

面向医疗机器人机械臂的自适应LSTM参数标定方法

洪伟, 金路凯

引用本文:

洪伟, 金路凯. 面向医疗机器人机械臂的自适应LSTM参数标定方法[J]. 中国医疗器械杂志, 2025, 49(5): 473-478.

HONG Wei, JIN Lukai. An Adaptive LSTM Method for Parameter Calibration of Medical Robotic Arms[J]. *Chinese Journal of Medical Instrumentation*, 2025, 49(5): 473-478.

<https://doi.org/10.12455/j.issn.1671-7104.250121>

收稿日期: 2025-02-24

您可能感兴趣的其他文章

Articles you may be interested in

一种基于光学导航的穿刺机器人无标定定位方法

Uncalibrated Positioning Method for Puncture Robots Based on Optical Navigation

中国医疗器械杂志. 2023, 47(6): 591-597 <http://doi.org/10.3969/j.issn.1671-7104.2023.06.001>

基于踝关节康复机器人的自主自适应控制策略

Voluntary and Adaptive Control Strategy for Ankle Rehabilitation Robot

中国医疗器械杂志. 2024, 48(4): 385-391 <http://doi.org/10.12455/j.issn.1671-7104.230642>

基于残差神经网络、双向长短期记忆网络和注意力机制的肠鸣音检测方法研究

Bowel Sounds Detection Method Based on ResNet-BiLSTM and Attention Mechanism

中国医疗器械杂志. 2024, 48(5): 498-504 <http://doi.org/10.12455/j.issn.1671-7104.240043>

手术机器人关键技术综述与优化探讨

Overview of Key Technologies in Surgical Robots and Optimization Discussions

中国医疗器械杂志. 2024, 48(5): 505-511 <http://doi.org/10.12455/j.issn.1671-7104.240107>

医疗服务机器人研究进展综述

Review of Research Advances in Medical Service Robotics

中国医疗器械杂志. 2023, 47(6): 645-650,568 <http://doi.org/10.3969/j.issn.1671-7104.2023.06.011>

机械通气人机不同步自动检测算法综述

A Review on Automatic Detection Algorithm for Patient-Ventilator Asynchrony during Mechanical Ventilation

中国医疗器械杂志. 2024, 48(1): 44-50 <http://doi.org/10.3969/j.issn.1671-7104.230209>



微信公众号



网站二维码

文章编号: 1671-7104(2025)05-0473-06

面向医疗机器人机械臂的自适应LSTM参数标定方法

【作者】 洪伟^{1,2,3}, 金路凯^{1,2,3}

1 上海市医疗器械检验研究院, 上海市, 201318

2 国家药品监督管理局医用电气设备重点实验室, 上海市, 201318

3 上海市医疗器械质量检验检测中心, 上海市, 201318

【摘要】 医疗机器人机械臂在标定过程中存在多源、非线性误差, 使得传统数学建模方法难以全面刻画其系统误差特性, 从而限制了标定精度的进一步提升。该文建立了机器人机械臂参数误差辨识模型, 并提出一种基于自适应长短时记忆 (ALSTM) 神经网络的标定方法。该方法引入粒子群优化算法 (PSO) 对LSTM神经网络的各层权重进行优化, 以更有效地拟合机器人机械臂运动学误差, 进而获得更为准确的D-H参数。在HSR-JR680机器人机械臂标定系统中采集110组实验数据进行验证。实验结果表明, ALSTM模型在均方根误差 (RMSE) 方面较传统标定方法降低了23.07%~80.39%, 收敛时间较普通LSTM模型缩短了32.44%, 所获得的最优D-H参数符合医疗机器人机械臂对高精度标定的需求, 验证了该方法的有效性。

