

基于深度神经网络逆动力学补偿与在线自适应的机械臂高精度轨迹跟踪控制

刘世达^{*#}, 邵音子^{*}, 姚智晔, 高月文

徐州工程学院圣彼得堡联合工程学院, 江苏 徐州

收稿日期: 2026年8月3日; 录用日期: 2026年9月16日; 发布日期: 2026年9月29日

摘要

机械臂动力学模型中的摩擦、负载变化等不确定因素是制约其轨迹跟踪精度的核心瓶颈。针对该问题, 本文提出一种“离线深度学习逆动力学前馈补偿 + 在线递推最小二乘(RLS)末层自适应”的复合控制框架。首先, 通过多正弦持续激励轨迹在闭环条件下采集约15.6万组状态-力矩样本, 训练多层感知机(MLP)逆动力学模型; 随后, 将学习得到的前馈力矩与低增益PD反馈复合, 构成NN-FF控制器; 进一步利用RLS在线更新网络末层权重, 形成对负载突变具有自适应能力的ANN-FF控制器。在二自由度机械臂高保真数值仿真平台上的系统实验表明: 学习模型的力矩预测均方根误差为 $0.087 \pm 0.004 \text{ N}\cdot\text{m}$, 较名义刚体模型($1.00 \text{ N}\cdot\text{m}$)降低约91%~92% ($R^2 > 0.998$); 在六种测试轨迹上, NN-FF的平均任务空间跟踪RMSE为0.49 mm, 较PID (14.86 mm)与计算力矩法(7.85 mm)分别提升约30.5倍与16.1倍; 面对1.0 kg负载突变, ANN-FF在约3~4 s内完成末层权重的主要重新整定, 稳态误差降至1.01 mm, 较冻结模型(5.49 mm)降低约82%。ANN-FF单步摊销计算耗时约160 μs , 满足1 kHz实时控制要求。研究结果为数据驱动的机械臂高精度控制提供了一条兼顾精度、鲁棒性与实时性的可行途径。

关键词

机器人工程, 机械臂, 轨迹跟踪, 深度学习, 逆动力学, 在线自适应, 递推最小二乘

High-Precision Trajectory Tracking Control of Robotic Manipulators Based on Inverse Dynamics Compensation with Online Adaptation of Deep Neural Network

Shida Liu^{*#}, Yinzi Shao^{*}, Zhiye Yao, Yuewen Gao

^{*}共同第一作者。

[#]通讯作者。

文章引用: 刘世达, 邵音子, 姚智晔, 高月文. 基于深度神经网络逆动力学补偿与在线自适应的机械臂高精度轨迹跟踪控制[J]. 人工智能与机器人研究, 2026, 15(5): 1335-1346. DOI: 10.12677/airr.2026.155121

Abstract

Uncertainties such as friction and payload variation in the dynamic model of a robotic manipulator are the core bottleneck limiting its trajectory-tracking accuracy. To address this problem, this paper proposes a composite control framework combining “offline deep-learning inverse-dynamics feedforward compensation + online recursive least-squares (RLS) output-layer adaptation”. First, approximately 156,000 state-torque sample pairs were collected under closed-loop conditions using multi-sine persistently exciting trajectories, and a multilayer perceptron (MLP) inverse-dynamics model was trained on these data. The learned feedforward torque was then combined with a low-gain PD feedback loop to form the NN-FF controller. RLS was further employed to update the network’s output-layer weights online, yielding an ANN-FF controller capable of adapting to sudden payload changes. Systematic experiments on a high-fidelity numerical simulation platform of a 2-DOF manipulator show that the learned model achieves a torque-prediction RMSE of 0.087 ± 0.004 N·m, a reduction of approximately 91%~92% relative to the nominal rigid-body model (1.00 N·m), with $R^2 > 0.998$. Across six test trajectories, NN-FF achieves a mean task-space tracking RMSE of 0.49 mm, representing improvements of approximately 30.5-fold and 16.1-fold over PID (14.86 mm) and computed-torque control (7.85 mm), respectively. Under a sudden 1.0 kg payload change, ANN-FF completes the main readjustment of its output-layer weights within approximately 3~4 s, with the steady-state error settling at 1.01 mm—a reduction of about 82% compared with the frozen model (5.49 mm). The amortized per-step computation time of ANN-FF is approximately 160 μ s, satisfying the requirements of 1 kHz real-time control. These results provide a feasible pathway for data-driven high-precision manipulator control that balances accuracy, robustness, and real-time performance.

