高技术通讯 2026 年 第 36 卷 第 6 期:643 - 651

doi:10.3772/j.issn.1002 - 0470.2026.06.010

基于 NARX 动态神经网络的球形机器人混合建模①

罗文龙② 章 政③ 付永鹏 张军生 刘思贤

(武汉科技大学信息科学与工程学院 武汉 430081)

摘 要 球形机器人具有欠驱动、非完整约束、数学模型复杂等特点,针对球形机器人存在难以建立精确数学模型的问题,提出了一种基于机理建模和外因输入的非线性自回归(nonlinear auto-regressive with exogeneous inputs,NARX)动态神经网络数据驱动建模的混合建模方法。首先,基于所搭建的球形机器人平台,使用拉格朗日方程建立其动力学模型;然后,针对机理建模过程中存在机理假设和非线性环节处理导致建模偏差,设计了一种自适应小波包去噪(adaptive wavelet packet denoising,AWPD)算法和 NARX 动态神经网络的数据驱动建模方法,通过采用自适应阈值函数策略,能够根据每一层的噪声分布规律自适应地调整 AWPD 算法的阈值,提升数据的去噪效果,同时,采用 NARX 动态神经网络建立了球形机器人的数据驱动模型,在此基础上将动力学模型和数据驱动模型相结合构建球形机器人混合模型。实验结果表明,相比于传统的机理建模和数据驱动建模方法,本文所设计的混合建模方法具有更强的数据去噪能力、更高的建模精度和泛化能力。

关键词 球形机器人;自适应小波包去噪;动态神经网络;混合建模

球形机器人是一类通过位于球壳内部的驱动装置,基于质心偏移和动量守恒原理实现球体滚动运动的机器人[1]。球形机器人具有良好密闭性、抗倾倒、防碰撞、能耗低、全向移动等特点,在环境监测、管道探伤、野外侦查等领域具有广泛应用[2]。由于球形机器人机械结构的复杂性、独特单点平衡运动方式以及运动环境的不确定性,具有欠驱动、非完整约束、数学模型复杂等特点,导致其在建模过程中存在难以精确数学描述的非线性问题,这增加了球形机器人的控制难度。因此,建立精确的球形机器人模型对于实现其稳定、高效运行至关重要。

目前,许多学者针对球形机器人建模问题进行了相关研究,主要方法有基于牛顿-拉格朗日法[3]和牛顿-欧拉法[4]的机理建模法,基于神经网络[5]、支持向量机[6]和决策树[7]等数据驱动的建模法。对于机理建模法而言,由于球形机器人复杂的运动性能和受力耦合等因素导致难以精确的确定模型参数;此外,在建模过程中需要作出多种机理假设以降低建模难度和处理非线性化环节,因此不可避免地引入了建模偏差。基于数据驱动建模方法已被证明可有效提高模型的精度和泛化能力[8]。但是,数据驱动建模方法存在难以对过程机理进行解释的固有缺陷,且模型的准确性依赖于数据的完备性和可靠性。近年来,将机理建模和数据驱动建模相结合的混合建模方法在复杂移动机器人领域已有广泛研究[9]。混合建模的方法不仅能结合机理模型的先验知识缩小参数空间的搜索域,减少模型估计所需的参数量并提高模型的泛化能力,而且能利用数据驱动方法建立复杂过程的数据驱动模型,简化建模流程、提高模型求解速度。

外因输入的非线性自回归(nonlinear auto-regressive with exogeneous inputs,NARX)动态神经网络通

① 国家自然科学基金(62303359)资助项目。
② 男,2001 年生,硕士生;研究方向:球形机器人;E-mail:19171517658@163.com。
③ 通信作者,E-mail:27347679@qq.com。
(收稿日期:2024 - 11 - 22)

过利用历史数据来增强对动态数据的处理能力，可用于非线性时间序列的建模[10]，具有记忆功能、训练逻辑简洁、提供完整信息及处理复杂问题的能力等特点[11]。文献[12]针对航空发电机气体路径参数建模复杂问题，基于 NARX 动态神经网络建立了具有输入输出数据的多元时间序列预测模型，以准确预测航空发电机气体路径参数。文献[13]对 NARX 动态神经网络进行训练建立了纵向飞行模型，有效解决了传统飞行动力学建模困难的问题。本文基于 NARX 动态神经网络建立球形机器人的数据驱动模型。在数据驱动建模过程中，输入输出的数据质量直接影响建模精度。针对球形机器人，其欠驱动的运动形式，球体在运动过程中会产生高频抖动，导致传感器采集到的信号中混入高频噪声，传感器温度变化造成零点偏移，产生低频噪声。这些因素不可避免地造成采样信号存在噪声干扰，导致数据精确性不高，难以保证建模所需数据的可靠性和准确性。鉴于此，有必要对 NARX 动态神经网络的输入输出数据进行预处理，以确保模型训练所用数据的质量与准确性。

综上所述，在自主搭建球形机器人平台的基础上，本文提出了一种基于自适应小波包去噪算法(adaptive wavelet packet denoising，AWPD)和 NARX 动态神经网络的球形机器人混合建模方法。首先，采用拉格朗日方程建立所设计球形机器人的动力学模型；然后，设计了一种自适应小波包去噪算法，并将其引入 NARX 动态神经网络中，在对输入输出数据进行噪声预处理后，利用 NARX 动态神经网络对非线性函数的逼近能力实现球形机器人的数据驱动建模；在此基础上，将机理模型与 NARX 动态神经网络数据驱动模型相结合构建混合模型；最后，实验结果验证了所设计混合建模方法的可行性和有效性。

