doi:10.6041/j.issn.1000-1298.2025.02.009

基于数字孪生的温室作业底盘行驶状态在线监测方法

王明辉[1,2]　徐　健[1]　周政东[1]　王玉龙[1]　崔永杰[1,3]

(1. 西北农林科技大学机械与电子工程学院, 陕西杨凌 712100;
2. 陕西省农业信息感知与智能服务重点实验室, 陕西杨凌 712100;
3. 农业农村部农业物联网重点实验室, 陕西杨凌 712100)

摘要: 数字孪生技术通过对物理实体全生命周期的数字化实现其状态的监测和控制,为实现机器人的远程控制和连续式作业提供了解决思路。作业底盘行驶过程的高精度控制是保证机器人作业质量的关键,本文针对温室环境变化和底盘损耗导致行驶状态预测模型误差大,以及动态数据在线采集困难等问题,提出一种基于数字孪生的温室作业底盘行驶状态在线监测方法。首先,开发了面向底盘行驶状态的温室作业底盘数字孪生系统,在线感知行驶过程中的动态数据并实时仿真底盘行驶状态变化过程;然后,结合底盘行驶状态时变偏差量化模型和考虑行驶过程中的各种不确定因素,构建了温室作业底盘行驶状态在线预测模型;最后,搭建底盘行驶状态在线监测试验环境,并进行在线监测试验和行驶效果验证试验。结果表明:本文在线预测方法对应数据集 M_1、M_2、M_3、M_4 的横向偏移预测精度分别为 96.32%、95.96%、95.69% 和 96.11%,纵向偏移预测精度分别为 96.58%、96.36%、96.51% 和 96.13%,对比基于 BP + SVR 方法的横向偏移预测精度分别提升 3.61%、3.26%、3.92% 和 3.98%,纵向偏移预测精度分别提升 2.96%、2.78%、3.27% 和 3.06%,证明了本文提出的在线预测方法能够有效修正地面波动和底盘损耗带来的偏差影响;实际底盘行驶横向偏移和纵向偏移平均值相较于基于固定行驶参数的行驶方法分别降低 48.13% 和 49.49%,本文方法能够基于底盘实时行驶状态进行动态调整。本文提出的基于数字孪生的温室作业底盘行驶状态在线监测方法具有强实时性和高精度的特点,可为设施农业机器人的连续式作业技术提供依据和参考。

关键词: 设施农业机器人; 轮式底盘; 数字孪生; 行驶状态; 时变模型; 在线监测

中图分类号: S24; TP23　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)02-0092-13　　**OSID**:

Online Prediction Method for Greenhouse Operation Chassis Driving Status by Digital Twins-driven

WANG Minghui[1,2]　XU Jian[1]　ZHOU Zhengdong[1]　WANG Yulong[1]　CUI Yongjie[1,3]

(1. *College of Mechanical and Electronic Engineering*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*
2. *Shaanxi Key Laboratory of Agricultural Information Perception and Intelligent Service*, *Yangling*, *Shaanxi* 712100, *China*
3. *Key Laboratory of Agricultural Internet of Things*, *Ministry of Agriculture and Rural Affairs*, *Yangling*, *Shaanxi* 712100, *China*)

Abstract: Digital twin technology digitizes the entire lifecycle of physical entities to achieve monitoring and control of their states, providing a solution for remote control and continuous operation of robots. The high-precision control of the operation chassis during the driving process is the key to ensuring the quality of robot operation. Aiming to address the issues of large error in the driving state prediction model due to changes in greenhouse environment and chassis wear, as well as the difficulty of online dynamic data collection, a digital twin based online monitoring method for the driving state of the greenhouse operation chassis was proposed. Firstly, a digital twin system of the greenhouse operation chassis geared towards the driving state was developed. It dynamically perceived the dynamic data in the driving process online and simulated the change process of the chassis driving state in real time. Then an online prediction model of the driving state of the greenhouse operation chassis was constructed by combining the temporal deviation quantification model of the chassis driving state and considering various uncertain factors during

收稿日期: 2024-10-02　修回日期: 2024-11-10

基金项目: 国家重点研发计划项目(2019YFD1002401)和国家自然科学基金项目(31971805)

作者简介: 王明辉(1996—),男,博士生,主要从事设施果蔬生产自动化装备研究,E-mail: wangminghui@nwafu.edu.cn

通信作者: 崔永杰(1971—),男,教授,博士生导师,主要从事果蔬生产自动化研究,E-mail: agriculturalrobot@nwafu.edu.cn

the driving process. Finally, an experimental environment for online monitoring of the chassis driving state was set up, and online monitoring experiments and driving effect verification tests were carried out. The results showed that the online prediction method proposed corresponded to lateral offset prediction accuracies of 96.32%, 95.96%, 95.69% and 96.11% for datasets M_1, M_2, M_3, M_4, respectively. The longitudinal offset prediction accuracies were 96.58%, 96.36%, 96.51% and 96.13% for datasets M_1, M_2, M_3, M_4, respectively. Compared with the BP + SVR method, the prediction accuracy of lateral displacement was increased by 3.61%, 3.26%, 3.92%, and 3.98%, respectively, and the prediction accuracy of longitudinal displacement was increased by 2.96%, 2.78%, 3.27%, and 3.06%, respectively. This proved that the online prediction method proposed can effectively correct for the bias effects caused by ground fluctuations and chassis wear and tear. The average values of the actual lateral and longitudinal deviations of the chassis during driving were reduced by 48.13% and 49.49%, respectively compared with the chassis driving method based on fixed driving parameters. This method can dynamically adjust based on the real-time driving status of the chassis. The online monitoring method for greenhouse operation chassis driving status based on digital twins had the characteristics of strong real-time and high accuracy, which can provide a basis and reference for the continuous operation method and technology of robots in facility agriculture.

Key words: facility agriculture robot; wheeled chassis; digital twin; driving status; time-varying model; online prediction

0　引言

设施农业因其具有不受自然环境和传统条件束缚的突出优势[1],已成为我国现代农业发展的重要方向。温室农作物高标准栽培模式的应用极大促进了智能化农机装备的发展,特别是在移动型巡检、喷药和收获等机器人领域[2]。底盘作为移动型机器人的关键组成部分,其高精度控制是保证机器人作业效果的关键[3-4]。为降低底盘行驶偏差并提高机器人的作业质量,需监测底盘的行驶状态并确定最佳调控策略。

近年来,底盘行驶状态监测的研究主要集中在传感器开发[5]、底盘状态预测[6-7]和集成控制[8-10]等方面,对实时在线监测控制的研究较少。以上研究主要基于历史数据开发底盘行驶过程中的状态预测模型和控制方法,而温室环境变化和底盘损耗等实时因素会对底盘行驶状态产生动态影响,因此仅使用离线数据构建预测模型存在一定的误差。

为解决基于历史数据构建的离线模型存在精度差的问题,部分学者采用在线学习的方法对底盘行驶状态预测模型进行了研究[11-13]。在线学习可以利用底盘行驶过程中的实时数据来修正模型,提高预测模型的准确性[14]。但目前广泛使用的在线学习方法在融合新的数据后需要重新训练模型,难以实时快速预测底盘行驶状态,因此,亟需一种底盘状态实时在线监测技术。

近年来,数字孪生技术已经在工业制造、航空航天、农业管理等领域成功应用[15-18],实现了对物理实体的在线监测、仿真及决策,具有实时性与保真性[19-20]。在农业管理领域,可以实时监测作物生长状态来优化作物种植过程,同时进行农业装备全生命周期的管理[21-22]。

针对上述问题,在考虑实时性、快速性和低功耗的前提下,本文基于数字孪生技术提出一种温室作业底盘行驶状态在线监测方法。

1　温室作业底盘行驶状态在线监测方法

针对基于历史数据训练的温室作业底盘行驶状态预测模型存在误差,且在线学习难以实时预测行驶状态偏差值的问题,提出一种基于数字孪生的温室作业底盘行驶状态在线监测方法,如图 1 所示。使用底盘行驶状态时变偏差量化方法减少因温室环境变化和底盘损耗产生的误差,实时预测行驶状态偏差;同时基于温室作业底盘数字孪生系统,在线采集数据并实时仿真底盘行驶的过程,实现温室作业底盘实际行驶过程中行驶状态偏差的在线监测。以地面倾角、电气性能(电机功率)、机械性能(电机转速)和行驶参数信号为输入,经过温室作业底盘行驶状态在线监测,输出底盘行驶状态的实时偏差和调整策略。

基于数字孪生的温室作业底盘行驶状态在线预测流程如下:首先,基于数字孪生五维模型框架开发面向底盘行驶状态的温室作业底盘数字孪生系统,用于实时在线仿真;其次,基于数字孪生系统采集温室作业底盘行驶过程中的地面倾角信号、电气性能信号、机械性能信号和行驶参数并存入数据库中;然后,将行驶过程中采集到的历史孪生数据进行处理,建立底盘行驶状态的时变偏差量化模型和底盘行驶状态在线预测模型;最后,实时采集行驶过程中数