Keywords

Robot Engineering, Robotic Manipulator, Trajectory Tracking, Deep Learning, Inverse Dynamics, Online Adaptation, Recursive Least-Squares

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

机械臂是智能制造、航空航天装配、医疗手术等领域的核心执行装备，其轨迹跟踪精度直接影响作业质量[1]-[3]。基于模型的控制方法(如计算力矩控制, Computed-Torque Control, CTC)在动力学模型精确已知时可实现优异的跟踪性能。然而，实际机械臂普遍存在关节摩擦、连杆参数辨识误差、末端负载变化等难以精确建模的不确定因素，导致名义模型与真实动力学之间存在显著偏差，进而显著削弱基于模型方法的性能优势[4] [5]。

为克服模型不确定性，自适应控制[6]与鲁棒控制方法相继被提出，但其通常依赖“参数线性化”假设，难以刻画摩擦等强非线性效应。近年来，以神经网络为代表的驱动方法为机器人动力学建模提供了新范式[7] [8]：多层前馈网络具有对连续非线性映射的万能逼近能力[9]，可直接从数据中学习包含摩

擦在内的完整逆动力学映射, 无需先验的参数化模型结构。相关思想已在腿式机器人运动技能学习、视觉运动策略端到端训练等任务中得到成功应用。然而, 纯离线学习的模型在部署后面临分布外(out-of-distribution)工况的挑战, 最典型的即末端负载变化: 抓取不同质量的工件会使系统动力学发生跳变, 冻结的网络模型无法跟随, 跟踪精度随之下降[10]。

针对上述问题, 本文提出一种兼顾离线学习精度与在线适应能力的复合控制框架, 主要贡献如下:

(1) 建立了基于多正弦持续激励与闭环数据采集的机械臂逆动力学学习流程, 所学 MLP 模型的力矩预测精度较名义刚体模型提升一个数量级; (2) 将学习前馈与低增益 PD 反馈复合, 构成结构简单、在线开销低的 NN-FF 控制器(网络前馈沿参考轨迹离线一次算出, 在线单步仅需查表与 PD 运算), 在六种测试轨迹上较 PID 平均提升约 30.5 倍跟踪精度; (3) 提出基于 RLS 的网络末层在线自适应机制(ANN-FF), 在保持深层特征不变的前提下以每步约 160 μ s 的摊销计算开销实现对负载突变的快速补偿; (4) 通过涵盖模型学习、轨迹跟踪、鲁棒性、泛化性与在线自适应的系统性仿真实验(共计近 400 次独立运行), 定量刻画了各环节的性能边界, 并进行了统计显著性检验。

2. 相关工作

2.1. 机械臂动力学建模与参数辨识

经典方法将机械臂动力学表示为惯性参数线性回归形式, 通过最优激励轨迹设计与最小二乘辨识获得参数估计[11]-[13]。此类方法物理可解释性强, 但对摩擦、关节柔性等非参数化效应只能采用简化模型(如库仑-黏性摩擦), 残余误差不可忽略。系统辨识理论[14]为激励设计与估计一致性提供了理论基础, 本文的多正弦激励方案即源于此。

2.2. 基于学习的动力学补偿

Nguyen-Tuong 与 Peters 系统综述了机器人模型学习方法[7], 指出局部高斯过程、核回归等非参数方法可在线逼近逆动力学, 但其推理复杂度随样本量增长。深度网络以固定推理代价换取大容量拟合能力, 近年来结合物理先验的 Deep Lagrangian Networks [15]等结构化模型进一步提升了外推性能。本文采用标准 MLP 以保证实时性, 并以消融实验量化容量与数据量的影响。

2.3. 自适应与在线学习控制

Slotine-Li 自适应控制[6]与神经网络自适应控制[8]通过李雅普诺夫方法保证跟踪误差有界, 但通常需要为特定结构定制自适应律, 其理论基础可追溯至经典自适应控制框架。另一条路线是在预训练网络上仅更新末层权重: 由于末层为线性回归结构, 可直接套用带遗忘因子的 RLS 更新[14], 兼具收敛速度与计算效率。仿真到现实迁移研究[10]亦表明, 在线适应是弥合动力学分布差异的关键环节。本文将该思想落实为完整的控制框架并给出系统评估。

