

结合动力学模型和 CNN 的机器人负载辨识方法^{*}

张春良, 郑仲之, 岳 夏, 王亚东, 龙尚斌

(广州大学机械与电气工程学院 广州, 510006)

摘要 现有基于神经网络识别工业机器人的负载识别方法易出现过度学习问题,且识别精度依赖于样本数量。为解决这一问题,提出了一种小样本条件下融合机器人动力学模型和神经网络的负载辨识方法。首先,提出了基于卷积神经网络(convolutional neural network,简称 CNN)的负载辨识方法,并分析了预测模型参数和不同神经网络的影响;其次,建立了多自由度工业机器人的经典动力学模型,并分析了动力学模型辨识的负载;最后,从动力学模型的计算结果中提取速度和位移等确定性信息作为初始锚定值,并应用 CNN 对残留的高度非线性信息进行补偿。结果表明:在 UR5 型机器人的负载测试实验中,所提方法在小样本条件下预测负载的平均误差小于 5%,总体误差波动小于 10%,验证了该方法的有效性。

关键词 工业机器人;动力学模型;卷积神经网络;小样本;非线性

中图分类号 TH113;TP242

0 引 言

工业机器人在某些场景下须对自身负载进行识别,以安全监控作业过程^[1]。然而,识别所需的扭矩传感器成本较高,且需要一定的安装空间^[2],在大湿度、强磁、大振动等极端环境下易导致数据失真^[3],必须通过动力学识别、神经网络预测等间接方法进行负载识别。目前,尽管机器学习已具备较好的研究基础,但对于高维复杂系统而言,其学习机制及方法的泛化能力仍需建立在大数据支撑之上^[4-6]。

目前,研究人员已经在小样本数据的处理和分析方面做了大量工作,并在预测、诊断、分类等方面取得了有效成果。王保健等^[7]针对样本数据冗余等问题,提出了结合支持向量机、核主成分分析和粒子群优化算法的方法,大幅提高了故障诊断精度。针对传统迁移学习在小样本时出现过拟合、精度低的情况,林杰威等^[8]提出循环微调训练方法,避免网络陷入局部最优解,提高了诊断的精度和稳定性。针对冲击损伤实验中数据量小且不平衡的问题,Doan 等^[9]利用分类器分割技术建立了一种具有高度稳定性能的自动分类模型。针对训练数据严重不足的情况,柳雅倩等^[10]提出了一种基于深度卷积生成对抗网络的方法,有效实现了对样本库的扩充和完善。

多自由度工业机器人动力学模型具有较强的非线性,直接用于参数辨识时存在计算量庞大的问题。因此,如何减少对样本量的依赖,以及提高负载辨识的效率已成为研究重点。针对机器人末端负载时变性引起控制精度降低的问题,张铁等^[11]建立了拉格朗日动力学线性辨识模型,有效实现了机器人负载辨识。针对非线性误差预测补偿问题,Chen 等^[12]提出了遗传算法驱动的深度神经网络非线性回归预测模型和柔度误差模型相结合的全局补偿方法,实现了任意外部负载下的高精度定位。为提高机器人应用的高精度和高安全性,Zhang 等^[13]提出了优化长短期记忆网络负载补偿模型,通过实验验证了系统误差补偿的可行性。

现有用于识别机器人非线性动力学参数和小样本高维运行数据的数学方法尚有待进一步完善。基于 CNN 的智能算法难以在样本数据较少的情况下有效识别高维非线性系统的输入或输出参数^[14],且模型的泛化能力不佳。因此,本研究提出将机器人动力学初步模型与 CNN 相结合,采用小样本数据对多自由度机器人进行动力学负载预测。负载动力学模型给出负载预测锚定值后,再结合 CNN 实现负载识别误差补偿,为小样本数据下的负载辨识提供新方法。

^{*} 国家自然科学基金资助项目(52275097);广东华中科技大学工业技术研究院/广东省制造装备数字化重点实验室开放基金资助项目(2023B1212060012)

