需要AKF算法。事实上,KF算法需要不断地手动调整 Q 和 R 的初值才能达到满足精度的估计值,更依赖经验;相比之下,初值设置对AKF算法结果的影响不大,通过自适应地对 Q 和 R 动态调整达到最佳估计目的。因而,实际中




图12 轨道横向不平顺AKF算法反演结果RMSE对比

Fig. 12 RMSE comparison of inversion results of lateral track irregularity using AKF algorithm




图13 左轮垂向轨道不平顺AKF算法反演结果RMSE对比

Fig. 13 RMSE comparison of inversion results of left wheel vertical track irregularity using AKF algorithm

AKF算法通常比KF算法有更好的适用性和结果精度,至少能达到与KF算法同等级的反演精度。

4 观测方案对反演结果的影响

在前文研究中,轨道不平顺反演是基于车辆振动响应的完全信息,即观测是车辆各部件的振动位移、速度和加速度响应信息。然而,实际中除振动加速度外,各部件的绝对位移和绝对速度信息往往难以直接测量。因此,探究合适的观测是基于一车辆振动响应反演轨道不平顺的重要内容。为此,本节考虑传感器布置的可行性,设计了3种贴合实际的车辆振动响应观测方案,并基于观测方案推导




图14 右轮垂向轨道不平顺AKF算法反演结果RMSE对比

Fig. 14 RMSE comparison of inversion results of right wheel vertical track irregularity using AKF algorithm

状态方程,联合前述KF算法和横垂耦合模型,分析不同方案下轨道不平顺反演的准确性和稳定性。

4.1 方案1:仅观测各部件加速度响应

考虑到振动加速度的易测性,方案1仅观测车体、前构架和后构架的振动加速度信息。从图15可知,轨道不平顺反演估计值与实际值在波动规律上具有一致性,且无漂移现象,但误差较大,反演值明显低于实际值,劣于第3节基于全部观测量的反演结果,这表明缺失绝对位移和速度的振动观测方案在实际轨道不平顺反演中结果准确度将大幅降低。

4.2 方案2:观测加速度响应并作二次积分

方案2是在方案1仅观测振动加速度基础上,引入一次、二次积分处理,利用数学手段得到各部件振动速度与位移补充信息。从图16可知,通过积分补充振动速度和位移的方案2其轨道不平顺反演估计值与实际值在整体波动规律上同样具有相似性。不过,相比于方案1,方案2存在明显的负向漂移现象,特别是垂向不平顺的反演结果,例如在5 s时刻,横向不平顺幅值偏移至约-26 mm位置,垂向不平顺幅值偏移至接近-70 mm位置。究其原因主要是,振动加速度的二次积分易受到测量的低频噪声干扰,若为真实的实验数据还会受到温度漂移的影响,导致通过积分获得的速度、位移信号中含有明显的趋势项,该趋势项在滤波过程中未能有效滤除,最终出现系统性偏移,需采用高通滤波或漂移修正机制处理。因此,尽管方案2的观测维度完整性最高,但由于基于数学积分补充后的输入信号误差较




图15 方案1的轨道不平顺反演结果
Fig. 15 Track irregularity inversion results of Scheme 1




图16 方案2的轨道不平顺反演结果
Fig. 16 Track irregularity inversion results of Scheme 2

大,使得轨道不平顺的反演效果反而劣于方案1。这说明,在基于卡尔曼滤波的轨道不平顺反演中,观测量的数据质量十分重要,强行依赖未经滤波修正的积分信号补偿是不可取的,易形成系统误差,破坏滤波器的收敛性与稳定性,导致漂移和误差放大。

4.3 方案3:观测加速度及相对位移响应

考虑轨道车辆中各部件的相对运动量往往比绝对运动量更易测量,故方案3在方案1基础上新增了车体与前后构架的相对位移和相对转角两种观测量。从图17可知,该方案在3种观测方案中表现最佳,无论是横向还是垂向,轨道不平顺反演估计值与实际值吻合度明显高于前两种方案,且波形无明显滞后、幅值偏差整体减小,系统性漂移

现象基本消除。这说明,相对位移和转角的引入提供了构架姿态变化与车体姿态变化的间接观测补偿,而且能够更准确地反映姿态转动对平移运动的贡献,增强观测方程的完整度,进一步提升反演精度。

另外,方案3反演结果未见明显漂移,这表明增加相对位移、相对角度这类相对观测量有效补偿了绝对位移不可观测的问题,可以有效降低轨道不平顺反演误差,对车辆整体发生绝对位移相关的大趋势漂移有显著限制效果。不过,需要指出的是,与第3节基于完整振动响应的反演结果对比,任何减少观测量的其他方案均会影响轨道不平顺状态反演精度,工程中应结合实际情况选择最可行的观测方案。




图17 方案3的轨道不平顺反演结果

Fig. 17 Track irregularity inversion results of Scheme 3

5 结论

针对基于车辆振动响应的轨道不平顺卡尔曼滤波反演问题,本文建立了3种不同精细程度的车辆系统动力学模型,推导了车辆系统状态空间方程,给出了基于KF/AKF算法的不平顺反演流程,得到了2种卡尔曼滤波算法、3种车辆模型以及3种观测方案对轨道不平顺状态反演效果的影响规律。主要结论如下。