3. 系统建模与控制方法

3.1. 机械臂动力学模型

考虑竖直平面内的二自由度旋转关节机械臂(图 1(a)), 其关节空间动力学方程为

$$M(q)\ddot{q} + C(q, \dot{q})\dot{q} + g(q) + f(\dot{q}) = \tau \quad (1)$$

式中: $q \in R^2$ 为关节角向量; $M(q)$ 为对称正定惯性矩阵; $C(q, \dot{q})$ 为科氏力/离心力矩阵; $g(q)$ 为重力项; τ 为关节驱动力矩; $f(\dot{q})$ 为摩擦力矩, 采用黏性摩擦与光滑化库仑摩擦的复合模型:

$$f(\dot{q}) = F_v \dot{q} + F_c \tanh(\dot{q}/\varepsilon) \quad (2)$$

其中, F_v 、 F_c 分别为黏性与库仑摩擦系数对角阵, $\varepsilon = 0.02 \text{ rad/s}$ 为光滑化参数。仿真中动力学方程采用四阶龙格-库塔法以 1 ms 步长积分, 力矩饱和限幅 $\pm 40 \text{ N}\cdot\text{m}$, 关节角与角速度测量分别叠加标准差 $1 \times 10^{-4} \text{ rad}$ 与 $2 \times 10^{-3} \text{ rad/s}$ 的高斯噪声, 以逼近真实编码器与差分测速特性。机械臂物理参数见表 1。

Table 1. Dynamics parameters of the robotic manipulator
表 1. 机械臂动力学参数

参数	符号	连杆 1	连杆 2	单位
质量	m	3.0	2.0	kg
长度	l	0.35	0.31	m
质心位置	lc	0.175	0.155	m
转动惯量	I	0.0306	0.0160	kg·m ²
黏性摩擦系数	F_v	0.8	0.5	N·m·s/rad
库仑摩擦系数	F_c	0.6	0.4	N·m

3.2. 逆动力学的深度学习建模

逆动力学学习的目标是从数据中逼近映射 $(q, \dot{q}, \ddot{q}) \rightarrow \tau$ 。为消除关节角的周期性并改善数值条件, 网络输入采用三角特征编码:

$$x = [\sin q_1, \sin q_2, \cos q_1, \cos q_2, \dot{q}_1, \dot{q}_2, \ddot{q}_1, \ddot{q}_2]^T \quad (3)$$

网络 h_θ 为两隐层多层感知机(每层 128 个神经元, SiLU 激活), 输入输出均作 z-score 标准化。训练数据通过 8 条互不相同的多正弦持续激励参考轨迹(图 1(c))在 PID 闭环下采集, 每条 20 s、采样率 1 kHz, 剔除每条起始 0.5 s 的瞬态后共得 156,000 组样本, 其末端位置覆盖了任务工作空间的主要区域(图 1(d)), 两关节力矩的分布见图 1(e)。训练目标为最小化均方误差:

$$L(\theta) = \frac{1}{N} \sum_{i=1}^N \|h_\theta(x_i) - \tau_i\|_2^2 \quad (4)$$

优化器为 Adam [16] (初始学习率 1.5×10^{-3} , 余弦退火, 批大小 1024, 80 个回合)。训练集随机抽取 5×10^4 样本, 验证集固定 8×10^3 样本, 重复 5 个随机种子以评估稳定性。需要说明, 验证集与训练集来自同一批激励数据的随机划分, 该 RMSE 为同分布精度估计, 模型在全新轨迹上的表现见 5.5 节。训练超参数汇总见表 2。

Table 2. Network architecture and training hyperparameters
表 2. 网络结构与训练超参数

项目	取值	项目	取值
输入维度	8	输出维度	2
隐层数 × 宽度	2×128	激活函数	SiLU
优化器	Adam	初始学习率	1.5×10^{-3}
学习率调度	余弦退火	批大小	1024
训练回合	80	训练样本数	5×10^4
验证样本数	8×10^3	随机种子数	5

3.3. 学习前馈复合控制律(NN-FF)

将学习得到的逆动力学模型沿参考轨迹计算前馈力矩, 并与低增益 PD 反馈复合:

$$\tau = h_{\theta}(q_r, \dot{q}_r, \ddot{q}_r) + K_p(q_r - q) + K_d(\dot{q}_r - \dot{q}) \quad (5)$$

其中, $K_p = \text{diag}(160, 110)$ 、 $K_d = \text{diag}(22, 14)$ 与 PID 基线的比例/微分增益一致, 以保证对比公平。前馈项承担了绝大部分驱动力矩, 反馈仅需修正残余误差与扰动, 因而无需高增益即可实现高精度跟踪, 避免了高增益反馈对噪声的放大(图 1(b))。前馈力矩可沿参考轨迹离线一次性计算, 在线阶段仅需查表与 PD 运算, 无需逐步推理网络。




Figure 1. System modeling and control framework. (a) Schematic diagram of the 2-DOF planar manipulator, with an optional end-effector payload m_p ; the gray dashed line marks the workspace boundary. (b) Composite control architecture: the learned inverse-dynamics model provides feedforward torque τ_{ff} , PD feedback provides corrective torque τ_{fb} , and the RLS module updates the network's output layer online. (c) Example multi-sine persistently-exciting reference trajectories used for data collection. (d) Coverage density of end-effector positions in the training data across the workspace; the black solid and dashed lines denote the circular and “figure-eight”-shaped test trajectories, respectively. (e) Distribution of the two joint torques in the dataset