1　球形机器人的机理建模

1.1　机械结构设计

本文设计球形机器人的机械结构图如图 1 所示，主要包括球壳、主板、驱动板、惯性测量单元(inertial measurement unit，IMU)模块、全向轮驱动装置、电源模块。全向轮驱动装置采用三相对称结构设计的形式，全向轮由 L 型直角电机驱动，全向轮均和球壳内壁相切，通过全向轮转动与球壳内壁的摩擦力产生的偏心力矩，来驱动球形机器人实现全向移动。

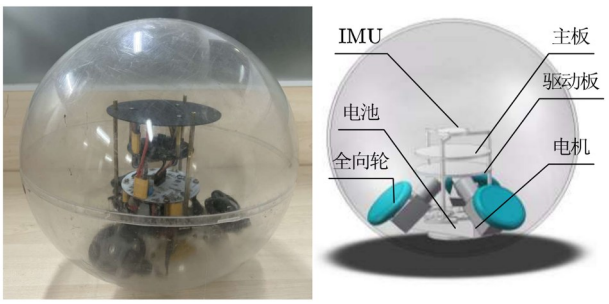

(a) 实物图　　(b) 示意图

图 1　球形机器人结构图

1.2　基于拉格朗日法的球形机器人动力学建模

为了便于进行动力学分析，本文假设球形机器人所有运动部件均为刚体，球壳与全向轮驱动装置、地面之间滚动接触均为纯滚动。

球形机器人参数说明如表 1 所示。

表 1　球形机器人参数说明

名称	变量符号	数值
球壳质量	M	0.956 kg
全向轮驱动装置质量	m	1.745 kg
球壳半径	R	0.175 m
球心到驱动装置质心间距离	l	0.115 m
重力加速度	g	9.8 m·s^{-2}

由于该球形机器人是一个轴对称结构，在球形机器人沿某一方向做直线运动时，可以将驱动平台投影到 xoz 和 yoz 平面上，其受力情况分析过程相同。为便于描述，将球形机器人的内部驱动平台等效为在球体内部运动的偏心块，球形机器人投影在 xoz 平面上的受力分析如图 2 所示。

图 2 中，α 表示驱动平台中心与球体中心的连线与铅垂线的夹角，即小车摆角；β 表示球体滚过的角度；x 表示球心在 ox 方向上的相对于初始位置的位移；τ 为驱动小车对球壳的驱动力矩。

假设球体在平面上滚动且无滑动，则球壳滚动的约束方程如下。

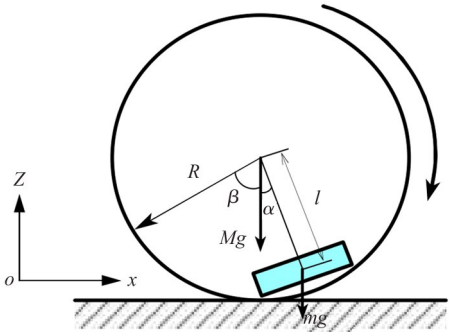

图 2　球形机器人的力学分析

$$x = R\beta \tag{1}$$

由式(1)可知,变量 x 和 β 之间不是独立的,因此整个球体的位移可由小车摆角 α 和球壳滚动的角度 β 唯一确定,则选取系统广义坐标为

$$q = [\ q_1 \quad q_2\ ]^{\mathrm{T}} = [\alpha \quad \beta]^{\mathrm{T}} \tag{2}$$

式中:上标 T 表示矩阵的转置。

球形机器人的动能 E_k 和势能 E_p 分别为

$$\begin{cases} E_k = E_{k1} + E_{k2} \\ E_{k1} = \dfrac{1}{2}M\dot{x}^2 + \dfrac{1}{2}J_1\left(\dfrac{\dot{x}}{R}\right)^2 \\ E_{k2} = \dfrac{1}{2}m_1(l\dot{\alpha} + \dot{x})^2 + \dfrac{1}{2}J_2\dot{\alpha}^2 \end{cases} \tag{3}$$

$$E_p = mgl(1 - \cos\alpha) \tag{4}$$

式中:E_{k1}、E_{k2} 分别是球壳动能和驱动平台动能;J_1 是球壳关于其转动轴的等效转动惯量,$J_1 = 2/3MR^2$;J_2 是驱动平台关于球心的等效转动惯量,$J_2 = ml^2$。

球形机器人的拉格朗日函数 L 为

$$L = E_k - E_p \tag{5}$$

根据虚功原理推算出系统所受广义力:

$$Q_k = [\ Q_\alpha \quad Q_\beta\ ]^{\mathrm{T}} = [\ \tau - mgl\sin\alpha \quad \tau\ ]^{\mathrm{T}} \tag{6}$$

由此可得,球形机器人系统的动力学方程为

$$\begin{cases} ml^2\ddot{\alpha} + mRl\cos\alpha\ddot{\beta} + mgl\sin\alpha = \tau \\ \left(\dfrac{5}{3}M + m\right)R^2\ddot{\beta} + mRl\cos\alpha\ddot{\alpha} - mRl\sin\alpha\dot{\alpha}^2 = \tau \end{cases} \tag{7}$$