收稿日期:2023-09-16;修回日期:2023-12-11

1 测试平台与数据采集

本研究以 UR5 型六自由度机器人为研究对象,该系统可采集机器人每个关节的运动和电流值。此外,为模拟无法测量负载的场景,本研究未在关节中加入扭矩传感器,而是通过电流力矩转换公式间接获得测量扭矩。

优良的激励轨迹可以有效降低采样数据的噪声,提高数据有效性和负载辨识效率。本研究选择对负载变化敏感的关节 2 作为识别采样关节,以傅里叶级数轨迹作为其激励轨迹,UR5 型机器人运动路径设计如图 1 所示。




图 1 UR5 型机器人运动路径设计

Fig.1 Designed motion path of UR5 robot

设置激励轨迹的约束条件为

$$\begin{cases} q_i(t) \leq q_{\max} \\ \dot{q}_i(t) \leq \dot{q}_{\max} \\ \ddot{q}_i(t) \leq \ddot{q}_{\max} \\ q_i(t_0) = \pi/4 \\ q_i(t_f) = -\pi/4 \\ \dot{q}_i(t_0) = \dot{q}_i(t_f) = 0 \\ \ddot{q}_i(t_0) = \ddot{q}_i(t_f) = 0 \\ p(t) \subset P \end{cases} \quad (1)$$

其中: q_i 、 $\dot{q}_i$ 、 $\ddot{q}_i$ 分别为关节电机 i 在 D-H 广义坐标系下的位置、速度和加速度; $q_{\max}$ 、 $\dot{q}_{\max}$ 、 $\ddot{q}_{\max}$ 分别为机器人允许的最大运动位置、速度、加速度; t 、 t_0 和 t_f 分别

为采样时间、运动开始时间和运动结束时间; $p(t)$ 和 P 分别为机器人的执行器的运动点矢量和 workspace。

为减小偶然误差,同组负载实验重复测量 50 次(合计 450 组),从中随机抽取 50 个样本作为原始数据,经过预处理后即得到实验数据。位移、速度和加速度用于计算关节扭矩,测量扭矩通过各关节的电流间接获得,电流和扭矩的关系为

$$\tau_i = K_i R I_i \quad (2)$$

其中: τ_i 、 I_i 和 K_i 分别为电机 i 的测量扭矩、电流及电机转矩常数^[14]; R 为关节电机与连杆之间的传动比,固定为 101。

为减少识别误差,还需要空载数据作为参考基准。

2 CNN 算法负载辨识方法

2.1 预测网络建模及参数分析

2.1.1 CNN 算法

CNN 的卷积结构可减少深度网络占用的内存量,从源信息中提取重要特征,采用梯度下降法使损失函数最小化,通过迭代训练提高网络预测精度。卷积层是 CNN 的核心,由多个卷积核组成,其宽度和高度相对较小。当滤波器沿着源数据的宽度和高度滑动时,会生成二维激活图,每层卷积均可形成多个激活图。

图 2 为 CNN 结构图。实验中负载的原始数据维度为 $[9, 2500, 18]$,共有 9 组不同的负载值,每组负载实验产生 2500×18 个数据点。初始数据存在明显信息冗余,采用主成分分析法(principal component analysis,简称 PCA)进行降维,然后采用 CNN 对处理后的数据进行分析。经过 PCA 处理后,原始数据维度变为 $[9, 2500, 7]$ 。




图 2 CNN 结构图

Fig.2 Structure of CNN

2.1.2 卷积核数量及损失函数

图 3 为卷积核数量对比。由图可知,相对标准

误差最初会随着卷积核数量的增加而减小,这是由于当卷积核数量较小时,不能充分读取源数据特征信息。另一方面,若卷积核数量过多(超过80个),则易出现过拟合,导致负载预测误差增大。因此,本研究示例中合适的卷积核数量为32~64。鉴于均方误差(mean square error,简称MSE)回归分析效果较好,故本研究采用MSE作为损失函数。