图 1. 系统建模与控制框架。(a) 二自由度平面机械臂示意图, 末端可携带负载 m_p , 灰色虚线为工作空间边界。(b) 复合控制架构: 学习逆动力学模型提供前馈力矩 τ_{ff} , PD 反馈提供修正力矩 τ_{fb} , RLS 模块在线更新网络末层。(c) 用于数据采集的多正弦持续激励参考轨迹示例。(d) 训练数据末端位置在工作空间中的覆盖密度, 黑色实线与虚线分别为圆形与“8”字形测试轨迹。(e) 数据集两关节力矩分布

3.4. 基于 RLS 的末层在线自适应(ANN-FF)

记网络倒数第二层输出(附加常数项)为特征向量 $\varphi(x) \in R^{129}$, 则网络输出可写为线性回归形式 $\tau_{ff} = W\varphi(x)$ 。部署阶段冻结深层特征提取器, 仅以带遗忘因子的递推最小二乘在线更新末层权重 W 。每个更新周期利用测量关节角与角速度、当前关节加速度(仿真中取真值, 真机上需有测量差分估计, 见第 6 节)与实际施加力矩构成监督对 (φ_k, y_k) , 更新律为:

$$K_k = \frac{P_k - 1\varphi_k}{\lambda + \varphi_k^T P_k - 1\varphi_k} \quad (6)$$

$$W_k = W_{k-1} + (y_k - W_{k-1}\phi_k)K_k^T \quad (7)$$

$$P_k = (P_{k-1} - K_k\phi_k^T P_{k-1})/\lambda \quad (8)$$

其中, 遗忘因子 $\lambda=0.998$, $P_0=10I$, 更新频率 200 Hz。该机制的优势在于: 末层更新为凸问题, 不存在灾难性遗忘深层特征的风险; 单次更新仅涉及 129 维参数的向量与秩一矩阵运算, 计算代价与控制周期兼容(实测单步摊销约 160 μs)。当负载等动力学参数发生变化时, RLS 通过遗忘因子快速跟踪新的最优末层权重, 实现在线补偿。

4. 实验设置

所有实验均在上述高保真数值仿真平台(Python 3.8/PyTorch 2.4/NumPy)中完成, 这一设定保证了动力学真值可控、扰动可精确复现, 便于对方法性能进行严格归因分析。对比方法包括: (1) PID: 工业标准基线, 取 $K_p = \text{diag}(160, 110)$ 、 $K_i = \text{diag}(60, 40)$ 、 $K_d = \text{diag}(22, 14)$, 积分误差限幅 ± 2 , 增益经手动整定至临界振荡的约 60% (齐格勒-尼科尔斯准则微调); (2) CTC: 计算力矩控制, 使用含 $\pm 15\%$ 惯性参数误差(连杆长度视为精确已知)且不含摩擦项的名义模型, 代表“基于不完美物理模型”的方法, 增益取 $K_p = \text{diag}(400, 400)$ 、 $K_d = \text{diag}(40, 40)$; (3) NN-FF: 本文学习前馈复合控制; (4) ANN-FF: 在 NN-FF 基础上增加 RLS 末层自适应。

测试轨迹共六种(圆形、“8”字形、利萨如、五角星、圆角方形、随机样条), 均未在训练数据中出现。每种条件重复 5 或 6 个随机噪声种子(轨迹跟踪与泛化实验为 6 个种子, 鲁棒性与负载突变在线自适应实验为 5 个种子, 具体见各图注)。除特别说明外, 每次运行时长为 10 s。评价指标: 任务空间跟踪均方根误差(RMSE, mm)、控制能量 $\int \|\tau\|^2 dt$ 及力矩平滑度(力矩变化率绝对均值)。组间差异采用 Welch t 检验(双尾)。

5. 结果与分析

5.1. 逆动力学模型学习效果

逆动力学模型的学习效果见图 2, 图 2(a)给出 5 个随机种子下的训练/验证损失曲线: 验证损失随训练稳定下降且与训练损失保持同量级, 未出现过拟合。5 个种子的验证集力矩预测 RMSE 为 0.087 ± 0.004 N·m, 其中最优种子达 0.080 N·m; 而含 15% 参数误差、无摩擦项的名义刚体模型为 1.00 N·m, 学习模型将预测误差降低约 91%~92%, 接近一个数量级。后续图表与控制实验均采用验证 RMSE 最优的种子所对应的模型(即误差 0.080 N·m 的模型)作为主模型。两关节的预测-真值散点紧贴对角线(图 2(b)、图 2(c)), 决定系数分别达 $R^2=0.9987$ 与 0.9984 ; 分关节的预测 RMSE (图 2(f))关节 1 为 0.096 N·m、关节 2 为 0.060 N·m。误差分布对比(图 2(d))显示名义模型存在明显的重尾与偏置, 而学习模型误差集中于零附近。值得注意的是, 名义模型误差随关节速度显著增大(图 2(e)), 这正是未建模摩擦的特征, 而学习模型在全速度域内误差平稳, 表明网络成功捕获了摩擦的非线性速度依赖。