2　基于 AWPD-NARX 动态神经网络的数据驱动建模

2.1　基于 AWPD-NARX 动态神经网络数据驱动建模方法设计

由式(7)所示的球形机器人动力学方程可知,面临其固有的不确定性和非线性特征,并且在其建模过程中由于线性假设、模型简化,从而引入建模误差。此外,球形机器人复杂的机械结构及欠驱动的运动方式,使得系统输入输出数据具有复杂的变化关系,影响建模精度。鉴于此,本文采用 NARX 动态神经网络建立球形机器人的数据驱动模型。NARX 动态神经网络是一种在线学习算法,可以根据输入数据在建模过程中动态调整其结构或参数,在非线性建模过程中具有显著优势。然而,在球形机器人运行过程中,其输入输出数据不可避免地会受到噪声影响,直接影响建模的准确性。为提高采集数据质量,本文在 NARX 动态神经网络建模基础上,设计了一种自适应小波包去噪算法。

小波包分解(wavelet packet decomposition, WPD)是一种对信号进行时频分析的算法,能够将信号分解为多个二维参量,实现不同频带的特征分解[14]。WPD 的阈值函数选择至关重要,不恰当的阈值函数会导致在信号重构时引入误差或导致信号失真。因此,本文设计了一种自适应阈值函数策略,能够根据每一层的噪声分布规律自适应地调整 AWPD 算法的阈值,确保在不同分层上对信号进行更精确的处理。

本文构建的 AWPD-NARX 动态神经网络数据驱动建模方法结构框图如图 3 所示。

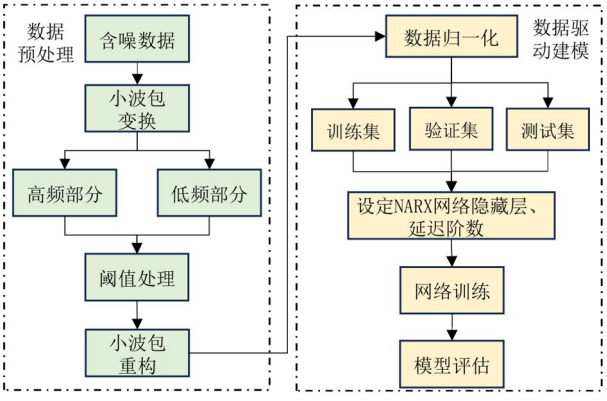

图 3　基于 AWPD-NARX 动态神经网络数据驱动建模的算法结构图

2.2　基于自适应阈值函数的小波包去噪算法

设球形机器人内电机的驱动力矩信号为 $u(t) = \tau_1, \tau_2, \cdots, \tau_t$;球形机器人的姿态角信号为 $dY(t) =$

$dY_1, dY_2, \cdots, dY_t$。球形机器人的含噪声信号模型为

$$s(t) = U(t) + n(t) \tag{8}$$

式中：$s(t)$ 为含噪信号；$U(t) = [u(t), dY(t)]$ 为有用信号；$n(t)$ 为噪声信号。

为避免因数据量纲和数据级不同导致的数据可比性差和模型训练低效的问题，采用线性归一化方法将样本数据进行无量纲化处理。

$$\bar{s} = \frac{s(t) - s(t)_{\min}}{s(t)_{\max} - s(t)_{\min}} \tag{9}$$

式中：$\bar{s}$ 为无量纲化数据序列；$s(t)$ 为原始序列数据；$s(t)_{\max}$ 为序列最大值；$s(t)_{\min}$ 为序列最小值。

根据递推关系可以求解出小波包分解系数的数学模型为

$$\begin{cases} w_{j+1,2k+1}(t) = \sqrt{2}\sum_{n\in Z} g(n) w_{j,k}(2t-n) \\ w_{j+1,2k}(t) = \sqrt{2}\sum_{n\in Z} h(n) w_{j,k}(2t-n) \end{cases} \tag{10}$$

式中：$w_{j+1,2k+1}$ 和 $w_{j+1,2k}$ 是 WPD 的系数，$j = 1,2,\cdots,J$ 为分解级数，表示第 j 层小波包分解；J 为总分解层数；k 为频带阶次，表示第 k 个小波包；$Z = 2^j$ 为第 j 层频带阶次总数；n 为平移变量；$g(n)$ 是低通滤波器的系数和；$h(n)$ 是高通滤波器的系数。

传统小波包去噪算法的阈值[15]为

$$\lambda = \sigma\sqrt{2\ln N} \tag{11}$$

式中：σ 是对第一层细节系数中噪声方差的估计，并应用到每一层的阈值计算中；N 为各层小波变换系数长度。

由式(11)所构建的硬阈值函数[16]和软阈值函数[17]分别为

$$\hat{w}_{j,k} = \begin{cases} w_{j,k}, & |w_{j,k}| \geqslant \lambda \\ 0, & \text{其他} \end{cases} \tag{12}$$

$$\hat{w}_{j,k} = \begin{cases} \operatorname{sgn}(w_{j,k}) \cdot |w_{j,k} - \lambda|, & |w_{j,k}| \geqslant \lambda \\ 0, & \text{其他} \end{cases} \tag{13}$$