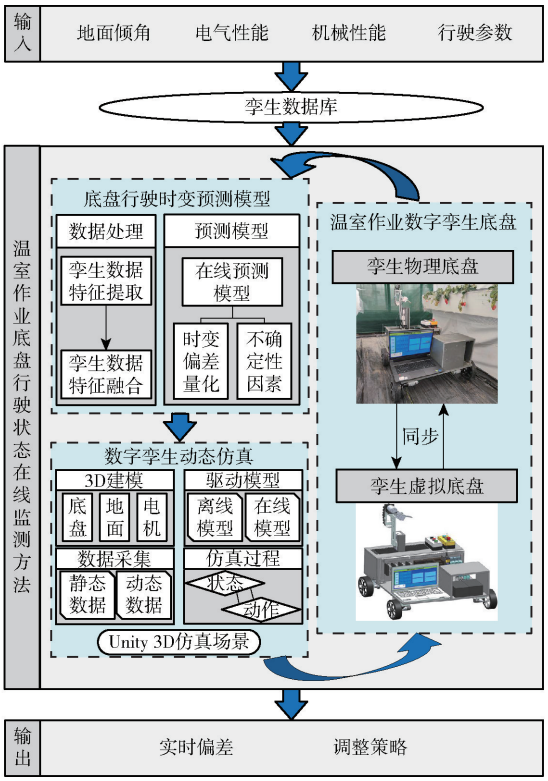

图 1 温室作业底盘行驶状态在线预测流程图

Fig. 1 Flowchart for online prediction of chassis driving status in greenhouse operations

据,实时仿真底盘的行驶过程和状态变化。结合上述提出的在线监测方法和在线预测流程,本文构建的温室作业底盘数字孪生系统主要包括物理温室作业底盘、孪生数据库和虚拟温室作业底盘 3 部分,三者互联互通。物理温室作业底盘执行行驶策略,将采集到的数据上传至孪生数据库;虚拟温室作业底盘通过处理分析孪生数据库中的数据建立预测模型和进行动态仿真,驱动物理温室作业底盘的行为动作。

2 面向底盘行驶状态的温室作业底盘数字孪生系统构建

2.1 温室作业底盘的数字孪生五维模型框架

温室作业底盘的数字孪生系统是在信息技术、传感器技术的驱动下,综合集成传感技术、物联网技术、建模仿真技术和可视化技术,实现虚拟底盘对物理底盘行驶状态的实时映射和预测。通过建立物理底盘与虚拟底盘之间的网络层通讯,实现数字孪生系统的数据集成与融合;在底盘孪生数据的驱动下,通过底盘运动映射、底盘状态监测、行驶参数优化与控制和行驶状态预测等,实现温室作业底盘的三维可视化及实时交互,从而对底盘行驶过程进行全面管控。

本文借鉴数字孪生五维模型[19]构建了温室作业底盘的数字孪生系统结构模型,如图 2 所示。该模型主要包括物理层、虚拟层、数据层、服务层和应用层。

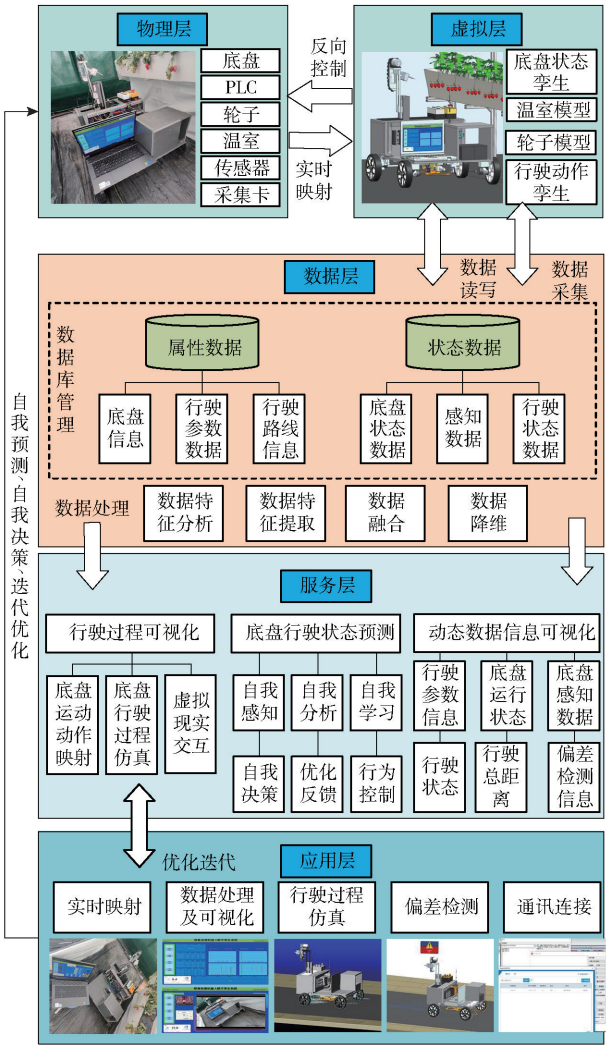

图 2 温室作业底盘数字孪生系统结构模型

Fig. 2 Structural model of greenhouse operation chassis digital twin system

(1)物理层:数字孪生系统中的物理设备主要包括作业底盘、外部传感器、数据采集卡等设备,通过在底盘上布置传感器并进行以太网连接,数字孪生系统将物理底盘的行为实时映射到虚拟底盘上。

(2)虚拟层:数字孪生系统中的虚拟模型是基于实际底盘建模的三维渲染模型,根据行驶阶段的不同而发生改变,为了实现物理底盘到虚拟底盘真实有效的镜像映射,需要融合虚拟模型的结构和功能,并根据底盘的行为规则定义虚拟模型的控制准则。通过开放平台通信统一框架协议(OLE for process control unified architecture,OPCUA)建立以虚控实的机制,实现虚拟底盘反向控制真实底盘的行为。

(3)数据层:孪生数据是数字孪生系统运行的基础,主要包括采集行驶现场的传感器数据,以及底盘内部的运行状态数据。将采集的信号在 Matlab

中完成特征提取与降维处理后传输至服务层。

(4)服务层:通过融合物理底盘、虚拟底盘和孪生数据,在可视化软件中搭建温室作业底盘数字孪生系统平台,面向底盘行驶过程,达到行驶过程可视化、行驶状态透明化、底盘管理智能化。例如,可以对底盘行驶状态进行预测,通过构建相关的神经网络模型,在经过网络参数优化和模型训练后用于预测底盘行驶的纵向偏移、横向偏移等,从而分析、判断底盘的行驶状态,根据该预测信息实现对底盘的高效管控。

(5)应用层:数字孪生系统的应用层作为物理底盘、虚拟底盘、服务平台、孪生数据以及两两交互连接的集成,是有效驱动整个系统运转的关键。针对底盘行驶过程调取孪生数据,如底盘内部数据、传感器数据等,并将其在可视化界面中进行动态实时刷新,同时通过行驶过程仿真和行驶状态监测,协助用户更好地了解和分析当前行驶情况。

2.2　数字孪生系统开发及配置

采用 Solidworks 2019、3Ds Max 2019 和 Unity 3D 开发温室作业底盘数字孪生系统。首先采用 Solidworks 2019 对温室作业底盘进行三维建模并导出 STL 格式文件;然后将该文件导入 3Ds Max 2019 中进行渲染和减面处理;最后使用 Unity 3D 设计系统界面和程序的交互,并将渲染后的 FBX 文件导出至 Unity 3D。采用 TCP/IP 通信协议将物理温室作业底盘的数据传送至数字孪生系统。系统工作过程中,传感器实时采集温室作业底盘行驶状态数据并上传至数字孪生系统;虚拟底盘根据采集的数据进行运动同时处理数据并预测状态变化情况;基于行为模型,由孪生体生成虚拟动作行为,并将模拟信号传入物理世界,进而控制温室作业底盘行驶。

开发的数字孪生系统仿真过程如图 3 所示。每 0.05 s 获取底盘行驶的一条数据并存入数据包中,每隔 0.5 s 向孪生数据库中发送一个数据包。数字孪生系统每 0.5 s 解析一个数据包,软件运行频率设置为 12 f/s。

3　数字孪生驱动的温室作业底盘行驶状态在线预测模型

3.1　数字孪生系统数据处理

采集底盘行驶过程中的多源数据并输入数字孪生系统中,将地面倾角信号数据矩阵 $\boldsymbol{R}_1$、电气性能信号数据矩阵 $\boldsymbol{R}_2$(包括 4 个电机功率信号数据)以及机械性能信号数据矩阵 $\boldsymbol{R}_3$(包括 4 个电机转速信号数据)输入数字孪生特征提取模块,然后将提取后的特征与行驶参数数据矩阵 $\boldsymbol{R}_4$(包括行驶速度和行驶距离信号数据)融合后进行特征降维处理。底盘行驶状态数字孪生数据处理流程如图 4 所示。