5.2. 轨迹跟踪性能

四种控制器的轨迹跟踪性能对比如图 3 所示。PID 因缺乏动力学前馈, 实际轨迹存在明显滞后与形变(图 3(a)、图 3(b)); CTC 受参数误差与未建模摩擦拖累, 误差虽较 PID 降低但仍有残余系统偏差。NN-FF 的跟踪轨迹与参考几乎重合: 在“8”字形轨迹上其 RMSE 为 0.29 mm, 较 PID (15.95 mm)与 CTC (9.07 mm)分别降低 98%与 97% (Welch t 检验 $p < 0.001$, 图 3(e))。误差时程(图 3(c))显示 NN-FF/ANN-FF 在起始瞬态(约 1 s)后全程维持亚毫米量级; 关节 1 的角度跟踪细节(图 3(d))中, NN-FF 的曲线与参考几乎不可分辨。力矩曲线(图 3(f))显示 NN-FF/ANN-FF 的输出由平滑前馈与小幅噪声抖动构成, 不存在 PID 那

样的滞后与低频振荡；但按力矩变化率绝对均值衡量，其平滑度(约 48 N·m/s)与 PID 相当、逊于 CTC (约 28 N·m/s，其高增益修正项经惯性矩阵衰减，力矩抖动更小)，见图 8(a)的 Smoothness 维度。




Figure 2. Learning performance of the inverse-dynamics model. (a) Training and validation loss curves. (b) (c) Density scatter of predicted vs. true torque for Joint 1 and Joint 2, with coefficient of determination R^2 ; the dashed line is the ideal diagonal. (d) Comparison of prediction-error distributions between the learned model and the nominal rigid-body model. (e) Prediction error as a function of peak joint velocity: the nominal model's error grows with velocity, revealing unmodeled friction, while the learned model remains stable across the full velocity range. (f) Per-joint torque-prediction RMSE comparison

图 2. 逆动力学模型的学习效果。(a) 训练与验证损失曲线。(b) (c) 关节 1 与关节 2 的预测力矩 - 真实力矩密度散点及决定系数 R^2 ，虚线为理想对角线。(d) 学习模型与名义刚体模型的预测误差分布对比。(e) 预测误差随峰值关节速度的变化：名义模型误差随速度增大，暴露未建模摩擦；学习模型全域平稳。(f) 分关节力矩预测 RMSE 对比




Figure 3. Trajectory-tracking performance comparison of the four controllers. (a) (b) Actual end-effector paths for the circular and “figure-eight”-shaped trajectories. (c) Task-space error time history for the “figure-eight”-shaped trajectory. (d) Detail of Joint-1 angle tracking. (e) Task-space RMSE for the two trajectories. (f) Joint-1 torque output comparison

图 3. 四种控制器的轨迹跟踪性能对比。(a) (b) 圆形与“8”字形轨迹的末端实际路径。(c) “8”字形轨迹的任务空间误差时程。(d) 关节 1 角度跟踪细节。(e) 两种轨迹下的任务空间 RMSE。(f) 关节 1 力矩输出对比

5.3. 模型容量与数据量消融

网络设计选择的影响见图 4 (除数据量扫描外, 各消融配置统一采用 2×10^4 训练样本与 40 个训练回合以控制计算开销, 故其绝对误差高于主模型, 但容量 - 精度趋势不受影响)。预测精度随隐层宽度增大而单调改善(图 4(a)): 宽度 8 时 RMSE 为 $0.39 \text{ N}\cdot\text{m}$, 128 时降至 $0.242 \text{ N}\cdot\text{m}$, 256 时为 $0.204 \text{ N}\cdot\text{m}$; 128 之后参数量需增至约 3.8 倍, 误差仅再降约 16%。数据量的影响更为显著(图 4(b)): 500 样本时模型($0.42 \text{ N}\cdot\text{m}$)虽已明显优于名义模型($1.00 \text{ N}\cdot\text{m}$), 但精度仍有限, 2000 样本以上误差随样本量近幂律下降, 3.2×10^4 样本时达 $0.205 \text{ N}\cdot\text{m}$ 。深度超过 2 层后收益递减(图 4(c))。以参数量为横轴的汇总(图 4(d))表明本文所选 2×128 结构位于精度 - 容量权衡的拐点附近, 兼顾了拟合能力与实时推理开销。