【关键词】 医疗机器人; 自适应长短时记忆神经网络; 粒子群优化算法; 运动学参数标定

【中图分类号】 R197.39; TP242

【文献标志码】 A

doi: 10.12455/j.issn.1671-7104.250121

An Adaptive LSTM Method for Parameter Calibration of Medical Robotic Arms

【 Authors 】 HONG Wei^{1,2,3}, JIN Lukai^{1,2,3}

1 Shanghai Institute of Medical Device Testing, Shanghai, 201318

2 NMPA Key Laboratory for Medical Electrical Equipment, Shanghai, 201318

3 Shanghai Quality Inspection and Testing Center for Medical Robots, Shanghai, 201318

【 Abstract 】 Medical robotic arm often encounters multi-source and nonlinear errors during the calibration process, making it difficult for traditional mathematical modeling methods to fully characterize system error features, thereby limiting further improvement in calibration accuracy. In this study, a robotic arm parameter error identification model is established, and a calibration method based on an adaptive long short-term memory (ALSTM) neural network is proposed. The method incorporates a particle swarm optimization (PSO) algorithm to optimize the weights of each layer of the LSTM neural network, enabling more effective fitting of robotic arm kinematic errors and ultimately yielding more accurate Denavit-Hartenberg (D-H) parameters. To validate the proposed approach, 110 sets of experimental data are collected using the HSR-JR680 robotic arm calibration system. Experimental results demonstrate that the ALSTM model reduces the root mean square error (RMSE) by 23.07%~80.39% compared to traditional calibration methods, and shortens the convergence time by 32.44% compared to a standard LSTM model. The optimized D-H parameters obtained meet the high-precision calibration requirements of medical robotic arm, confirming the effectiveness of the proposed method.

【Key words】 medical robot, adaptive long short-term memory (ALSTM) neural network, particle swarm optimization (PSO), kinematic parameter calibration

0 引言

近年来, 机器人以安全性高、通用性强等优势

成为智能医疗领域的关键设备^[1]。对于医疗服务机器人而言, 其机械臂的绝对定位精度是一项重要的指标^[2]。然而, 由于制造误差和装配误差等因素的影响^[3], 机器人机械臂定位精度下降, 无法满足高精度定位要求。因此, 研究机器人机械臂标定技

收稿日期: 2025-02-24

作者简介: 洪伟, E-mail: hwcmtc@163.com

通信作者: 金路凯, E-mail: lukaijinmeche@163.com

术, 对其参数误差进行标定, 提升定位精度, 是机器人应用于医疗领域的重要课题^[4]。

现有的机器人机械臂定位精度标定仪器主要有激光跟踪仪^[5]、球杆仪^[6]、电子经纬仪^[7]等。这些仪器具有精度高、测量量程大、抗干扰能力强等优点, 但价格昂贵, 需要专业人员维护和操作, 无法满足医疗机器人标定需求。因此, 建立机器人的运动学模型^[8], 研究泛化能力强、计算效率高、标定精度高的算法, 开发一套高效的机器人标定系统, 实现医疗机器人的快速精准标定, 对于推动机器人在医疗领域的全面应用具有重大意义。

近年来, 神经网络^[9]在机器人标定与误差补偿领域得到广泛应用, 尤其在应对复杂非线性误差建模方面展现出显著优势。WANG等^[10]提出一种综合考虑几何误差、关节柔性和外部载荷的标定方法, 利用反向传播神经网络 (back propagation neural network, BPNN) 优化控制器角度输入, 使ABB IRB 6640机器人的定位误差从0.85 mm降低至0.23 mm。GAO等^[11]结合BPNN与粒子群优化算法 (particle swarm optimization, PSO), 联合搜索最优几何误差参数以提升标定精度。HWANG等^[12]则采用递归神经网络对达·芬奇手术机器人的误差参数进行建模补偿, 将跟踪误差从2.96 mm显著降至0.65 mm。此外, CHEN等^[13]基于径向基函数神经网络 (radial basis function neural network, RBFNN) 结合误差相似度分析, 实现了误差平均降低91.99%、最大误差降低85.41%的补偿效果。WANG等^[14]和SONG等^[15]分别通过人工神经网络模型对机器人的非几何误差进行补偿, 有效提高了其静态位姿精度。LE等^[16]亦提出一种新型神经网络结构, 将最大位置误差控制在1.01 mm以内。

尽管上述研究在精度提升方面取得了一定成效, 但当前神经网络在医疗机器人标定中的应用仍存在不足, 多数网络结构为静态设计, 缺乏对不同系统动态特性的自适应能力; 部分算法对初始权重依赖较大, 易陷入局部最优, 影响优化结果稳定性。基于此, 本文提出一种融合粒子群优化的自适应长短时记忆 (adaptive long short-term memory, ALSTM) 神经网络模型, 将粒子群优化算法 (PSO) 应用于普通长短时记忆 (long short-term memory, LSTM) 神经网络^[17-18], 优化各层网络权重。ALSTM算法不仅能解决长序列中遗忘和长距离依赖等问题, 还能解决网络需要更新的权重较多、梯度信息计算复杂的问题。该算法结合运动学参数误差辨识模型, 精准