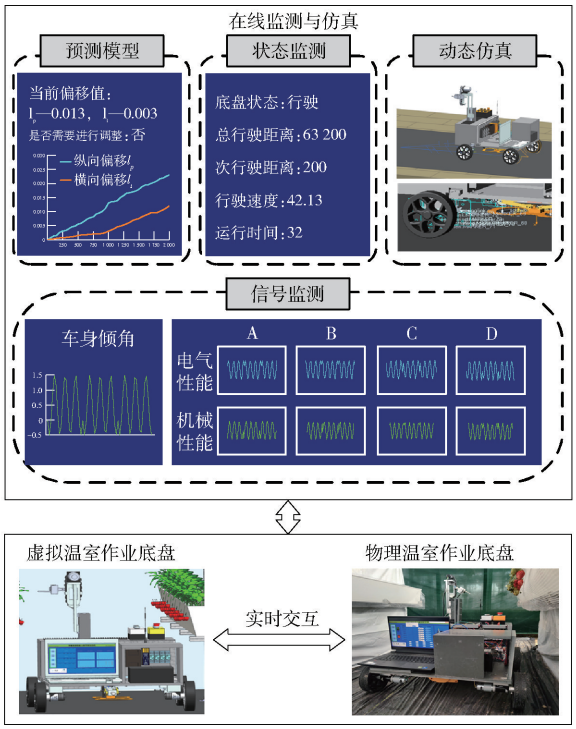

图 3　温室作业底盘数字孪生系统仿真过程

Fig. 3　Simulation process of digital twin system for greenhouse operation chassis

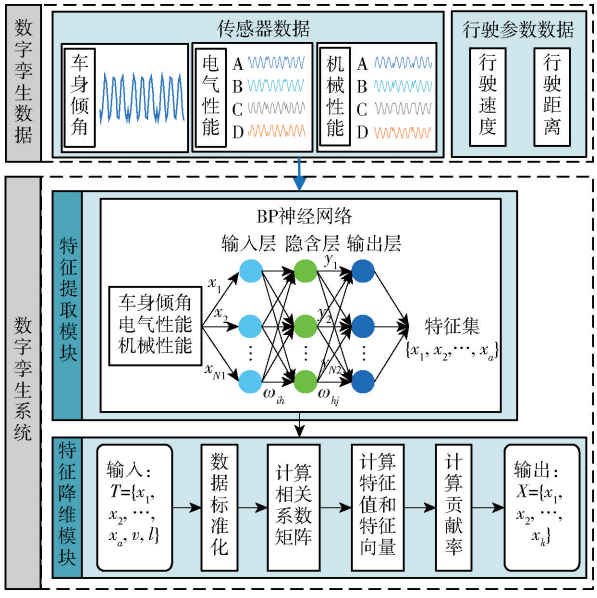

图 4　底盘行驶状态数字孪生系统数据处理流程

Fig. 4　Data processing flowchart of chassis driving status digital twin system

3.1.1　孪生数据特征提取

数字孪生特征提取模块作业步骤如下:

(1)采用直接测量法,分别对底盘行驶过程中的地面倾角、电气性能(电机 1、2、3、4 功率)和机械性能(电机 1、2、3、4 转速)进行实时信号采集。

(2)计算采集的地面倾角、电气性能和机械性

能数据平均值与标准差,共获得 9 个标准差数据。

(3)通过每个采样点数据和本组数据平均值差值与标准差的对应关系进行特征提取。

(4)对比获取的 9 组特征,以保留数据量最少的一组作为基准,从其他 8 组数据中随机提取出与基准组相同的数据量。

(5)整理上述数据,完成特征提取

采用前馈神经网络(Back propagation, BP)对信号数据矩阵 $\boldsymbol{R}_1$、$\boldsymbol{R}_2$、$\boldsymbol{R}_3$自动进行特征提取,传递函数采用 Logsig 算法,学习函数采用 Levenberg - Marquardt 优化算法(trainlm 函数)[23]。由于数据样本较少,故采用 3 层 BP 神经网络,包括输入层、隐含层和输出层。输出层为车身倾角、电气性能和机械性能信号提取的特征,包括具有相同数据量的剔除异常值且在置信区间内的信号数据(地面倾角,电机 1、2、3、4 功率,电机 1、2、3、4 转速)。BP 模型可表示为

$$y = \mathrm{net}(\boldsymbol{R}_1, \boldsymbol{R}_2, \boldsymbol{R}_3) \tag{1}$$

隐含层神经元数 h 根据经验进行初步选取,即

$$h = \sqrt{p+q} + e \tag{2}$$

式中 p——输入层节点数目

q——输出层节点数目

e——1 ~ 10 之间的调节常数

经过试验选取隐含层节点数为 21。

3.1.2 孪生数据特征降维

经过数字孪生系统数据特征提取后,车身倾角、电气性能和机械性能信号提取的特征为 $T = \{x_1, x_2, \cdots, x_a\}$。将 T 与行走参数数据矩阵 $\boldsymbol{R}_4$输入数字孪生系统特征降维模块,该模块输入 $\boldsymbol{X}_s$为

$$\boldsymbol{X}_s = \begin{bmatrix} x_1^{(1)} & x_1^{(2)} & \cdots & x_1^{(u)} \\ x_2^{(1)} & x_2^{(2)} & \cdots & x_2^{(u)} \\ \vdots & \vdots & & \vdots \\ x_a^{(1)} & x_a^{(2)} & \cdots & x_a^{(u)} \\ v^{(1)} & v^{(2)} & \cdots & v^{(u)} \\ l^{(1)} & l^{(2)} & \cdots & l^{(u)} \end{bmatrix} \tag{3}$$

式中 v——行驶速度 l——行驶距离

u——数据条数

采用主成分分析法(Principal component analysis, PCA)对温室作业底盘行驶状态的孪生数据进行降维处理,通过正交变换将 n 维数据映射到 $m(m<n, n=a+2)$维上[24]。其中输出特征的集合 $X_e = \{x_1, x_2, \cdots, x_m\}$,假设 X_e对应的特征值分别为 $\{\lambda_1, \lambda_2, \cdots, \lambda_m\}$,则第 $i(1 \leqslant i \leqslant m)$个特征的贡献率 J_i为

$$J_i = \frac{\lambda_i}{\sum_{q=1}^{m} \lambda_q} \tag{4}$$

将原 n 维特征降至 k 维,计算前 k 个特征的累计贡献率,若累计贡献率大于 90%,则通过 PCA 法所提取的特征值能够反映高维特征信息。

3.2 温室作业底盘行驶状态在线预测模型

由于温室实时环境变化和底盘损耗会导致基于历史数据的行驶状态离线预测模型误差大,据此本文提出了温室作业底盘行驶状态在线预测方法。首先,构建底盘行驶状态时变偏差模型来量化环境变化和底盘损耗产生的偏差;其次,建立历史底盘行驶状态预测模型来预测底盘行驶偏差;然后,引入高斯白噪声来模拟底盘行驶状态时变偏差中的不确定性;最后,综合考虑基于历史数据训练的底盘行驶状态预测模型、底盘行驶状态时变偏差量化模型和考虑底盘行驶过程中不确定性的高斯白噪声,建立底盘行驶状态的在线预测模型。

3.2.1 底盘行驶状态时变偏差量化

地面波动不均以及底盘输出功率和轮胎损耗会对行驶状态造成影响,故基于历史数据的离线预测模型会有较大误差。因此,本文引入底盘行驶状态时变偏差模型,即基于实时采集的数据构建行驶状态预测模型来量化地面波动以及底盘输出功率和轮胎损耗产生的偏差。

在建立底盘行驶状态数字孪生系统后,获取底盘多次运行的行驶状态数据,通过数据拟合得出地面波动以及底盘输出功率和轮胎损耗对行驶状态的影响。拟合的时变偏差量化模型为 $g(L, v, l)$,变量为试验开始时建立离线预测模型后底盘连续行驶距离 L、行驶速度 v 和行驶距离 l,响应值为底盘行驶状态初始偏差与第一次试验后偏差的差值,包括纵向偏差 $\Delta l_p'$和横向偏差 $\Delta l_t'$。由于地面波动、底盘输出功率和轮胎损耗与底盘行驶状态偏差之间具有强非线性,故采用径向基函数(Radial basis function, RBF)方法来拟合时变模型。同时与响应曲面(Response surface methodology, RSM)方法[25]和多元线性回归(Multiple linear regression, MLR)[26]方法拟合的模型进行对比。

RBF 模型能够逼近任意非线性函数,学习收敛的速度较快,泛化能力强。基于 Matlab 的 Neural Network Toolbox 工具箱构建和训练 RBF 模型,通过 newrb 函数创建 RBF 对象,并通过 train 和 sim 函数进行训练和预测,按比例 4∶1将试验所得的数据随机分为训练集和测试集。其中模型的输入为连续行驶距离 L、行驶速度 v 和行驶距离 l,输出为偏差,包