Figure 4. Ablation experiments on model capacity and data volume. (a) Torque-prediction RMSE as a function of hidden-layer width. (b) RMSE as a function of training sample size. (c) RMSE as a function of network depth. (d) Summary of the width and depth sweeps on the “parameter-count vs. accuracy” plane

图 4. 模型容量与数据量消融实验。(a) 力矩预测 RMSE 随隐层宽度的变化。(b) RMSE 随训练样本量的变化。(c) RMSE 随网络深度的变化。(d) 宽度扫描与深度扫描在“参数量 - 精度”平面上的汇总

5.4. 鲁棒性分析

三类未见扰动下的性能退化评估见图 5。负载扫描(图 5(a))中, 随着末端负载从 0 增至 1.0 kg , NN-FF 误差从 0.29 mm 升至 11.91 mm , 离线模型无法感知动力学变化; 而 ANN-FF 凭借在线适应将 1.0 kg 负载下的误差控制在 0.24 mm , 仅为冻结模型的 2%。传感噪声扫描(图 5(b))中, PID 与 CTC 的误差对噪声几乎不敏感(4 倍噪声下 RMSE 变化不足 0.1%, 其误差由模型失配主导), NN-FF/ANN-FF 则随噪声小幅上升(4 倍噪声下分别增大 2.0%与 6.1%), 表明测量噪声会部分侵蚀学习前馈的精度优势, 但其在 4 倍噪声下的绝对误差($0.29/0.24 \text{ mm}$)仍远低于两个基线。摩擦增大 50% (图 5(c))使 NN-FF 误差升至 1.11 mm (3.9 倍, 相对退化最大, 因学习模型完整记住了名义摩擦), CTC 升至 13.29 mm (1.5 倍, 绝对增量最大), PID 几乎不受影响(1.01 倍), ANN-FF 则凭借在线适应将误差控制在 0.27 mm (1.2 倍)。归一化退化热图(图 5(d))综合表明 ANN-FF 在所有扰动下的性能退化最小。

5.5. 对未见轨迹的泛化能力

由于训练数据仅来自随机多正弦激励, 六种测试轨迹对模型而言均为“零样本”任务。对未见测试轨迹的泛化能力见图 6: 图 6(a)~(d)展示了四种几何特征迥异的轨迹(利萨如、五角星、圆角方形、随机样条)上的跟踪效果: NN-FF 在高曲率的星形尖角与方形转角处依然紧贴参考。跨轨迹汇总(图 6(e))显示 NN-FF/ANN-FF 在全部六种轨迹上稳定优于两个基线约一个数量级, 平均 RMSE 为 0.49 mm (PID: 14.86 mm ; CTC: 7.85 mm), 各控制器在六种测试轨迹下的逐轨迹 RMSE 见表 3, 证明学习模型捕获的是状态空间中

的动力学映射本身, 而非对特定轨迹的记忆。




Figure 5. Robustness analysis (“figure-eight”-shaped trajectory, 5 seeds). (a) RMSE as a function of end-effector payload mass. (b) RMSE as a function of sensor-noise amplification factor. (c) RMSE comparison under nominal friction (light) vs. 50% increased friction (dark). (d) Heatmap of the RMSE degradation factor relative to the undisturbed baseline across the different perturbation conditions

图 5. 鲁棒性分析(“8”字形轨迹, 5 个种子)。 (a) RMSE 随末端负载质量的变化。 (b) RMSE 随传感噪声放大倍数的变化。 (c) 名义摩擦(浅色)与摩擦增大 50% (深色)下的 RMSE 对比。 (d) 各扰动条件下 RMSE 相对无扰动基准的退化倍数热图




Figure 6. Generalization to unseen test trajectories. (a)~(d) End-effector paths for the Lissajous, five-pointed-star, rounded-square, and random-spline trajectories. (e) Summary of task-space RMSE across the six trajectories $\times$ four controllers

图 6. 对未见测试轨迹的泛化能力。 (a)~(d) 利萨如、五角星、圆角方形与随机样条轨迹的末端路径。 (e) 六种轨迹 $\times$ 四种控制器的任务空间 RMSE 汇总