式中：λ 为小波阈值；$w_{j,k}$ 是各层小波细节系数；$\hat{w}_{j,k}$ 是阈值处理后的小波细节系数。阈值 λ 和阈值函数 $\hat{w}_{j,k}$ 选取是小波包去噪的关键。如果阈值过大，会损失部分有用信号；阈值过小，则会保留较多噪声。而阈值函数会直接影响重构信号的平滑性及其高频信息。

由式(11)可知，在 WPD 中使用的第 1 层小波系数的阈值方差作为整体阈值方差，由此所得阈值 λ 保持恒定不变。然而，噪声是随小波变换分布，固定阈值 λ 会导致某些层噪声去除不够，无法达到更好的去噪效果。为了平衡保留信号与去除噪声，本文提出一种 WPD 的自适应阈值算法。

在设计阈值 λ 时，为了消除间断点并迅速逼近硬阈值函数，同时具有软阈值函数的平滑性，引入自然数 e，增大前两层的阈值函数数值间距，减少真实信号的过量去除。设第 j 层小波系数的阈值 λ_j 为

$$\lambda_j = \exp\left(\frac{\max(w_{j,k})^2}{2\sigma_j^2}\right)\cdot\frac{\sigma_j\sqrt{2\ln N}}{\ln(e + j - 1)} \tag{14}$$

式中：$w_{j,k}$ 为第 j 层的小波系数；σ_j 是对第 j 层小波系数噪声方差的估计，$\sigma_j = \text{median}|w_{j,k}|/0.6745$，其中 median 表示取中位数；$N$ 为各层小波变换系数长度；ln 是自然对数。

在式(14)中，当 $j = 1$ 时，与式(11)结果近似；当 $j > 1$ 时，随着 j 的变大，λ_j 变小，符合噪声随小波变换的分布规律，且具有自适应调整阈值的优点。

在设计阈值函数时，考虑到式(12)的硬阈值函数对阈值的执行力度最高，但由于硬阈值函数不连续，数据重构后容易产生新的数据震荡；而式(12)与式(13)之间存在固定阈值差，当数据重构后存在一定失真。基于式(14)定义的阈值 λ_j，一种可调节参数的自适应阈值函数定义为

$$\hat{w}_{j,k} = \begin{cases} 0, & |w_{j,k}| < \lambda_j \\ \operatorname{sgn}(w_{j,k})\left[|w_{j,k}| - \dfrac{\lambda_j}{\varepsilon^{\ln(1+|\hat{w}_{j,k}|-\lambda_j)}}\right], & |w_{j,k}| \geqslant \lambda_j \end{cases} \tag{15}$$

式中：$\varepsilon \in (1, +\infty)$ 为阈值函数的可调节参数。

在式(15)中，当 $w_{j,k} \to \pm\lambda_j$ 时，$|w_{j,k}| \to \lambda_j/[\varepsilon^{\ln(1+|w_{j,k}|-\lambda_j)}]$，自适应阈值函数保证了整体的连续性，从而避免了硬阈值函数产生的震荡现象；当 $w_{j,k} \to \infty$ 时，使得 $\hat{w}_{j,k} \to w_{j,k}$，能够有效地减少软阈值函数产生恒定偏差的问题；当 $\varepsilon \to 1$ 时，$\hat{w}_{j,k}$ 逼近于软阈值函数；$\varepsilon \to +\infty$ 时，$\hat{w}_{j,k}$ 逼近于硬阈值函数。且 $\lambda_j/[\varepsilon^{\ln(1+|w_{j,k}|-\lambda_j)}]$ 中分母指数增大，整体指数减小。

将式(15)定义的自适应阈值函数与式(10)得到的第 j 层近似系数进行重构,得到去噪后的球形机器人输入输出数据 $U(t)$ 为

$$U(t) = \sum_{n\in Z}(g(n)w_{j+1,2k+1}(t) + h(n)w_{j+1,2k}(t)) \tag{16}$$

2.3 NARX 动态神经网络数据驱动建模

NARX 动态神经网络通过结合静态神经元和网络输出的反馈,实现了对动态系统的建模。NARX 动态神经网络结构包括输入层、隐含层、输出层,以及输入延迟和输出延迟[18]。输入延迟允许网络考虑过去的输入数据,而输出延迟使得网络能够利用过去的输出信息,从而捕捉系统的动态特性。

球形机器人的 NARX 动态神经网络拓扑结构如图 4 所示。将经过 AWPD 算法预处理之后的数据 $U(t)$ 作为 NARX 动态神经网络的输入输出数据。在网络训练过程中,采用“开环”结构,直接将真实的输出 dY 作为训练期望输入,提升网络准确性;完成开环网络训练后将网络转化为虚线所示的“闭环”结构,将模型输出引回输入层,实现球形机器人的建模功能。