图3 卷积核数量对比

Fig.3 Comparison of the number of convolution kernels

表1为负载补偿模型参数统计。将卷积层padding设置为same模式以保持数据量的完整性,激活函数设为ReLU,优化器为RMSProp,损失函数为MSE,评价函数为平均绝对误差(mean absolute error,简称MAE)。

表1 负载补偿模型参数统计

Tab.1 Parameter statistics of load compensation model

网络层	输入层	参数量
CONV1D	[None, 18, 64]	1 216
MaxPooling1D	[None, 9, 64]	0
CONV1D_1	[None, 9, 64]	12 352
CONV1D_2	[None, 9, 32]	6 176
MaxPooling1D_1	[None, 4, 32]	0
Flatten	[None, 128]	0
Dense	[None, 64]	8 256
Dense_1	[None, 1]	65

2.2 不同神经网络的预测结果

UR5型机器人的额定最大载荷为5.0 kg,本研究设计8组标准负载(0.5~4 kg),以百分比的形式进行测量和预测。使用CNN、长短期记忆模型(long short-term memory,简称LSTM)、循环神经网络(recurrent neural network,简称RNN)和门控循环单元(gate recurrent unit,简称GRU)4种神经网络对不完整的小样本进行训练,然后以0.05 kg为间隔,将91个0~4.5 kg之间的间隔负载分组用于预测。图4为不同负载组50个样本点的预测结果,各实验组的间隔负载预测结果和误差分别如图4(a)和图4(b)所示。




图4 不同负载组50个样本点的预测结果

Fig.4 Prediction results with 50 sample points for each weight load

图4(a)展示了采用多种机器学习方法对每种载荷随机50个样本点的预测结果。除少数组点的预测结果偏差较大外,大部分结果的波动较小。CNN、LSTM、RNN、GRU的综合平均误差分别为7.58%、7.74%、7.75%、7.67%。当负载小于额定负载的10%时,预测结果偏差较大。当UR5型机器人以较小的负载运动时,其运动参数和电流的特征值

变化不大,这提高了机器学习方法提取特征的难度,导致预测误差增大。

图4(c)和图4(d)给出了CNN方法的误差分析,图中各负载下对应的误差棒用于表征辨识结果的稳定性。从图4(c)中可以看出,在0~1.5 kg的相同重量负荷范围内,识别误差的平均值波动较大。在2.5 kg之后,误差值则变得极小,仅为最大负载下的50%。图4(c)的变化趋势与图4(a)一致。从图4(d)可以看出,误差的上下限随着负载的增大而减小,由此可知,负载越大,误差波动范围越小,辨识结果越稳定。

2.3 模型评价分析

机器学习中常用卷积方式处理源数据,并用梯度下降原理完成损失函数计算,损失值与模型的训练精度成反比。评价函数用于表征模型输出结果的准确性。图5为网络模型结果评价,展示了CNN迭代6 000次的评价结果。




Fig.5 Evaluation of network model results

图5(a)为训练数据对应模型评价结果,其中损失函数和评价函数的下降趋势基本保持一致,表明模型对输入数据的学习准确率在迭代过程中逐渐提高。图5(b)为测试数据对应的模型评价结果,其损失函数值明显大于训练数据集的值,而评价函数随模型迭代过程波动较大。由此可知,受样本数量的约束,CNN的学习能力被极大程度限制,虽能实现

已知数据的学习,但无法完成对未知数据集的迁移和转换。此外,由于工作状态和负载的多变性,CNN难以实现所有负载源数据的学习。在可学习的测试数据有限的情况下,模型对目标问题的学习易产生过拟合现象,导致输出值围绕已学习样本波动,无法真正实现精准预测。