括纵向偏差 $\Delta l_p'$和横向偏差 $\Delta l_t'$。

3.2.2　底盘行驶状态在线预测模型

底盘行驶数据经数字孪生系统处理后，车身倾角、电气性能和机械性能信号的特征向量为 $\boldsymbol{X}=(x_1, x_2, \cdots, x_k)$，构成新的数据集 $Q=\{(\boldsymbol{X}_i, y_i), i=1,2,\cdots,u\}$。其中，$\boldsymbol{X}_i$和 y_i分别为输入值和输出值。基于支持向量机回归（Support vector machine regression，SVR）算法[27]建立历史底盘行驶状态预测模型为

$$f(\boldsymbol{X})=\sum_{i=1}^{m}(d_i-d_i^*)K(\boldsymbol{X}_i,\boldsymbol{X})+f \tag{5}$$

式中　d_i、d_i^*——拉格朗日乘子

$K(\boldsymbol{X}_i,\boldsymbol{X})$——核函数　　f——偏置量

基于 Matlab 提供的 SVR 函数库构建 SVR 模型，由于 RBF 核函数计算的复杂度不随参数变化而变化，故选取其作为核函数；惩罚因子 c 和影响因子 g 为主要影响参数，经网格验证方法进行多次经验计算获取最佳参数值。其中模型输入为多源数据（$\boldsymbol{R}_1$、$\boldsymbol{R}_2$、$\boldsymbol{R}_3$和 $\boldsymbol{R}_4$）经过特征提取和特征降维后的数据集，输出为底盘行驶状态偏差，包括纵向偏移和横向偏移。

在底盘行驶过程中，地面波动以及底盘输出功率和轮胎损耗等不确定因素都会对底盘的行驶状态产生影响，使得底盘行驶状态随机地在一定范围内波动。采用高斯白噪声来模拟底盘行驶状态时变偏差中的不确定性。高斯白噪声幅度服从高斯分布，记为 $\varepsilon=N(\mu, \sigma^2)$，其中，$\mu$ 为高斯白噪声分布的均值，σ^2为方差，且功率谱密度服从均匀分布[28]。

综合考虑基于历史数据训练的底盘行驶状态预测模型、底盘行驶状态时变偏差量化模型和考虑底盘行驶过程中不确定性的高斯白噪声，得到温室作业底盘行驶状态在线预测模型为

$$Y=f(\boldsymbol{X})+g(L,v,l)+\varepsilon \tag{6}$$

式中　$f(\boldsymbol{X})$——离线行驶状态预测模型

$g(L,v,l)$——基于 RBF 的行驶状态时变偏差模型

对于温室作业底盘行驶状态在线预测模型，选取平均百分比误差（Mean absolute percentage error，MAPE）、均方根误差（Root mean square error，RMSE）、最大绝对误差（Mean absolute error，MAE）和决定系数（R^2）来评估模型的准确性。

4　温室作业底盘行驶状态在线监测试验

4.1　材料与方法

4.1.1　试验材料

试验于 2024 年 3 月在西北农林科技大学南校区科研温室（北纬 34°17′、东经 108°04′）进行。在温室高架草莓栽培环境下，基于自研的轮式电动移动平台搭建底盘行驶状态在线监测试验环境，如图 5 所示。通过外加传感器与底盘的控制系统连接通信采集底盘行驶过程中的多源数据。

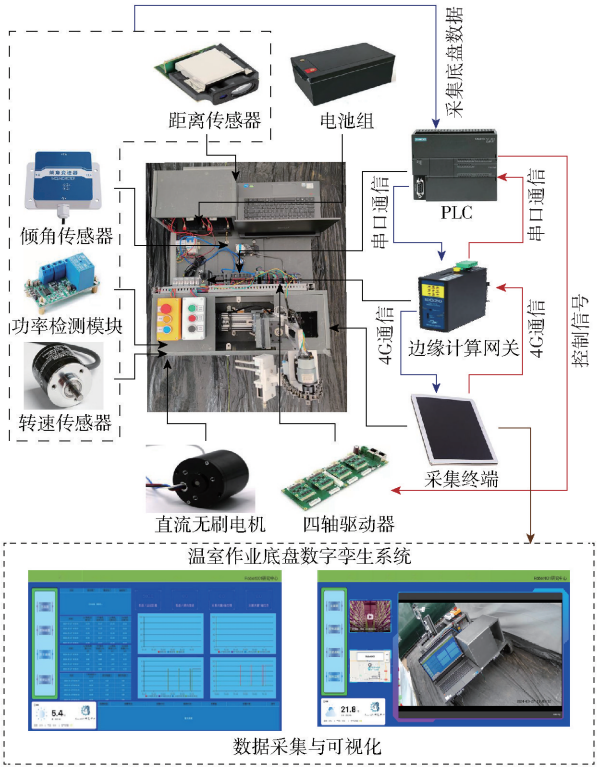

图 5　试验设备

Fig. 5　Test equipment

底盘尺寸为 800 mm × 700 mm × 400 mm，质量为 60 kg；行驶环境为铺设黑色地膜的地面。设计了三因素四水平正交试验，采用 16 组行驶参数进行作业底盘直线行驶试验，每组行驶参数试验 5 次，每行驶一次，测量底盘行驶的横向偏移和纵向偏移，试验参数如表 1 所示。同时，为了拟合功率损耗和轮胎磨损的底盘行驶状态时变偏差量化模型，本文在无磨损轮胎下分别使用常压电池、微欠压电池和严重欠压电池，在常压电池下分别使用无磨损轮胎、轻微磨损轮胎和严重磨损轮胎以相同条件进行底盘行驶试验，得到 5 个数据集。

表 1　底盘行驶试验参数

Tab. 1　Chassis driving test parameters

水平	行驶速度 v/(m·s^{-1})	行驶距离 l/mm	地面倾角 θ/(°)
1	0.35	500	0
2	0.40	1 000	1
3	0.45	1 500	2
4	0.50	2 000	3

在底盘行驶试验过程中，根据实际行驶轨迹分别测量横向偏移和纵向偏移，测量过程如图 6 所示。

在底盘重心位置安装示踪装置,实现底盘实际行驶轨迹可视化。底盘初始位置时示踪装置位于行驶路线起点 O_1,试验过程中实时显示行驶轨迹并获取底盘最终位置信息,比较实际终点 O_3 与理论终点 O_2 的偏差情况,即可得底盘行驶横向偏移和纵向偏移,如图 7 所示。

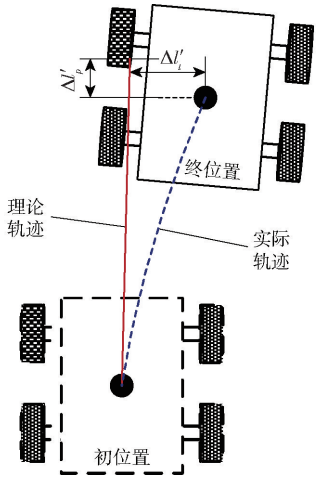

图 6 偏移测量原理图

Fig. 6 Principle of deviation measurement

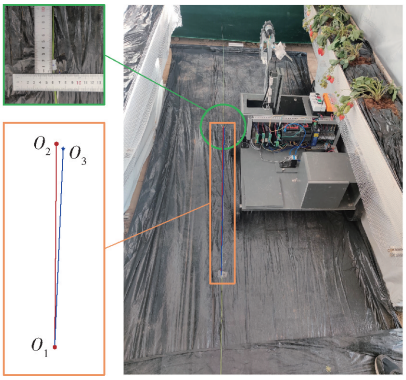

图 7 偏移测量结果

Fig. 7 Deviation measurement results

以无磨损轮胎和常压电池组合下获取的底盘行驶横向偏移和纵向偏移为例,16 组试验结果分布如图 8 所示。其中横向偏移最大变异系数为 33.53%,平均变异系数为 14.96%;纵向偏移最大变异系数为 26.34%,平均变异系数为 10.85%。表明试验获取的数据集中在平均值附近,证明了本试验设备具有较好的稳定性。

4.1.2 数据集描述

温室作业底盘数字孪生系统采集的总数据集为 $M=\{M_0, M_1, M_2, M_3, M_4\}$,其中,$M_0$、$M_1$、$M_2$、$M_3$、$M_4$ 分别为无磨损轮胎/常压电池、无磨损轮胎/微欠压电池、无磨损轮胎/严重欠压电池、常压电池/轻微磨损轮胎和常压电池/严重磨损轮胎在相同行驶条件下采集的数据。每个方式均包含 80 个数据文件,在每个数据文件中车身倾角、电气性能和机械性能

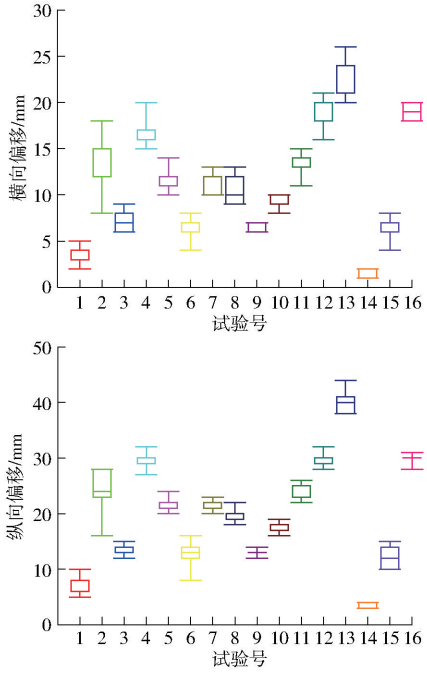

图 8 无磨损轮胎和常压电池组合下试验结果分布

Fig. 8 Distributions of test results under combination of non worn tires and atmospheric pressure batteries