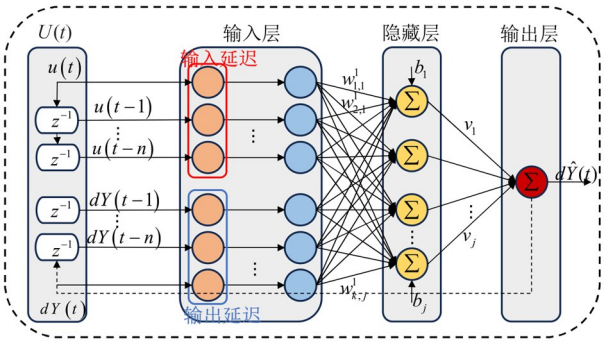

图 4　球形机器人的 NARX 动态神经网络结构图

网络设定隐藏层为 1 层,隐藏层神经元数为 6,输入输出时延阶数为 3,训练算法为列文伯格-马夸尔特(Levenberg Marquardt, LM)算法。基于 NARX 动态神经网络数据驱动建模的模型表示为

$$\begin{aligned} d\hat{Y}(t) &= f(U(t-1),U(t-2),\cdots,U(t-n)) \\ &= f\begin{pmatrix} u(t-1),u(t-2),\cdots,u(t-n_u), \\ dY(t-1),dY(t-2),\cdots,dY(t-n_y) \end{pmatrix} \end{aligned} \tag{17}$$

式中:$dY(t)$ 和 $u(t)$ 分别为离散时间步长下的模型输出与输入,n_u 是输入延迟,n_y 是输出延迟。

NARX 动态神经网络第 j 个隐藏层节点的为

$$H_j = f\left(\sum_{n=1}^{d_u} w_{n,j}u_n + \sum_{k=1}^{d_y} w_{k,j}dY_n + b_j\right) \tag{18}$$

式中:$w_{n,j}$ 为输入 u 的第 n 个时延节点 u_n 与第 j 个隐藏层节点的权值系数,$w_{k,j}$ 为外部输入 dY 的第 k 个时延节点 dY_n 与第 j 个隐藏层节点的权值系数,b_j 为该隐藏层的阈值,$f(\cdot)$ 表示非线性激活函数。

输出层函数为线性函数 $d\hat{Y}(t)$ 的函数为

$$d\hat{Y}(t) = \sum_{j=1}^{m} v_jH_j + b \tag{19}$$

式中:m 为隐藏层神经元个数,v_j 为第 j 个隐藏层节点与输出的权值系数,b 为输出层阈值。

采用实时循环学习(realtime recurrent learning, RTRL)算法调整球形机器人的 NARX 动态神经网络权值。

3　球形机器人的混合驱动建模方法设计

机理与数据互补的混合建模方式可以在建模过程中充分发挥机理建模和数据驱动建模各自的优点,本文所设计球形机器人并联型混合建模系统,其结构如图 5 所示。基于式(7)机理模型和式(19)数据驱动模型,利用 NARX 动态神经网络的非线性逼近能力来补偿机理模型的非线性误差,以提高模型的精度及泛化能力。

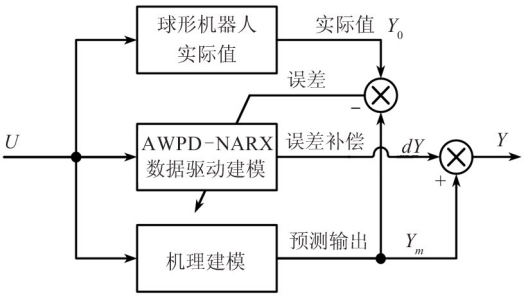

图 5　基于 AWPD-NARX 动态神经网络混合建模方法结构图

建立球形机器人的基于动态神经网络的混合模型的过程如下。

步骤 1　基于牛顿拉格朗日法建立球形机器人的动力学方程式(7),得到输出 Y_m。

步骤 2　采集球形机器人的输入输出时间序列

数据，构建数据驱动输入输出数据集，机理建模输出 Y_m 和球形机器人的实际输出 Y_0 之间的误差作为外部输入数据。

步骤 3　对数据集进行无量纲化处理，并利用本文提出的 AWPD 对 NARX 动态神经网络输入输出数据进行预处理，减小数据噪声对数据驱动建模精度的影响。

步骤 4　将去噪后无量纲的数据集划分为训练集、验证集和测试集。训练集用于 NARX 动态神经网络模型训练；验证集用于训练过程中对模型初步评估；测试集用于测试模型的实际学习能力，评估模型泛化能力。

步骤 5　将测试集输入到训练好的预测模型中，对比输出数据和测试集，计算 RMSE 和训练时长，评估模型预测精度。

步骤 6　循环步骤 4 到步骤 5，直到完成模型训练和评估，得到 NARX 动态神经网络模型输出 $d\hat{Y}$。

步骤 7　通过结合机理建模输出 Y_m 和 AWPD-NARX 动态神经网络数据驱动建模误差补偿输出 $d\hat{Y}$，得到球形机器人的混合建模输出 Y。

4　实验结果及分析

4.1　数据集构成及性能评价指标

在球形机器人运行过程中，以 50 ms 的采样周期采集 2 000 组球形机器人的输入力矩 τ 和输出姿态角 $[\alpha, \beta]$，按照 70%、15%、15% 的比例将数据集分别划分成 1 400 组数据作为训练集、300 组数据作为验证集、300 组数据作为测试集。

采用均方根误差（root mean square error，RMSE）作表征去噪效果和建模精度的性能评价指标。

$$\mathrm{RMSE} = \sqrt{1/N\sum_{i=1}^{N}(y_i' - y_i)^2} \tag{20}$$

式中：N 为采样点数，y_i 为样本原始值，y_i' 为去噪后数据或模型输出值。

4.2　数据预处理实验

为模拟传感器在采集数据时因球体高频抖动导致的采集信号带有的高频噪声，及传感器本身因温度变化导致的零点漂移产生的低频噪声，在原始数据集的姿态角数据上加入白噪声模拟噪声数据。