5.6. 负载突变下的在线自适应

机械臂在 $t = 6$ s 突然抓取 1.0 kg 工件的负载突变场景见图 7 (运行总时长 18 s)。负载突变瞬间, 两种学习控制器误差均跳升(图 7(a)、图 7(b)); 冻结的 NN-FF 此后维持在 5.49 mm 的退化水平无法恢复, 而 ANN-FF 的 RLS 机制在约 3~4 s 内完成末层权重的主要重新整定(图 7(d)), 误差随后在波动中回落, 约 4

s 后降至毫米量级, 并在稳态阶段(图 7(c)的最后 3 s 窗口)收敛至 1.01 mm, 仅为冻结模型的 18%。权重变化范数在突变后快速增长, 随后在 60~95 范围内小幅波动, 这与遗忘因子 0.998 所对应的约 2.5 s 有效记忆长度一致(RLS 持续跟踪最新数据所致)。PID 因本身不依赖模型, 对负载变化相对不敏感, 但其稳态误差(10.5 mm)仍远高于 ANN-FF。




Figure 7. Online adaptation under a sudden payload change ($t = 6$ s, +1.0 kg). (a) Tracking-error time history. (b) Detailed comparison from 1 s before to 5 s after the change. (c) RMSE before the change, during the 0~3 s window after the change, and at steady state. (d) Frobenius norm of the adaptive output-layer weights relative to their initial values over time

图 7. 负载突变($t = 6$ s, +1.0 kg)下的在线自适应。(a) 跟踪误差时程。(b) 突变前 1 s 至突变后 5 s 的细节对比。(c) 突变前、突变后 0~3 s 与稳态阶段的 RMSE。(d) 自适应末层权重相对初值的 Frobenius 范数变化

5.7. 综合性能评估

图 8 从精度、泛化、鲁棒性、能量、平滑度与计算开销六个维度对四种控制器进行归一化综合评估。ANN-FF 在几乎所有维度上覆盖面积最大(图 8(a)); 全条件误差分布(图 8(b))显示其中位数与离散度均最优。精度 - 计算开销平面(图 8(c))表明两种学习控制器均以远低于控制周期的在线开销换取了一个数量级的精度提升: NN-FF 的网络推理(约 256 μ s)沿参考轨迹离线一次完成, 在线单步仅查表加 PD 运算(约 2.3 μ s); ANN-FF 因需在线更新末层权重, 单步摊销约 160 μ s; 能量 - 精度平面(图 8(d))则显示该精度增益并未以额外控制能量为代价: 前馈补偿本质上是“用对模型”而非“用大力气”。




Figure 8. Comprehensive performance evaluation. (a) Six-dimensional normalized performance radar chart. (b) RMSE distribution across all experimental conditions. (c) Trade-off between mean RMSE and per-step control computation time. (d) Relationship between control energy and RMSE

图 8. 综合性能评估。(a) 六维归一化性能雷达图。(b) 全部实验条件下的 RMSE 分布。(c) 平均 RMSE 与单步控制计算耗时的权衡。(d) 控制能量与 RMSE 的关系

Table 3. Task-space tracking RMSE of the four controllers on the six test trajectories
表 3. 各控制器在六种测试轨迹下的任务空间 RMSE

方法	圆形	“8”字形	利萨如	五角星	圆角方形	随机样条
PID	15.96	15.95	14.61	15.14	16.25	11.25
CTC	8.62	9.07	8.85	7.05	7.59	5.91
NN-FF	0.46	0.29	0.38	0.40	0.79	0.61
ANN-FF	0.39	0.23	0.34	0.25	0.56	0.24

6. 讨论

本研究的全部实验在高保真数值仿真中完成，其价值在于提供了动力学真值可控、扰动可精确复现的受控实验环境，从而能够对“学习精度→控制精度→鲁棒性”的因果链条进行严格归因。但仿真与真实系统之间仍存在差距：真实机械臂的关节柔性、传动间隙、力矩环带宽限制以及温漂等因素未被建模，向物理平台迁移时需结合域随机化或在真机数据上微调。其次，加速度信号在真实系统中须由差分与滤波获得，其噪声水平高于仿真设定，可能降低在线自适应的监督质量；采用力矩传感器直接测量实际施加力矩、或降低更新频率是可行的缓解手段。此外，本文平台为二自由度机械臂，将框架扩展至六/七自由度时，逆动力学映射维度升高，所需数据量与网络容量将相应增长，结合拉格朗日结构先验有望进一步降低样本需求。最后，RLS 末层自适应虽然高效，但其补偿能力受限于冻结特征的表达范围，面对与训练分布差异极大的工况(如末端接触作业)可能需要更深层次的在线更新与稳定性保障机制。