辨识机器人机械臂的非线性误差^[19], 以得到真实的机械臂系统性误差参数^[20], 在医疗诊断等领域具有良好的应用前景。

1 自适应长短时记忆神经网络

1.1 参数误差辨识

1955年, Denavit和Hartenberg提出了基于齐次变换矩阵的D-H (Denavit-Hartenberg) 模型, 机电耦合效应通过误差建模方式等效地反映在D-H参数中。本文根据理论拉线长度与实际拉线长度之差, 建立了机器人运动学参数误差辨识模型:

$$f(w) = \frac{1}{2n} \left\| \sum_{i=1}^n Y_i - Y'_i \right\|_2^2 \quad (1)$$

式中: f 是目标函数, w 是运动学参数, n 是样本数量, Y_i 是测量拉线长度, Y'_i 是名义拉线长度。由于其D-H参数与末端位置响应之间是一个复杂的非线性问题, 因此需要选择合适的优化算法来进行D-H参数求解。

1.2 长短时记忆神经网络

长短时记忆神经网络由遗忘门、输入门、输出门和一个记忆单元组成。

遗忘门 f_t 用来删除上一时刻记忆单元中的部分信息, 保留一些信息到当前记忆单元中。接近于0表示需要忘记, 接近于1表示需要保留:

$$f_t = \text{Sigmoid}(w_f \cdot [x_t, h_{t-1}] + b_f) \quad (2)$$

式中: w_f 为权重, b_f 为偏置, h_t 为当前时刻外部状态, h_{t-1} 为前一时刻外部状态。

输入门 i_t 指由Sigmoid函数决定更新的参数, 然后通过tanh层创造出一个候选量, 并将其加入记忆单元, 从而得到记忆单元的更新信息:

$$\begin{cases} i_t = \text{Sigmoid}(w_i \cdot [x_t, h_{t-1}] + b_i) \\ C'_t = \text{tanh}(w_c \cdot [x_t, h_{t-1}] + b_c) \\ C_t = f_t \cdot C_{t-1} + i_t \cdot C'_t \end{cases} \quad (3)$$

式中: w_i 和 w_c 分别为输入门、神经元状态的权重。 x_t 为当前时刻输入, b_i 和 b_c 为偏置, C_t 为当前时刻记忆单元, C_{t-1} 为前一时刻记忆单元, C'_t 为信息候选状态。

最后经过输出门, 由Sigmoid层选择输出信息。利用tanh层进行变换后输出结果。控制当前时刻输出的信息:

$$\begin{cases} o_t = \text{Sigmoid}(w_o \cdot [x_t, h_{t-1}] + b_o) \\ h_t = o_t \cdot \text{tanh}(C_t) \end{cases} \quad (4)$$

式中: w_o 为输出门的权重, b_o 为偏置。利用“门”控制网络的长时记忆和短时记忆避免了传统RNN

处理长序列时的梯度消失和爆炸问题。

1.3 粒子群优化算法

粒子群优化算法模仿自然界鱼鸟群体行为进行迭代搜寻全局最优解，该算法中粒子的位置和速度的迭代计算式为：

$$\begin{cases} V_{i,t+1} = wV_{i,t} + c_1r_1(p_i^{\text{best}} - x_{i,t}) + \\ \quad c_2r_2(g_i^{\text{best}} - x_{i,t}) \\ x_{i,t+1} = x_{i,t} + \lambda_1 V_{i,t+1} \end{cases} \quad (5)$$

式中： w 是惯性权重，实时控制粒子的搜索范围。 c_1 和 c_2 是加速度常数。 λ_1 是速度的系数， r_1 和 r_2 是满足均匀分布 $[0,1]$ 范围内的随机数。 $V_{i,t}$ 表示 t 时刻第 i 个粒子的速度， $V_{i,t+1}$ 表示 $t+1$ 时刻第 i 个粒子的速度。 $x_{i,t}$ 、 $x_{i,t+1}$ 分别表示第 i 个粒子在 t 、 $t+1$ 时刻的位置。 p_i^{best} 是第 i 个粒子经历过的最好的位置， g_i^{best} 是种群经历过的最好位置。粒子群优化算法通过优化长短时记忆神经网络的权重，加快了网络收敛速度。