的采集频率为 20 Hz,行驶参数、连续行驶距离和行驶状态偏差的采集频率为每段 1 条数据。

为了保证多源信号之间的同步性,需将相同时间段内的数据输入数字孪生系统。从每一条数据文件的中间时刻开始截取 5 s 内的数据,即车身倾角信号截取 100 个数据点,相同时间段内的电气性能信号和机械性能信号截取 100 个数据点。车身倾角数据样本维度为 80×100×1,将电气性能和机械性能堆叠为 8 通道样本,其数据维度为 80×100×8。

4.2 结果与分析

4.2.1 预测结果及分析

(1)特征提取

将 M_0 数据集的车身倾角、电气性能和机械性能信号数据样本输入 BP 神经网络中。训练次数为 500,训练误差为 0.001,输入层节点为 $\{i_1, i_2, \cdots, i_{100}\}$,包括相同时间段内车身倾角信号、电气性能信号和机械性能信号,截取 100 个数据点,隐含层神经元个数 21,输出层输出 63 个特征,为 $\{x_1, x_2, \cdots, x_{63}\}$,每个特征均为包含地面倾角,电机 1、2、3、4 功率,电机 1、2、3、4 转速在内的一组数据。

(2)特征降维

将车身倾角、电气性能和机械性能信号提取的特征与行驶参数融合,组成特征集 $\{x_1, x_2, \cdots, x_{63}, v, l\}$。将特征集输入数字孪生数据降维模块,使用主成分分析法降维,最后提取的特征数为 15,累计贡献率为 92.596 2%,可反映原特征集的信息。

(3)预测模型

为了拟合出地面波动、底盘输出功率和轮胎损耗对底盘行驶状态偏差的影响，计算 M_1、M_2、M_3、M_4 与 M_0 在相同试验因素下的底盘行驶状态偏差，变量为 L、v、l、θ，得到底盘行驶状态偏差值数据集 M_5，部分数据如表 2 所示。

表 2　底盘行驶状态偏差数据集 M_5 的部分数据

Tab. 2　Partial data of chassis driving state deviation difference dataset M_5

试验序号	L/mm	v/(m·s^{-1})	l/mm	θ/(°)	$\Delta l_p'$/mm	$\Delta l_t'$/mm
1	500	0.4	500	2	0	1
2	2 500	0.4	2 000	3	5	8
⋮	⋮	⋮	⋮	⋮	⋮	⋮
80	100 000	0.5	2 000	0	3	1
81	500	0.4	500	2	4	5
82	2 500	0.4	2 000	3	1	5
⋮	⋮	⋮	⋮	⋮	⋮	⋮
160	100 000	0.5	2 000	0	13	19
161	500	0.4	500	2	4	6
162	2 500	0.4	2 000	3	2	2
⋮	⋮	⋮	⋮	⋮	⋮	⋮
240	100 000	0.5	2 000	0	12	13
241	500	0.4	500	2	8	15
242	2 500	0.4	2 000	3	21	22
⋮	⋮	⋮	⋮	⋮	⋮	⋮
320	100 000	0.5	2 000	0	25	41

采用 RSM、MLR、RBF 模型对数据集 M_5 进行拟合，选取 256 组数据作为训练集(占总数据集的 80%)，剩下 64 组数据作为测试集(占总数据集的 20%)。3 种模型测试结果如图 9 所示，相较于 RSM 模型和 MLR 模型，RBF 模型的 RMSE、MAE 最小，R^2 最大，即 RBF 模型具有最高的模型精度，故将 RBF 函数作为考虑地面波动、底盘输出功率和轮胎损耗的时变量化模型。

数据集 M_0 在经过数字孪生特征降维模块后，输入 SVR 预测模型特征集为 $\{t_1, t_2, \cdots, t_{15}\}$，惩罚因子 c 和影响因子 g 分别为 128 和 0.01。本文在预测结果中加入高斯白噪声，模拟底盘行驶过程中的随机性和不确定性。结合本文试验数据，底盘行驶状态偏移的测量误差最小为 0.5 mm，为了保证底盘行驶状态预测的最小预测范围并留有一定的余量，设定产生噪声的最小值为 0.4 mm。为了保证底盘行驶状态预测结果在 95% 的置信区间内，即结果误差不超过 10%，选取高斯白噪声方差为 0.4 mm，产生噪声的最大误差为 8.3%，能够在保证置信度的同时尽量提高预测精度。

通过以上模型的建立，数据集 M_0 使用本文方法预测结果如图 10 所示。由图 10a 可得，横向偏移实测值与预测值拟合直线斜率和截距分别为 0.954 2、1.005 8，纵向偏移实测值与预测值拟合直线的斜率

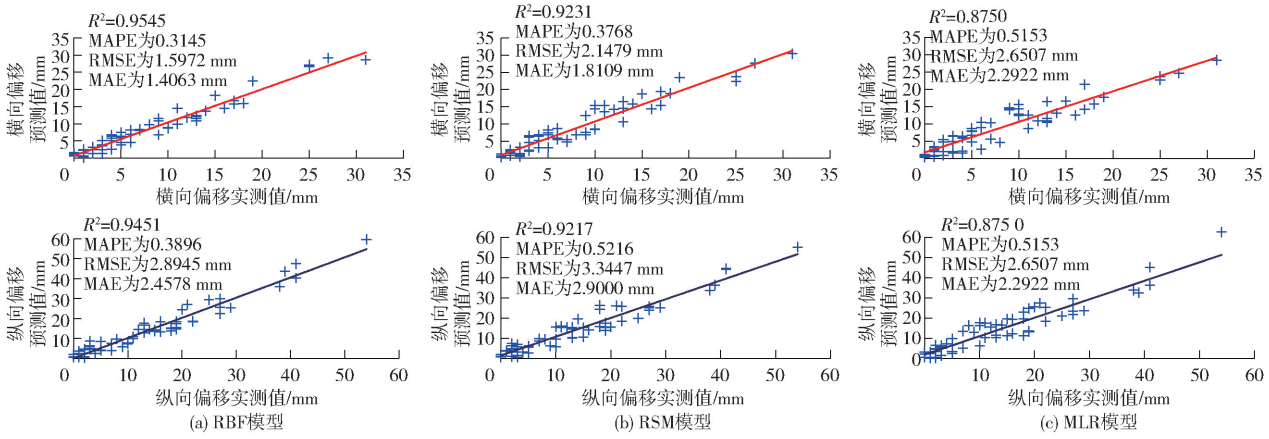

图 9　RBF、RSM、MLR 模型测试结果

Fig. 9　Test results of RBF, RSM and MLR models

和截距分别为 0.973 6、0.809 4，具有较好的预测效果；由图 10b 可得，测试集的预测结果均在上下界限中。可见，本文方法能够准确预测底盘行驶状态偏移值，为底盘行驶状态的精准调控提供了定量依据。

4.2.2　预测结果对比分析

为验证本文数据处理方法的优越性，基于数据集 M_0，分别采用 BP + SVR 算法、SVR 算法和 BP 神经网络 3 种方法建立预测模型，并分别使用数据集 M_1、M_2、M_3 和 M_4 中 20% 的数据来测试预测结果，结果如表 3 和图 11 所示。

由图 11 可得，BP + SVR 方法构建模型的实测值与预测值拟合效果与标准结果误差最小，表明本文数据处理方法具有较好的优越性。同时 BP + SVR 方法可以充分利用底盘行驶过程中多源数据的信息特点，因此在全生命周期预测中具有较稳定的效果。由表 3 可得，相较于 SVR 预测模型和 BP 神经网络预测模型，BP + SVR 预测模型预测结果 RMSE、MAE 最小，R^2 最大，体现了本文数据处理方