3 动力学模型负载辨识方法

3.1 拉格朗日动力学方程

拉格朗日法是通过能量法对机器人进行动力学分析,基于图1(b)所示的UR5机器人的关节坐标,建立机器人的系统动力学模型,由文献[14]可知,拉格朗日动力学方程为

$$\tau = M(q)\ddot{q} + C(q, \dot{q})\dot{q} + G(q) \quad (3)$$

其中: τ 是广义力矩阵; $M(q)$ 为机器人的质量惯性矩阵; $C(q, \dot{q})$ 为机器人的科氏力和离心力矩阵; $G(q)$ 为重力矩阵; q 为关节位置矩阵; $\ddot{q}$ 为关节加速度矩阵; $\dot{q}$ 为关节速度矩阵。

本研究将库仑黏性摩擦模型应用到机器人动力学识别模型中。机器人低速运作时,摩擦的非线性效应会非常显著,因此在进行误差补偿时需要考虑动力学影响因素,动力学方程变为

$$\tau = M(q)\ddot{q} + C(q, \dot{q})\dot{q} + G(q) + f_v(\dot{q}) + f_c \text{sign}(\dot{q}) + \lambda(q, \dot{q}, \ddot{q}) \quad (4)$$

其中: f_c 为关节的库仑摩擦因数矩阵; f_v 为关节的黏性摩擦力矩阵; $\lambda(q, \dot{q}, \ddot{q})$ 为未被准确建模的动力学影响因素的补偿矩阵。

3.2 扭矩线性化

定义与运动无关的参数为矩阵 ϕ_a ,则动力学方程可线性化^[15]表示为

$$\tau = W(q, \dot{q}, \ddot{q})\phi_a \quad (5)$$

其中: $W(q, \dot{q}, \ddot{q}) \in \mathbb{R}^{n \times m}$ 为与动力学参数相对应的系数矩阵; n 为机器人关节数; m 为动力学参数矩阵 ϕ_a 中的元素个数。

负载动力学参数和机器人本体动力学参数可线性分离,则负载的动力学参数可表示为

$$\phi_{\text{load}} = (W_{\text{link+load}}(q, \dot{q}, \ddot{q}))^{-1} \tau - (W_{\text{link}}(q, \dot{q}, \ddot{q}))^{-1} \tau_E \quad (6)$$

其中: ϕ_{load} 为负载矩阵; $W_{\text{link+load}}$ 为与连杆和负载相关的综合观测矩阵; τ 为加载时的关节扭矩矩阵; W_{link} 和 τ_E 分别为空载时的观测矩阵和关节扭矩。

分别计算负载和空载条件下的动力学参数,两者相减即为机器人负载,以避免小负载时关节变形等因素带来的系统误差。

当使用相同轨迹进行测量时,观测矩阵 $W_{\text{link} + \text{load}}$ 和 W_{link} 相同,则负载矩阵可表示为

$$\phi_{\text{load}} = (W(q, \dot{q}, \ddot{q}))^{-1} (\tau - \tau_E) \quad (7)$$

实际情况中,沿同一激励轨迹进行负载辨识实验时,关节的运动学参数与规划量并不完全相同。为补偿负载变化和关节变形的影响,需要引入不确定性误差补偿量 λ ,则负载矩阵变为

$$\phi_{\text{load}} = (W(q, \dot{q}, \ddot{q}))^{-1} (\tau - \tau_E) + \lambda \quad (8)$$

其中: λ 为动力学模型求解结果的误差项矩阵,其值由机器人关节与连杆之间的柔性变形误差、实验环境干扰、实验数据采集的系统误差等多重因素决定。

3.3 动力学负载辨识结果

UR5模型参数参考自文献[16]。机器人的关节位置、速度、加速度以及关节电流等数据由鲁棒局部回归滤波器进行处理,关节加速度则采用中心差分法计算后再进行滤波,最后进行时域平均化。随后,结合力矩求解法(torque solution method,简称TS)、全局参数辨识法(global parameter method,简称GP)和参数作差法(parameter difference method,简称PD)这3种负载辨识方法,对上述关节数据进行负载识别。基于动力学的负载辨识方法简述如表2所示。