本文采用自适应阈值函数在实验中设置的参数 $\varepsilon = 2.6$，设置小波包分解层数为 3。将本文设计的 AWPD 与 WPD 的去噪效果进行对比，实验结果如图 6、图 7 和表 2 所示。

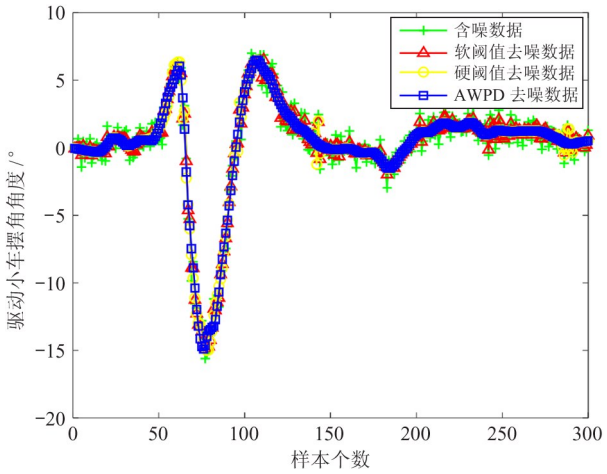

图 6　小车摆角的不同小波阈值去噪效果

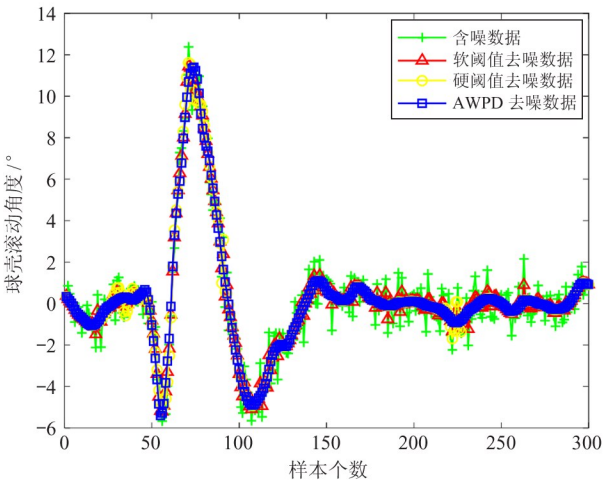

图 7　球壳滚角的不同小波阈值去噪效果

表 2　不同阈值函数的去噪效果

	软阈值去噪	硬阈值去噪	AWPD
RMSE	0.192 4	0.135 2	0.118 4

图 6 和图 7 中，经过 WPD 处理得到的绿色波形存在多处震荡，噪声因硬阈值函数的不连续性未被很好地去除；而经过 AWPD 处理过后红色波形可以看出，整体波形的连续性和光滑性较好，与原信号相似度更高，峰谷点周围幅值和曲线去噪效果占据优势。由表 2 可知，采用 AWPD 算法相对于软阈值去

噪效果提高了 35.09%,相较于硬阈值去噪效果提高了 12.43%。

4.3 3 种建模方法实验对比

在不引入白噪声数据前提下,分别采用基于式(7)的机理建模、基于式(19)的 NARX 动态神经网络建模和混合建模方法。其球形机器人的建模结果分别如图 8、图 9 和表 3 所示。

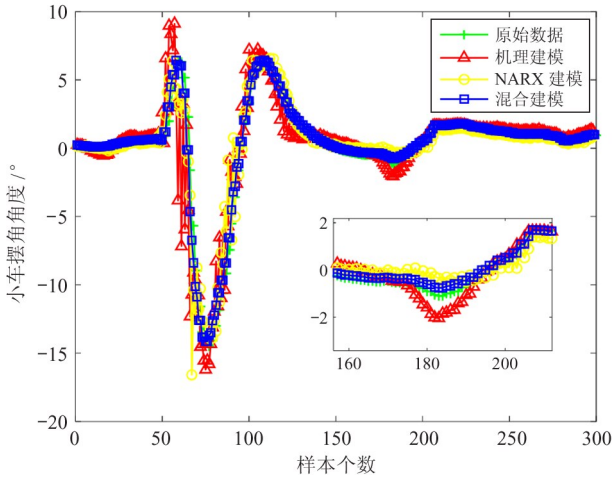

图 8 小车摆角的不同建模方法输出曲线

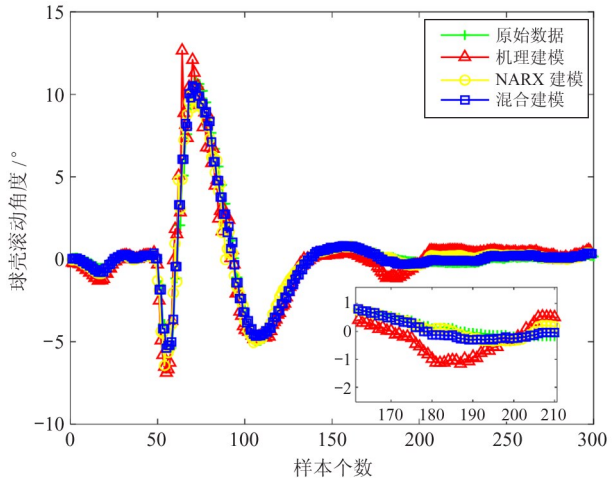

图 9 球壳滚角的不同建模方法输出曲线

表 3 3 种不同建模方法的误差

方法	小车摆角/°	球壳滚角/°
机理建模	0.437 4	0.412 2
NARX 建模	0.368 0	0.345 1
混合建模	0.268 0	0.252 6