1) 无论是KF还是AKF算法,在3种模型下轨道不平顺反演估计值与实际值在趋势上均保持了良好的一致性,特别是较好地捕捉了轨道不平顺的低频变化趋势。

2) 相比于单一横向和垂向模型,横垂耦合模型在KF算法中的轨道不平顺反演效果最佳、稳定性更好,表明横垂耦合模型能够更好地模拟车辆横向和垂向运动行为。

3) 相比于KF,AKF算法在单一横向和垂向模型表现更优,其中横向不平顺估计误差能够降低30%~58%,但在横垂耦合模型中并未发挥出自适应调参优势,表明对于复杂高维耦合模型自适应策略不能保证一定收敛到最优解,反而对于更简单低维模型的自适应反演效果更好,因此工程实际中不能一味追求模型复杂度。同时,需要注意到,KF算法高度依赖于滤波参数初值设置,需要经验反复调整;而AKF算法可自适应动态调整滤波参数,对初值敏感性较低,在实际应用中适用性更好。

4) 方案1由于仅观测加速度信息,反演结果误差较大;方案2虽增加了积分后的观测量但因漂移

误差导致效果不如预期;方案3通过融合加速度和相对位移、角度等观测量,显著抑制了漂移误差,在轨道不平顺反演中具备明显优越性。由此可见,观测方案对轨道不平顺反演结果影响较大,特别是单一的振动加速度观测量难以有效反演轨道不平顺,应结合实际补充有效振动信息。

参考文献:

- [1] LI C Z, HE Q, WANG P. Estimation of railway track longitudinal irregularity using vehicle response with information compression and Bayesian deep learning[J]. Computer-Aided Civil and Infrastructure Engineering, 2022, 37 (10): 1260-1276.
- [2] PIRES A C, VIANA M C A, SCARAMUSSA L M, et al. Measuring vertical track irregularities from instrumented heavy haul railway vehicle data using machine learning [J]. Engineering Applications of Artificial Intelligence, 2024, 127: 107191.
- [3] CHEN M, ZHU S Y, ZHAI W M, et al. Inversion and identification of vertical track irregularities considering the differential subgrade settlement based on fully convolutional encoder-decoder network[J]. Construction and Building Materials, 2023, 367: 130057.
- [4] KALMAN R E. A new approach to linear filtering and prediction problems[J]. Journal of Basic Engineering, 1960, 82(1): 35-45.
- [5] MUÑOZ S, ROS J, URDA P, et al. Estimation of lateral track irregularity through Kalman filtering techniques[J]. IEEE Access, 2021, 9: 60010-60025.
- [6] 李振乾, 池茂儒, 杨晨, 等. 基于铁道车辆振动加速度的

- 轴承载荷反演研究[J]. 铁道科学与工程学报, 2023, 20(6): 1983-1993.
- LI Z Q, CHI M R, YANG C, et al. On inverse identification method of bearing load based on railway vehicle acceleration[J]. Journal of Railway Science and Engineering, 2023, 20(6): 1983-1993.
- [7] 唐嘉, 池茂儒, 杨晨, 等. 高速列车轴箱轴承载荷反演模型及关键参数优化匹配[J]. 振动与冲击, 2024, 43(4): 52-60.
- TANG J, CHI M R, YANG C, et al. A load inversion model of the axle box bearing of a high-speed train and optimal match of key parameters[J]. Journal of Vibration and Shock, 2024, 43(4): 52-60.
- [8] GUO X Y, LI C K, LUO Z, et al. Identification of track irregularities with the multi-sensor acceleration measurements of vehicle dynamic responses[J]. Vehicle System Dynamics, 2024, 62(4): 906-931.
- [9] STRANO S, TERZO M, TORDELA C. Output-only estimation of lateral wheel-rail contact forces and track irregularities[J]. Vehicle System Dynamics, 2024, 62(10): 2481-2509.
- [10] XIAO X, SUN Z, SHEN W A. A Kalman filter algorithm for identifying track irregularities of railway bridges using vehicle dynamic responses[J]. Mechanical Systems and Signal Processing, 2020, 138: 106582.
- [11] 柯颢. 基于自适应卡尔曼滤波的铁道车辆轨道谱反演及应用研究[D]. 成都: 西南交通大学, 2021.
- KE B. Research on inversion and application of railway vehicle track spectrum based on adaptive Kalman filter [D]. Chengdu: Southwest Jiaotong University, 2021.
- [12] 张宇轩, 李奇, 吴阅, 等. 车载振动观测方案对轨道不平顺识别效果影响研究[J]. 铁道科学与工程学报, 2023, 20(8): 2835-2846.
- ZHANG Y X, LI Q, WU Y, et al. Investigation on the influence of observation scheme of vehicle vibration on track irregularity estimation[J]. Journal of Railway Science and Engineering, 2023, 20(8): 2835-2846.
- [13] 金欢欢. AKF算法及其在轨道交通信号安全检测中的应用[D]. 南京: 南京邮电大学, 2022.
- JIN H H. AKF algorithm and its application in rail transit signal safety detection[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2022.
- [14] 刘怡辰. 基于车辆振动响应的轨道不平顺反演研究[D]. 南昌: 华东交通大学, 2025.
- LIU Y C. Research on track irregularity inversion based on vehicle vibration response[D]. Nanchang: East China Jiaotong University, 2025.
- [15] 魏伟, 秦永元, 张晓冬, 等. 对Sage-Husa算法的改进[J]. 中国惯性技术学报, 2012, 20(6): 678-686.
- WEI W, QIN Y Y, ZHANG X D, et al. Amelioration of the sage-husa algorithm[J]. Journal of Chinese Inertial Technology, 2012, 20(6): 678-686.



第一作者:周生通(1984—),男,副教授,博士,硕士生导师,研究方向为轨道车辆系统动力学与可靠性。E-mail:zhoust@ecjtu.edu.cn。



通信作者:肖乾(1977—),男,二级教授,博士,博士生导师,江西省“井冈学者”特聘教授,研究方向为轨道交通车辆智能运维。E-mail:jxralph@foxmail.com。

(责任编辑:熊玲玲)