表2 基于动力学的负载辨识方法简述

Tab.2 Description of workload identification method based on dynamic model

方法	简述
TS	直接通过式(5)计算扭矩
PD	通过式(6)计算在负载及空载时的扭矩
GP	假定负载时的运动轨迹和空载时相同,通过式(7)计算扭矩

UR5允许最大负载为5 kg,故实验中采集1、2、3和4 kg这4组负载数据,采样频率和周期分别为125 Hz和15 s,数据总量为1 825,根据采样时间等距采样50个样本,得到不同动力学辨识方法下的负载辨识结果如图6所示。由图可以看出,最大误差出现在样本起始段和末段,最大值约为识别值的30%,这一现象是由轨迹连续变化引起的电流值不稳定所导致。由此可见,以单个测量数据作为识别结果并不可靠。在取样的中间阶段,TS识别负载的相对误差小于10%,反映出较好的识别精度。在




图6 不同动力学辨识方法下的负载辨识结果

Fig.6 Identified results of workload by different method based on dynamic model

3种方法中,TS的识别精度最好,GP在采样起始段和末段的精度较差,而PD经过2次动力学计算后产生了累计误差,其平均识别误差会较其他2种方法误差更大。

表3为样本点负载预测结果。分析表中数据可知,TS具有良好的识别稳定性,预测值与实际值的相对误差小于10%;GP仅进行1次动力学分析,对关节电流和动力学模型的精度依赖性较大,其平均

误差小于 15%；由于累积误差的存在，PD 识别结果偏差较大。综上，仅靠这 3 种方法的识别精度无法满足行业需求。

表 3 样本点负载预测结果

Tab.3 Predicted results of workload with sample points

方法	负载/kg				平均误差/%	
	1	2	3	4	最大值	最小值
TS	1.02	1.97	3.10	4.21	7.95	2.74
GP	0.85	1.87	3.06	4.25	13.40	8.65
PD	1.10	2.12	3.31	4.50	11.83	6.18

4 动力学模型和 CNN 相结合的负载辨识方法

4.1 负载辨识组合方法

负载识别结果包括确定非线性部分和波动的不

确定部分。在小样本条件下，无波动的非线性部分可通过动力学模型进行识别，而波动的不确定部分可通过 CNN 进行识别。

机器学习可以完成小样本训练数据的学习，但其泛化能力较弱，且过拟合问题严重，难以准确预测负载的中心值。此外，动力学模型虽能粗略给出可靠的初始值，但波动误差较大。因此，本研究提出一种结合动力学模型和 CNN 的方法，即以动力学模型对负载的预测作为初始锚值，再采用 CNN 对该值进行补偿，以获得更高精度的预测负载。负载辨识组合方法流程图如图 7 所示。训练集(80%)和测试集(20%)的每个样本包括 25 个信息，即 24 个输入信息(6 个关节的位置 q 、速度 $\dot{q}$ 、加速度 $\ddot{q}$ 和关节电流 I)和 1 个输出信息(机器人负载计算误差)。在 1 个采样周期之后输入信息，同时经过动力学模型计算和 CNN 预测，分别得到负载计算值和负载补偿值，采用 CNN 预测结果对计算值补偿，即可得到精度更高的结果。




图 7 负载辨识组合方法流程图

Fig.7 Flow chart for the combination method for workload identification

4.2 组合方法识别标准负载

测试使用的标准负载为 1~4 kg 不等，每组负载取 30 个样本点。随机抽取 80% 的原始关节数据用于网络的训练和学习，剩余 20% 的数据用于补偿分析。图 8 为标准负载识别的平均误差，可以看出，3 种组合方法辨识结果与实际值之间具有良好的相关性，平均误差均低于 8%，其中结合 CNN 的力矩求解法(TS+CNN)的识别精度最高，其他 2 种方法(PD+CNN 和 GP+CNN)在小负载下误差相对较大，这与图 6 中的变化规律相一致。