对比图 8、图 9 和表 3 可知,与单一的机理建模方法或 NARX 动态神经网络驱动建模方法相比,两者结合的混合建模方法具有更高的建模精度。混合建模相较于采用机理建模方法和 NARX 动态神经网络建模方法精度分别提高了 38.84% 和 27.14%。

为验证本文所设计的混合建模方法的泛化能力,将球体内部驱动小车配重增加 0.5 kg,并在用于数据驱动建模的输入输出数据集上加入白噪声模拟噪声数据。深度神经网络(deep neural network,DNN)建模、长短期记忆网络(long short-term memory network,LSTM)建模和混合建模 3 种不同建模方法的结果对比如图 10、图 11 和表 4 所示。

对比图 10、图 11 和表 4 可知,与单一的 DNN 建模方法或 LSTM 建模方法相比,采用 AWPD-NARX 动态神经网络的混合建模方法能有效改善球体姿态角在跳跃间断点导致的数据突变。混合建模不仅具

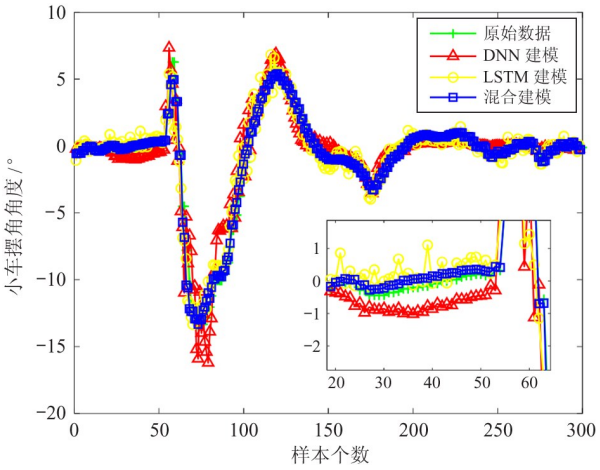

图 10 小车摆角的不同建模方法输出曲线

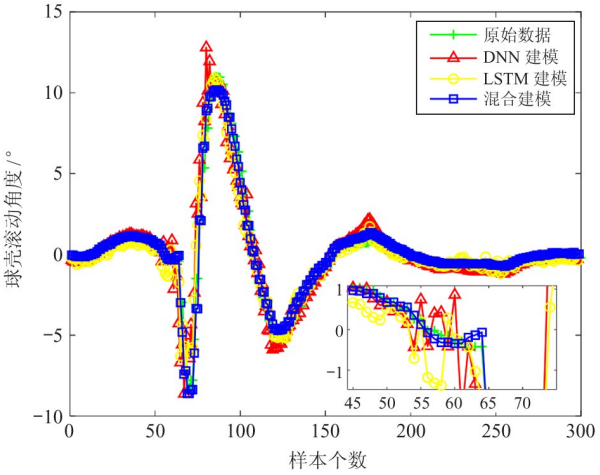

图 11 球壳滚角的不同建模方法输出曲线

表 4 3 种不同模型输出的误差

	驱动小车摆角/°	球壳滚动角度/°
DNN 建模	0.365 3	0.359 6
LSTM 建模	0.356 1	0.362 3
混合建模	0.257 1	0.242 5

有更高的建模精度,而且具备一定的泛化能力。具体来说,与 DNN 建模方法相比,混合建模的精度提高了 29.62%;与 LSTM 建模方法相比,精度提高了 27.80%。

5 结 论

球形机器人具有欠驱动、非完整约束、数学模型复杂等特点,建立其准确可靠的模型是实现球形机器人稳定运行的基础和前提,本文设计了一种结合动力学建模和基于 AWPD-NARX 动态神经网络数据驱动建模的球形机器人混合建模方法。主要结论如下所述。

(1)搭建了一个单球驱动自平衡机器人实验平台,采用拉格朗日法建立了其动力学模型。提出了一种基于 AWPD-NARX 动态神经网络数据驱动建模方法,在采用 NARX 动态神经网络建立球形机器人数据驱动建模过程中,针对球形机器人的输入输出数据不可避免存在噪声的问题,设计具有自适应阈值的小波包算法,根据每一层的噪声分布规律自适应地调整 AWPD 算法的阈值,提高输入输出数据质量,增强 NARX 动态神经网络模型对噪声的适应性,由此有效提高了基于 NARX 动态神经网络的建模精度。

(2)利用所构建球形机器人的数据驱动模型对其机理模型进行完善及扩充,由此构建了球形机器人混合模型。实验结果表明本文所设计的混合模型经过实验验证是切实可行的。通过数据驱动模型对机理模型的误差补偿,有效纠正机理建模的建模偏差,相较于单独使用机理建模或数据驱动建模,混合建模在建模精度上有显著提升,并展现出良好泛化能力,混合建模将均方根误差降低了 30.00% 以上,显著提升了球形机器人的建模精度。

参考文献

[1] Diouf A, Belzile B, Saad M, et al. Spherical rolling robots—design, modeling, and control: a systematic literature review[J]. Robotics and Autonomous Systems, 2024,175:104657.