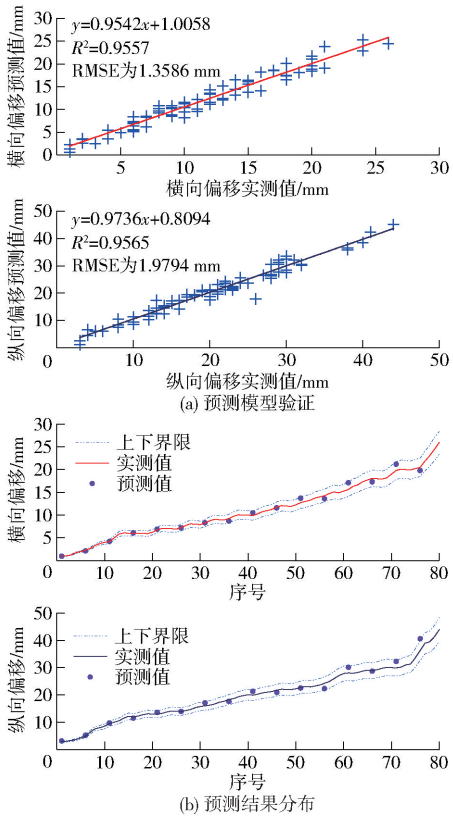

图 10 本文方法预测结果

Fig. 10 Prediction results of proposed method

表 3 BP + SVR、SVR、BP 预测评价指标

Tab. 3 BP + SVR, SVR and BP result evaluation indicators

测试集		模型	MAPE	RMSE/mm	MAE/mm	R^2
M_1	横向	BP + SVR	0.172 5	1.745 0	1.500 0	0.929 6
		SVR	0.330 7	2.724 0	2.575 0	0.813 0
		BP	0.217 9	2.075 8	1.887 5	0.894 2
	纵向	BP + SVR	0.186 9	2.963 6	2.843 8	0.938 0
		SVR	0.230 4	4.886 2	4.087 5	0.825 8
		BP	0.207 5	4.081 6	3.693 8	0.883 5
M_2	横向	BP + SVR	0.134 5	2.488 7	2.225 0	0.929 3
		SVR	0.251 1	3.804 7	3.606 3	0.837 5
		BP	0.190 3	3.215 3	2.993 8	0.887 1
	纵向	BP + SVR	0.147 4	3.953 3	3.775 0	0.937 5
		SVR	0.266 6	6.853 2	6.725 0	0.830 0
		BP	0.186 4	4.980 1	4.775 0	0.896 3
M_3	横向	BP + SVR	0.174 6	2.523 3	2.268 8	0.923 4
		SVR	0.308 1	4.133 2	3.837 5	0.809 7
		BP	0.223 2	3.034 1	2.743 8	0.892 8
	纵向	BP + SVR	0.150 0	3.739 7	3.562 5	0.934 5
		SVR	0.268 5	6.252 5	6.093 8	0.822 2
		BP	0.206 8	5.217 7	4.993 8	0.878 3
M_4	横向	BP + SVR	0.196 4	3.883 3	3.712 5	0.924 3
		SVR	0.330 8	5.676 3	5.550 0	0.834 6
		BP	0.269 5	4.765 0	4.600 0	0.878 3
	纵向	BP + SVR	0.139 4	6.040 9	5.718 8	0.932 8
		SVR	0.241 8	9.725 5	9.362 5	0.815 4
		BP	0.185 8	7.453 1	7.181 3	0.892 8

式的优越性。

为验证本文预测方法的预测效果,分别使用本文方法与 BP + SVR 算法建立预测模型,并分别使用数据集 M_1、M_2、M_3和 M_4中 20% 的数据来测试和对比预测结果,结果如图 12 所示。

由图 12 可知,针对数据集 M_1、M_2、M_3和 M_4,本文在线预测方法的横向偏移预测精度分别为 96.32%、95.96%、95.69% 和 96.11%,相较于 BP + SVR 算法的 92.96%、92.93%、92.34% 和 92.43%,分别提高 3.61%、3.26%、3.92% 和 3.98%;本文在线预测方法的纵向偏移预测精度分别为 96.58%、96.36%、96.51% 和 96.13%,相较于 BP + SVR 算法预测精度的 93.80%、93.75%、93.45% 和 93.28%,分别提高 2.96%、2.78%、3.27% 和 3.06%,表明本文在线方法中加入时变偏差量化模型能有效减小误差,使预测结果更接近实测值。分析可知,地面波动、底盘输出功率和轮胎损耗会导致底盘行驶状态

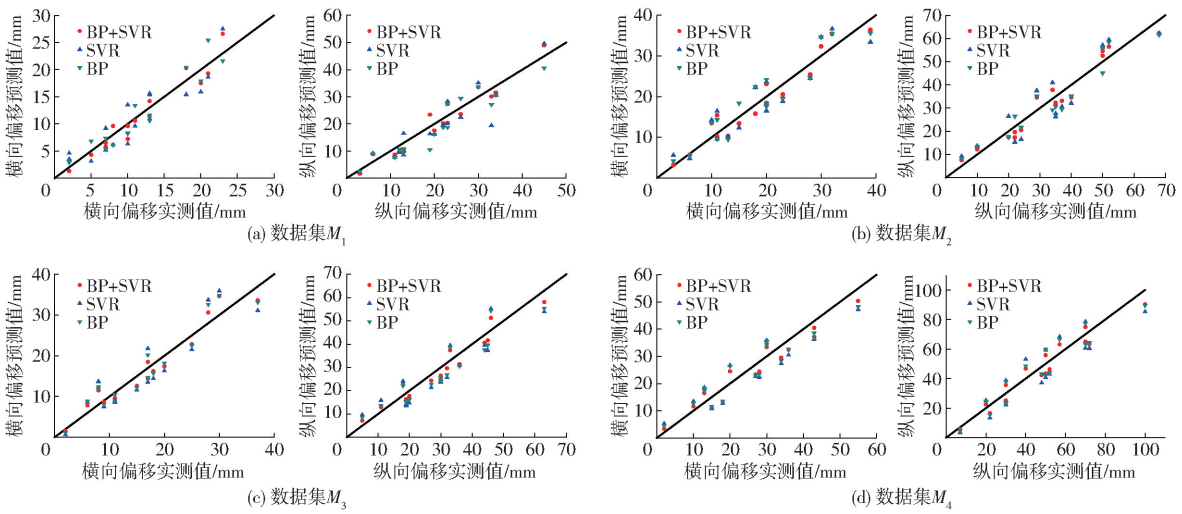

图 11 3 种数据处理方法结果对比

Fig. 11 Comparison results of three data processing methods

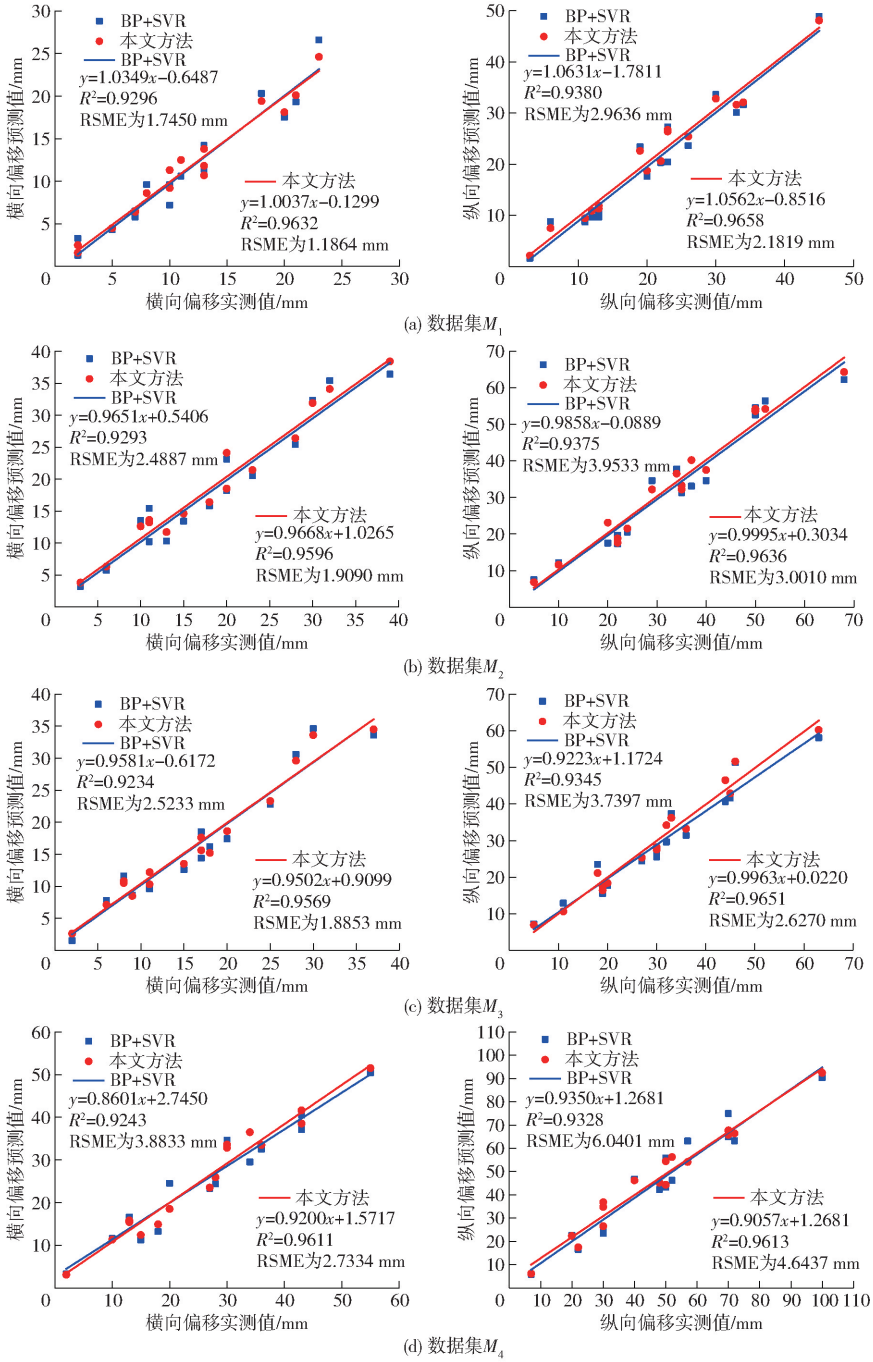

图 12　本文方法与 BP + SVR 算法预测结果对比

Fig. 12　Comparison of prediction results between proposed method and BP + SVR

发生变化，仅使用离线模型预测，忽略了外界实时变化因素对底盘行驶状态的影响，而本文的时变量化模型可以实时不断修正结果，减少预测误差。

进一步分析可知，离线的 BP + SVR 模型使用数据集 M_1 预测精度高于使用数据集 M_3 预测精度，离线的 BP + SVR 模型使用数据集 M_2 预测精度高于使用数据集 M_4 预测精度。说明离线预测模型的精度会被地面波动、底盘输出功率和轮胎损耗所影响，且底盘轮胎损耗对模型预测精度的影响大于输出功率变化带来的影响。而本文在线预测方法在使用数据集 M_1、M_2、M_3 和 M_4 时预测精度均高于 95%，数据处理方法相比于其他方法更能挖掘多源数据中的有用信息，同时能够实时修正历史数据训练的模型，减少地面波动、底盘输出功率和轮胎损耗对预测结果的影响。