进行重复测试以减少单次测试的随机性，并采用 TS、CNN 和 TS+CNN 这 3 种方法来识别负载。图 9 为不同方法下标准负载的平均误差和重复范




图 8 标准负载识别的平均误差

Fig.8 Average error with standard load weight

围。图 9(a)显示，TS+CNN 和 TS 在负载辨识方面的表现良好；从图 9(b)可以看出，CNN 识别结果的误差波动范围最小，但平均中心误差最大。TS+CNN 识别结果的波动范围略小于 TS，其误差波动具有良好的对称性，这是因为 TS+CNN 结

合了CNN和动力学模型的优点。由此可见,TS+CNN方法的平均误差和重复性误差均较小。




图9 不同方法下标准负载的平均误差和重复范围

Fig.9 Average errors and error repetitive range by each method with standard load weight

4.3 组合法识别非标准负载

在相同的实验条件下,重复收集85组小样本数据,负载范围为0.5~4.5 kg,质量梯度为0.05 kg,将这些数据定义为未经事先学习的非标准数据。与前文测量类似,每组负载重量取25个样本点,并用前述的组合法识别负载,非标准负载下组合方法的识别结果如图10所示。

由图10可知,3种方法的识别误差均随着负载增大而增大,这是由于大负载对于关节的影响显著,带来的动力学响应变化较大,更容易被识别;而在小负载(小于1.5 kg)下,每个关节的动力学响应变化较小,识别精度小于大负载时的精度。这表明PD+CNN和GP+CNN的识别结果比实际值大,而





图10 非标准负载下组合方法的识别结果

Fig.10 Identified results of non-standard load weight by combination methods

TS+CNN的结果却有相反的特点。在负载约为1.5、3.5 kg时,辨识结果有2次明显的跳变,这是由电流扰动所导致。在图10(b)中,PD+CNN在负载为1.5~3.5 kg时的识别精度最佳,而TS+CNN则在负载大于3.5 kg时展示出最佳识别精度。

不同样本数下非标准负载的识别误差如图11所示,给出了样本量变化对识别精度的影响。以TS为例进行研究,可以看出TS+CNN方法的全局误差远小于TS。TS的识别精度与样本数量的相关性较小,随着样本点逐渐增加,其平均误差迅速减小。当样本数达到50个时,识别精度已经足够优异。此时,样本数继续增加,识别精度变化不大。




图11 不同样本数下非标准负载的识别误差

Fig.11 Identified error of non-standard load weight with different sample number

5 结束语

从动力学模型中提取确定性信息,通过CNN学习不确定性信息和非线性信息,这2种方法的结合可以在小样本条件下有效识别高维系统的参数。结果表明:使用CNN研究已知标准负载的小样本数据时,接近学习数据的预测值误差较小,而对未研究过的非标准数据的预测误差较大;当负载为1.5~3.5 kg时辨识结果会出现跳变,误差急剧增大,原因在于输入参数(如电流值)不连续;动力学模型的识别结果波动较大,与负载激励有关,而CNN方法的结果平