7. 结论

本文提出并系统评估了一种“深度学习逆动力学前馈 + RLS 末层在线自适应”的机械臂轨迹跟踪控制框架。仿真实验表明：(1) 从闭环激励数据学习的 MLP 逆动力学模型将力矩预测误差较名义刚体模型降低约 91%~92%，并成功捕获非线性摩擦特性；(2) 以该模型构建的 NN-FF 控制器在六种未见轨迹上将跟踪误差较 PID 降低约一个数量级(平均 0.49 mm 对 14.86 mm)，且不增加控制能量；(3) RLS 末层自适应使控制器在 1.0 kg 负载突变后约 4 s 内误差回落至毫米量级，稳态误差(1.01 mm)较冻结模型(5.49 mm)降低约 82%；(4) 控制律在线计算开销低(NN-FF 单步约 2.3 μ s，ANN-FF 平均约 160 μ s)，均满足 1 kHz 实时性要求。后续工作将聚焦于物理样机验证、高自由度扩展以及带稳定性保证的深层在线学习。

数据与代码可用性

本文的全部仿真代码、训练数据与结果数据可向通讯作者合理索取。

AI 声明

本文写作过程中使用了人工智能工具(DeepSeek, GLM)辅助代码编写与文字润色，所有内容均经作者核查，作者对全文内容负全部责任。

参考文献

[1] 张成浩, 杨圣慧, 夏川迪, 等. 双臂葡萄采摘机器人手眼布局与底盘步进优化[J/OL]. 智慧农业(中英文): 1-11. <https://link.cnki.net/urlid/10.1681.S.20260828.1539.002>, 2026-08-31.

[2] 李涛, 范箴, 施绍武, 等. 基于机械手臂技术对有源医疗器械检测方法的应用[J]. 计量与测试技术, 2026, 52(8): 169-173.

[3] 张航, 郑正鼎, 高全杰, 等. 面向砌筑机器人机械臂路径规划的改进 Q-RRT*算法[J]. 工程设计学报, 2026, 33(4):

- 491-500.
- [4] 李森, 库祥臣, 朱二州, 等. 应用混合迭代法的机器人动力学参数辨识[J]. 现代制造工程, 2026(7): 33-40+85.
 - [5] 刘妮, 张永林, 吴梦宇. 水下机械臂双边遥操作力反馈-位置反馈混合控制研究[J]. 计算机应用与软件, 2025, 42(8): 132-138.
 - [6] Slotine, J.E. and Weiping Li, (1987) On the Adaptive Control of Robot Manipulators. *The International Journal of Robotics Research*, **6**, 49-59. <https://doi.org/10.1177/027836498700600303>
 - [7] Nguyen-Tuong, D. and Peters, J. (2011) Model Learning for Robot Control: A Survey. *Cognitive Processing*, **12**, 319-340. <https://doi.org/10.1007/s10339-011-0404-1>
 - [8] Lewis, F.L., Yesildirek, A. and Kai Liu, (1996) Multilayer Neural-Net Robot Controller with Guaranteed Tracking Performance. *IEEE Transactions on Neural Networks*, **7**, 388-399. <https://doi.org/10.1109/72.485674>
 - [9] Hornik, K., Stinchcombe, M. and White, H. (1989) Multilayer Feedforward Networks Are Universal Approximators. *Neural Networks*, **2**, 359-366. [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8)
 - [10] Peng, X.B., Andrychowicz, M., Zaremba, W. and Abbeel, P. (2018) Sim-to-Real Transfer of Robotic Control with Dynamics Randomization. 2018 *IEEE International Conference on Robotics and Automation (ICRA)*, Brisbane, 21-25 May 2018, 3803-3810. <https://doi.org/10.1109/icra.2018.8460528>
 - [11] 张相胜, 陈佳明. 一种改进的机器人动力学参数辨识方法[J]. 江苏大学学报(自然科学版), 2025, 46(1): 50-56.
 - [12] 孙鹏, 葛梦虎, 芮超, 等. 混联双足机械腿的动力学建模与参数辨识[J]. 机械工程学报, 2026, 62(5): 192-203.
 - [13] 张涛, 何家豪, 施永平, 等. 基于改进 Stribeck 摩擦的协作机器人动力学参数辨识[J]. 机械工程学报, 2026, 62(5): 151-167.
 - [14] Simpkins, A. (2012) System Identification: Theory for the User, 2nd Edition (Ljung, L.; 1999) [On the Shelf]. *IEEE Robotics & Automation Magazine*, **19**, 95-96. <https://doi.org/10.1109/mra.2012.2192817>
 - [15] Lutter, M., Ritter, C. and Peters, J. (2019) Deep Lagrangian Networks: Using Physics as Model Prior for Deep Learning. arXiv: 1907.04490.
 - [16] Kingma, D.P. and Ba, J. (2014) Adam: A method for Stochastic Optimization. arXiv: 1412.6980.