5　行驶效果验证试验

5.1　试验方法

为验证本文提出的基于数字孪生的温室作业底盘行驶状态在线监测方法，基于自主研发的轮式电动移动平台进行验证试验。控制过程采用数字孪生反向控制的方式，基于行为模型，由孪生体生成虚

拟动作行为,并将模拟角度传入物理世界,进而控制温室作业底盘行驶。在孪生界面内显示当前偏移预测值,模型根据孪生动作信息,评估行驶状态的偏移状况,并在可能超过偏移预设值的时刻,进行行驶方向微调同时提示报警信息,基于数字孪生的控制过程如图 13 所示。

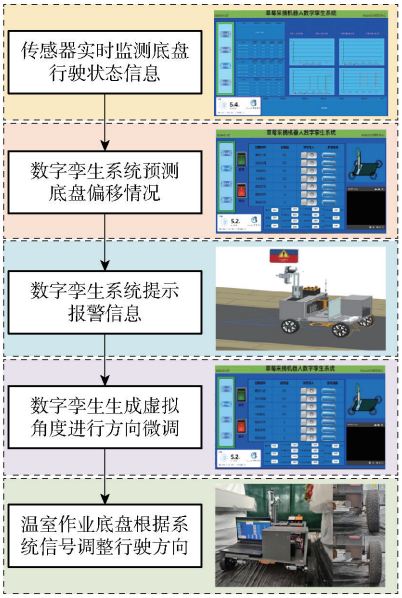

图 13 基于数字孪生的底盘行驶状态调整控制流程图

Fig. 13 Chassis driving state adjustment control based on digital twins

设置底盘在速度 0.35、0.40、0.45、0.50 m/s 下行驶 2 m 的距离进行验证试验,行驶结束后测量横向偏移和纵向偏移。在进行验证试验时,为降低非试验因素对试验效果的影响,在同一温室的相同位置进行试验。对比本文提出的基于数字孪生的温室作业底盘行驶状态在线监测方法和基于固定行驶参数下的底盘行驶效果。

5.2 试验结果分析

试验得到不同行驶速度下,基于数字孪生的温室作业底盘行驶状态在线监测方法和基于固定行驶参数下底盘的行驶横向偏移和纵向偏移,如图 14 所示。

由图 14 可以发现,对比于基于固定行驶参数的底盘行驶方法,基于数字孪生的温室作业底盘行驶状态在线监测方法的底盘行驶精度更高、误差更小。分别在速度为 0.35、0.40、0.45、0.50 m/s 行驶时,在本文提出的作业方法下其横向偏移分别为 6.00、8.00、9.00、10.00 mm,相较于基于固定行驶参数的底盘行驶方法下横向偏移的 13.00、15.00、16.00、20.00 mm,分别降低 53.85%、46.67%、43.75% 和 50.00%;在本文提出的作业方法下其纵向偏移分别为 15.00、12.00、15.00、17.00 mm,相较于基于固定行驶参数的底盘行驶方法下纵向偏移的 23.00、28.00、32.00、34.00 mm,分别降低 34.78%、

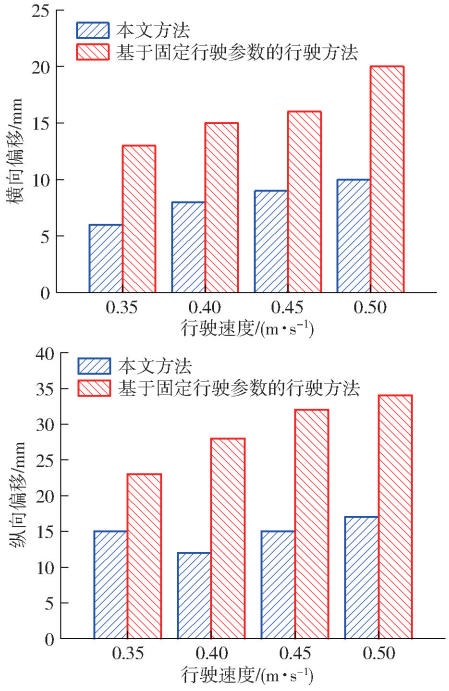

图 14 不同方法下行驶结果对比

Fig. 14 Comparison of results using different methods

57.14%、53.13% 和 50.00%;本文提出方法横向偏移平均值和纵向偏移平均值分别为 8.25 mm 和 14.75 mm,相较于基于固定行驶参数的底盘行驶方法横向偏移平均值(16.00 mm)和纵向偏移平均值(29.25 mm)分别降低 48.13% 和 49.49%。证明了本文提出的基于数字孪生的温室作业底盘行驶状态在线监测方法可以有效提升底盘行驶效果。

6 结论

(1)提出了一种基于数字孪生的温室作业底盘行驶状态在线监测方法,实现了底盘行驶过程的实时监测、状态预测和精准控制,为实现机器人的远程控制和连续式作业方法和技术提供依据和参考。通过开发面向行驶状态变化的设施作业底盘数字孪生系统,构建考虑地面波动和底盘损耗的底盘行驶状态时变模型,建立设施作业底盘行驶状态在线预测模型,解决了温室作业底盘行驶过程动态数据在线采集处理困难和行驶状态预测误差大的问题。

(2)基于 RBF 构建的底盘行驶状态横向偏差时变模型的 RMSE、MAE、R^2 分别为 1.597 2 mm、1.409 6 mm、0.954 5;纵向偏差时变模型的 RMSE、MAE、R^2 分别为 2.894 5 mm、2.457 8 mm、0.945 1,拟合效果良好,比基于 RSM 和 MLR 构建的底盘行驶状态时变模型具有更好的拟合精度;基于本文在线预测方法构建的横向偏移和纵向偏移预测模型决定系数分别为 0.955 7、0.956 5,均方根误差分别为

1.358 6、1.979 4 mm，拟合效果良好，且预测结果均为上下界限之内，本文方法能够准确预测底盘行驶状态偏差。

(3)对比于 SVR 预测模型和 BP 神经网络预测模型，BP + SVR 预测模型预测结果的 RMSE 和 MAE 最小，R^2最大，证明了本文数据处理方式的优越性；针对数据集 M_1、M_2、M_3和 M_4进行预测，使用本文在线预测方法的横向偏移预测精度分别为 96.32%、95.96%、95.69%、96.11%，相较于 BP + SVR 算法预测精度的 92.96%、92.93%、92.34%、92.43%，分别提高 3.61%、3.26%、3.92%、3.98%；使用本文在线预测方法的纵向偏移预测精度分别为 96.58%、96.36%、96.51%、96.13%，相较于 BP + SVR 算法预测精度的 93.80%、93.75%、93.45%、93.28%，分别提高 2.96%、2.78%、3.27%、3.06%，证明了加入时变偏差量化模型能有效减小误差，使预测结果更精准。

(4)验证试验表明，本文提出的基于数字孪生的温室作业底盘行驶状态在线监测方法横向偏移平均值和纵向偏移平均值分别为 8.25 mm 和 14.75 mm，相较于基于固定行驶参数的底盘行驶方法横向偏移平均值(16.00 mm)和纵向偏移平均值(29.25 mm)分别降低 48.13% 和 49.49%。在不同速度下行驶时，基于数字孪生的温室作业底盘行驶状态在线监测方法的行驶偏差基本保持稳定，能够基于底盘实时行驶状态进行动态调整。

参 考 文 献

[1] YANG X, SHU L, CHEN J, et al. A survey on smart agriculture: development modes, technologies, and security and privacy challenges [J]. IEEE - CAA Journal of Automatica Sinica, 2021, 8(2): 273 - 302.