均误差较大,但波动较小。在小样本条件下,所提出的动力学模型与CNN相结合的方法预测负载平均误差小于5%,总体误差的波动在10%左右。

参 考 文 献

- [1] WU J, WANG J S, YOU Z. An overview of dynamic parameter identification of robots[J]. *Robotics and Computer-integrated Manufacturing*, 2010, 26 (5): 414-419.
- [2] CAO M Y, LAWS S, BAENA F R Y. Six-axis force/torque sensors for robotics applications: a review[J]. *IEEE Sensors Journal*, 2021, 21(24): 27238-27251.
- [3] SCHICKER R, WEGENER G. Measuring torque correctly[EB/OL]. [2023-08-18]. https://theengineer.markallengroup.com/production/content/uploads/2017/03/HBM_Measuring-Torque-Correctly.pdf.
- [4] FARSONI S, FERRAGUTI F, BONFÈ M. Safety-oriented robot payload identification using collision-free path planning and decoupling motions[J]. *Robotics and Computer-integrated Manufacturing*, 2019, 59: 189-200.
- [5] FALEZZA F, VESENTINI F, DI FLUMERI A, et al. A novel inverse dynamic model for 3-DoF delta robots[J]. *Mechatronics*, 2022, 83: 102752.
- [6] JIN G, MA S, LI Z H. Dynamic simulation modeling of industrial robot kinematics in industry 4.0[J]. *Discrete Dynamics in Nature and Society*, 2022, 2022(36): e3217360.
- [7] 王保建, 张小丽, 傅杨奥骁, 等. 优化支持向量机及其在智能故障诊断中的应用[J]. *振动、测试与诊断*, 2017, 37(3): 547-552.
WANG Baojian, ZHANG Xiaoli, FU Yang'aoxiao, et al. Optimization of support vector machine and its application in intelligent fault diagnosis[J]. *Journal of Vibration, Measurement & Diagnosis*, 2017, 37(3): 547-552. (in Chinese)
- [8] 林杰威, 张益铭, 朱小龙, 等. 基于循环微调训练的柴油机故障迁移学习诊断[J]. *振动、测试与诊断*, 2025, 45(4): 682-689.
LIN Jiewei, ZHANG Yiming, ZHU Xiaolong, et al. Transfer learning and gas path fault diagnosis of diesel engine based on cyclic fine-tune training[J]. *Journal of Vibration, Measurement & Diagnosis*, 2025, 45(4): 682-689. (in Chinese)
- [9] DOAN Q H, MAI S H, DO Q T, et al. A cluster-based data splitting method for small sample and class imbalance problems in impact damage classification[J]. *Applied Soft Computing*, 2022, 120: 108628.
- [10] 柳雅倩, 蔡浩原, 李文宽, 等. 小样本条件下轴承故障的DCGAN诊断方法[J]. *振动、测试与诊断*, 2023, 43(4): 817-823.
LIU Yaqian, CAI Haoyuan, LI Wenkuan, et al. Research on deep convolutional generative adversarial networks diagnosis method of bearing fault under small sample condition[J]. *Journal of Vibration, Measurement & Diagnosis*, 2023, 43(4): 817-823. (in Chinese)
- [11] 张铁, 覃彬彬, 邹焱飏. 机器人负载的动力学参数辨识[J]. *工程科学学报*, 2017, 39(12): 1907-1912.
ZHANG Tie, QIN Binbin, ZOU Yanbiao. Identification methods for robot payload dynamical parameters[J]. *Journal of University of Science and Technology Beijing*, 2017, 39(12): 1907-1912. (in Chinese)
- [12] CHEN X Y, ZHANG Q J, SUN Y L. Evolutionary robot calibration and nonlinear compensation methodology based on GA-DNN and an extra compliance error model[J]. *Mathematical Problems in Engineering*, 2020, 2020: e3981081.
- [13] ZHANG G, XU Z, HOU Z C, et al. A systematic error compensation strategy based on an optimized recurrent neural network for collaborative robot dynamics[J]. *Applied Sciences*, 2020, 10: 6743.
- [14] RAVIOLA A, GUIDA R, DE MARTIN A, et al. Effects of temperature and mounting configuration on the dynamic parameters identification of industrial robots[J]. *Robotics*, 2021, 10(3): 83.
- [15] SWEVERS J, VERDONCK W, SCHUTTER J D E. Dynamic model identification for industrial robots[J]. *IEEE Control Systems Magazine*, 2007, 27(5): 58-71.
- [16] UNIVERSAL ROBOTS. DH parameters for calculations of kinematics and dynamics[EB/OL]. [2023-08-19]. <https://www.universal-robots.com/articles/ur/application-installation/dh-parameters-for-calculations-of-kinematics-and-dynamics>.



第一作者简介:张春良,男,1964年1月生,博士、教授。主要研究方向为系统状态检测、设备故障诊断。曾发表《A method of crack detection based on digital image correlation for simulated cracked tooth》(《BMC Oral Health》2021, Vol.21, No.1)等论文。
E-mail: nhzcl@163.com

通信作者简介:岳夏,男,1980年1月生,博士、讲师。主要研究方向为系统状态检测与识别。
E-mail: smnsss@gzhu.edu.cn