[2] Kalita H, Gholap A S, Thangavelautham J. Dynamics and control of a hopping robot for extreme environment exploration on the Moon and Mars[C]//2020 IEEE Aerospace Conference. Big Sky, USA:IEEE, 2020:1-12.

[3] Nam D W, Lee C, Choi J, et al. Deep learning approach for linear locomotion control of spherical robot[C]//2019 19th International Conference on Control, Automation and Systems. Jeju, Korea: IEEE, 2019:557-562.

[4] Montenegro G, Chacón R, Fabregas E, et al. Modeling and control of a spherical robot in the CoppeliaSim simulator[J]. Sensors, 2022,22(16):6020.

[5] 袁铁江,郭泽林,胡辰康. 基于 LSTM-MPC 的 PEMFC 运行状态建模与容错控制[J]. 中国电机工程学报,2024,44(10):3927-3937.

[6] 赵戈雅,薛明皋. 基于 TN-LP-LSTM-SVM 混合模型的原油期货次日价格变化方向和波动率大小预测[J]. 控制与决策,2022,37(10):2627-2636.

[7] 夏恒,汤健,余文,等. 基于仿真机理和改进回归决策树的二噁英排放建模[J]. 自动化学报,2024,50(8):1601-1619.

[8] 李永刚,王月,刘丰瑞,等. 基于 Stacking 融合的短期风速预测组合模型[J]. 电网技术,2020,44(8):2875-2882.

[9] Ren J C, Liu D, Wan Y. Data-driven and mechanism-based hybrid model for semiconductor silicon monocrystalline quality prediction in the czochralski process[J]. IEEE Transactions on Semiconductor Manufacturing, 2022,35(4):658-669.

[10] Xu C, Li W, Zhao Y A. Novel fused NARX-driven digital twin model for aeroengine gas path parameter prediction[J]. IEEE Transactions on Industrial Informatics, 2024,20(4):6280-6288.

[11] 郭迎庆,朱文,刘少帅,等. 基于 NARX 神经网络系统辨识的振动台迭代学习控制研究[J]. 现代制造工程,2024,(12):37-47.

[12] 曹新宇,彭飞,李立伟,等. 基于 IBAS-NARX 神经网络的锂电池荷电状态估计[J]. 储能科学与技术,2021,10(6):2342-2351.

[13] 陈开民,顾宏斌,李鹏,等. 一种基于 NARX 神经网络的纵向飞行动力学建模方法[J]. 飞行力学,2023,41(5):37 -43,51.
[14] 肖勇,李博,曹敏. 基于小波阈值的电力谐波信号去噪研究[J]. 电测与仪表,2024,61(8):78 -83.
[15] 周晶,罗日成,黄军. 基于改进小波阈值—CEEMDAN 的变压器局部放电超声波信号白噪声抑制方法[J]. 高压电器,2024,60(1):163 -171.
[16] 向北平, 周建,倪磊, 等. 基于样本熵的改进小波包阈值去噪算法[J]. 振动. 测试与诊断,2019,39(2):410 -415,450 -451.
[17] Yang Y, Rao J. Robust and efficient harmonics denoising in large dataset based on random SVD and soft thresholding[J]. IEEE Access, 2019,7:77607 -77617.
[18] Dong Q, Austin A C M, Sowerby K W. Augmentation of self-interference cancellation for full-duplex using NARX neural networks[J]. IEEE Wireless Communications Letters, 2024,13(3):810 -813.

Hybrid modeling of spherical robot based on NARX dynamic neural network

Luo Wenlong, Zhang Zheng, Fu Yongpeng, Zhang Junsheng, Liu Sixian
(School of Information Science and Engineering, Wuhan University of Science and Technology, Wuhan 430081)

Abstract

Spherical robot has the characteristics of underactuation, non-holonomic constraint, complex mathematical model, etc. In order to solve the problem that it is difficult to establish accurate mathematical model, a hybrid modeling method based on nonlinear auto-regressive with exogeneous inputs (NARX) dynamic neural network data-driven modeling is proposed. Firstly, based on the spherical robot platform, Lagrange equation is used to establish its dynamics model. Then, aiming at the modeling deviation caused by mechanism assumption and nonlinear processing, a adaptive wavelet packet denoising (AWPD) algorithm and a data-driven modeling method based on NARX dynamic neural network are designed. By adopting the adaptive threshold function strategy, the threshold value of AWPD algorithm can be adjusted adaptically according to the noise distribution law of each layer to improve the noise reduction effect of data. Meanwhile, the data-driven model of spherical robot is established by using NARX dynamic neural network. On this basis, the dynamic model and data-driven model are combined to build a hybrid model of spherical robot. Finally, the experimental results show that the hybrid modeling method designed in this paper has stronger data denoising ability, higher modeling accuracy and generalization ability compared with the traditional mechanism modeling and data-driven modeling methods.

Key words: spherical robot, adaptive wavelet packet denoising, dynamic neural network, hybrid modeling