[2] 刘成良, 贡亮, 苑进, 等. 农业机器人关键技术研究现状与发展趋势[J]. 农业机械学报, 2022, 53(7): 1 - 22, 55.
LIU Chengliang, GONG Liang, YUAN Jin, et al. Current status and development trends of agricultural robots[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(7): 1 - 22, 55. (in Chinese)

[3] 石梓廷, 张华. 基于 ADAMS 的温室作业柔性移动底盘仿真与实验[J]. 黑龙江工业学院学报(综合版), 2023, 23(2): 80 - 87.
SHI Ziting, ZHANG Hua. Simulation and experiment of flexible mobile chassis for greenhouse operation based on ADAMS[J]. Journal of Heilongjiang University of Technology (Comprehensive Edition), 2023, 23(2): 80 - 87. (in Chinese)

[4] JIA W, YANG G, WANG C, et al. Energy-efficient torque distribution optimization for an omnidirectional mobile robot with powered caster wheels[J]. Energies, 2019, 12(23): 4417.

[5] LE GOFF A, LACOUME J, BLANPAIN R, et al. Automobile wheel clearance estimation using magnetism[J]. Mechanical Systems and Singnal Processing, 2012, 26: 315 - 319.

[6] 宗长富, 陈国迎, 梁赫奇, 等. 基于模型预测控制的汽车底盘协调控制策略[J]. 农业机械学报, 2011, 42(2): 1 - 7.
ZONG Changfu, CHEN Guoying, LIANG Heqi, et al. Vehicle chassis coordination control strategy based on model predictive control[J]. Transactions of the Chinese Society for Agricultural Machinery, 2011, 42(2): 1 - 7. (in Chinese)

[7] SHI Y, LIU J, HUANG D, et al. Prediction and experimental study of tire slip rate based on chassis sinkage amount[J]. Agriculture, 2023, 13: 665.

[8] 沈跃, 何思伟, 刘慧, 等. 高地隙喷雾机自转向电动底盘控制系统设计与试验[J]. 农业机械学报, 2020, 51(11): 385 - 392, 402.
SHEN Yue, HE Siwei, LIU Hui, et al. Modeling and control of self-steering electric chassis structure of high clearance sprayer [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(11): 385 - 392, 402. (in Chinese)

[9] 瞿济伟, 郭康权, 宋树杰, 等. 农用柔性底盘偏置轴转向机构联动耦合控制策略及试验[J]. 农业工程学报, 2019, 35(23): 55 - 65.
QU Jiwei, GUO Kangquan, SONG Shujie, et al. Coupling control strategy and test for off-centered shaft steering mechanisms of agricultural flexible chassis[J]. Transactions of the CSAE, 2019, 35(23): 55 - 65. (in Chinese)

[10] 朱立成, 赵智宇, 韩振浩, 等. 基于自抗扰控制的双重转向运动控制系统设计与试验[J]. 农业机械学报, 2023, 54(增刊 1): 391 - 401.
ZHU Licheng, ZHAO Zhiyu, HAN Zhenhao, et al. Design and experiment of dual-steering control system based on active disturbance rejection control[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp. 1): 391 - 401. (in Chinese)

[11] 张燕军, 周厚强, 张昇, 等. 以内外信息相结合的轮式底盘状态预测研究[J]. 农业装备与车辆工程, 2012, 50(6): 38 - 41.
ZHANG Yanjun, ZHOU Houqiang, ZHANG Sheng, et al. The condition prediction study of wheel-type chassis based on internal and external information[J]. Agricultural Equipment & Vehicle Engineering, 2012, 50(6): 38 - 41. (in Chinese)

[12] 钱晓明, 黄宇轩, 楼佩煌, 等. 基于多传感器融合的跟随 AGV 复合导引技术[J]. 农业机械学报, 2022, 53(1): 14 - 22, 32.
QIAN Xiaoming, HUANG Yuxuan, LOU Peihuang, et al. Navigation technology of following AGV based on multi-sensor fusion [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(1): 14 - 22, 32. (in Chinese)

[13] LIANG Y, MUELLER S, ROLLE D. Tightly coupled multimodal sensor data fusion for robust state observation with online delay estimation and compensation[J]. IEEE Sensors Journal, 2022, 22(13): 13480 - 13496.

[14] WANG X, ZHANG H, WANG Y, et al. ELM-based AFL - SLFN modeling and multiscale model-modification strategy for online prediction[J]. Process, 2019, 7(12): 893.
[15] 王纪章, 王涛, 付益辉, 等. 数字孪生技术在农业生产管控中的应用现状与展望[J]. 农业机械学报, 2024, 55(9): 1 - 20.
WANG Jizhang, WANG Tao, FU Yihui, et al. Application status and development prospects of digital twin technology in agricultural production process control[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(9): 1 - 20. (in Chinese)
[16] 赵罡, 李瑾岳, 徐茂程, 等. 航空发动机关键装配技术综述与展望[J]. 航空学报, 2022, 43(10): 475 - 507.
ZHAO Gang, LI Jinyue, XU Maocheng, et al. Research status and prospect of key aero-engine assembly technology[J]. Acta Aeronautica et Astronautica Sinica, 2022, 43(10): 475 - 507. (in Chinese)
[17] PYLIANIDIS C, OSINGA S, ATHANASIADIS I. Introducing digital twins to agriculture[J]. Computers and Electronics in Agriculture, 2021, 184: 105942.
[18] 王纪章, 刘哲, 高志恒, 等. 基于数字孪生的拖拉机混流装配智能排产仿真评价[J]. 农业机械学报, 2024, 55(4): 385 - 393.
WANG Jizhang, LIU Zhe, GAO Zhiheng, et al. Intelligent scheduling simulation evaluation of tractor mixed-model assembly based on digital twin[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(4): 385 - 393. (in Chinese)
[19] 陶飞, 刘蔚然, 张萌, 等. 数字孪生五维模型及十大领域应用[J]. 计算机集成制造系统, 2019, 25(1): 1 - 18.
TAO Fei, LIU Weiran, ZHANG Meng, et al. Five-dimension digital twin model and its ten applications[J]. Computer Integrated Manufacturing Systems, 2019, 25(1): 1 - 18. (in Chinese)
[20] 马博文, 刘孟楠, 尹彦鑫, 等. 联合收获机轻量级数字孪生系统构建方法研究[J]. 农业机械学报, 2024, 55(5): 108 - 120.
MA Bowen, LIU Mengnan, YIN Yanxin, et al. Construction method and application example of lightweight digital twin system of combine harvester[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(5): 108 - 120. (in Chinese)
[21] 郭大方, 杜岳峰, 栗晓宇, 等. 云-雾-边-端协同的农业装备数字孪生系统研究[J]. 农业机械学报, 2023, 54(10): 133 - 141.
GUO Dafang, DU Yuefeng, LI Xiaoyu, et al. Digital twin system for agricultural machinery with cloud - fog - edge - terminal architecture[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(10): 133 - 141. (in Chinese)
[22] 王武英, 魏霖静. 基于数字孪生的智慧农业环境监测系统设计与实现[J]. 智能计算机与应用, 2023, 13(4): 181 - 185.
WANG Wuying, WEI Linjing. Design and implementation of intelligent agricultural environmental monitoring system based on digital twins[J]. Intelligent Computer and Applications, 2023, 13(4): 181 - 185. (in Chinese)
[23] 汪成亮, 庞栩, 陆志坚, 等. 基于动态特征提取和神经网络的数据流分类研究[J]. 计算机应用, 2010, 30(6): 1539 - 1542, 1567.
WANG Chengliang, PANG Xu, LU Zhijian, et al. Classifica of data stream based on dynamic feature extraction and neural network[J]. Journal of Computer Applications, 2010, 30(6): 1539 - 1542, 1567. (in Chinese)
[24] MARUKATAT S. Tutorial on PCA and approximate PCA and approximate kernel PCA[J]. Artificial Intelligence Review, 2022, 56(6): 5445 - 5477.
[25] BELAADI A, BOUMAAZA M, ALSHAHRANI H, et al. Effect of jute fiber length on drilling performance of biocomposites: optimization comparison between RSM, ANN, and genetic algorithm[J]. International Journal of Advanced Manufacturing Technology, 2023, 124(10): 3579 - 3599.
[26] 周修理, 秦娜, 王开宇, 等. 基于机器学习的机械压实对大豆产量的影响预测研究[J]. 农业机械学报, 2023, 54(11): 139 - 147.
ZHOU Xiuli, QIN Na, WANG Kaiyu, et al. Effect of mechanical compaction on soybean yield based on machine learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 139 - 147. (in Chinese)
[27] 崔永杰, 王明辉, 张鑫宇, 等. 基于支持向量机回归的营养液调控模型研究[J]. 农业机械学报, 2021, 52(1): 312 - 323.
CUI Yongjie, WANG Minghui, ZHANG Xinyu, et al. Regulation model research of nutrient solution based on support vector machine regression[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(1): 312 - 323. (in Chinese)
[28] 李韶华, 李健玮, 冯桂珍. 基于 GA - LSTM 自适应卡尔曼滤波的路面不平度识别[J]. 振动与冲击, 2024, 43(9): 121 - 130.
LI Shaohua, LI Jianwei, FENG Guizhen. Road roughness recognition based on GA - LSTM adaptive Kalman filtering[J]. Journal of Vibration and Shock, 2024, 43(9): 121 - 130. (in Chinese)