1.4 ALSTM算法设计和分析

ALSTM神经网络进行机器人标定的详细工作流程如表1所示。

表1 长短时记忆神经网络的流程

Tab.1 Process of long short-term memory neural network

操作	时间复杂度
输入：对应测量点的关节角度值 q_1-q_6 ，运动学参数名义值 w_0 ，拉线测量值 Y_i	
初始化 x_0, V_0	$\Theta(r)$
初始化 w_i, w_f, w_c, w_o, x_0	$\Theta(1)$
初始化 $w, c_1, c_2, \lambda_1, r_1, r_2$	$\Theta(1)$
初始化 $t=1, T_{\text{max}}=\text{max_iteration_count}$	$\Theta(1)$
while $t \leq T_{\text{max}}$ or 未达到收敛条件do	$\times t$
for $n=1$ to N	$\times N$
通过式 (5) 更新粒子速度 $V_{i,t}$ 和位置 $x_{i,t}$	$\Theta(1)$
通过式 (2) 计算遗忘门 f_t	$\Theta(1)$
通过式 (3) 计算输入门的 i_t, C_t 和 C'_t	$\Theta(1)$
通过式 (4) 计算输出门的 o_t 和 h_t	$\Theta(1)$
end for	—
$t = t+1$	$\Theta(1)$
end while	—
输出：最优的机器人关节角误差 $\Delta q_1-\Delta q_6$	

该方法的时间复杂度分析如下。

$$T_K = \Theta(r) + \Theta(T_{\text{max}} \times N) \approx \Theta(T_{\text{max}} \times N) \quad (6)$$

式(6)满足条件 $r \ll T_{\text{max}} \times N$ ，时间复杂可以省略低阶项 $\Theta(r)$ 。因此，基于自适应长短时记忆神经网络的机器人标定方法的时间复杂度由采集的样本数量和算法迭代次数决定，通过合理设置样本数量和算法迭代次数可以提升该网络的计算效率，加速机器人标定过程，节省时间成本。

2 实验与结果

2.1 实验数据采集

考虑到医疗机器人实验环境构建的复杂性及伦理审批等限制，实验采用重庆华数机器人有限公司生产的机器人HSR-JR680。它具备多自由度、高精度控制等特性，与当前医疗机器人中常用的臂式机械结构具有较高的相似性，能够作为验证算法有效性的可行替代方案。由于实际测量环境中存在噪声和操作误差，本实验对110组不同空间位置的样本进行采集。使用拉线编码器^[21-22]对这些点的位置进行测量，基于LabVIEW软件，设计了一款实时数据采集软件，采集机器人在任意位置的拉线长度，并将数据传送给实验使用的上位机。

2.2 实验方法

利用自适应长短时记忆神经网络对数据进行处理，获得标定后的D-H参数。实验过程中，选择其中100组样本进行训练，其余10组样本用于测试标定算法的最终输出以验证其性能。标定算法的训练终止条件为：①训练的迭代轮数达到了预设的最大值，如300；②连续两轮训练的均方根误差小于 10^{-3} 。

2.3 结果验证

将基于ALSTM神经网络的机器人非线性参数标定方法与常用的标定方法进行对比。常用的标定算法如下。

扩展卡尔曼滤波 (extended Kalman filter, EKF)^[23]：

①利用D-H转角增量和机器人运动学模型计算出理论末端位置，构建系统状态及初始误差协方差；②在预测步骤中，根据当前状态和运动学模型对系统状态进行递推，并对非线性模型在当前状态处进行一阶泰勒展开，获得线性化雅可比矩阵；③利用实际拉线测量数据计算观测残差，并根据测量噪声更新状态和协方差；④通过递归卡尔曼滤波实现状态校正，不断反馈修正后的D-H参数，逐步缩小理论末端位姿与实际测量之间的偏差。

粒子滤波 (particle filter, PF)^[19]：①根据D-H转角增量和运动学模型生成初始粒子集合，每个粒子代表一组可能的状态及其对应的理论末端位置；②根据实际拉线测量偏差计算每个粒子的权重，反映测量与理论位置的匹配程度；③采用重采样策略，淘汰权重低的粒子，保留和扩展高权重粒子；④利用状态转移函数更新所有粒子的状态，跟踪运动学动态变化；⑤通过多次迭代，粒子分布逐步收敛到最优状态，实现对D-H参数的自适应修正和误差

差最小化。

PSO^[18]: ①通过D-H转角增量计算出理论末端位置, 并以实际拉线测量偏差构造目标函数; ②初始化一群粒子, 每个粒子代表一种D-H参数候选解, 并赋予初始速度; ③每个粒子依据自身历史最优解与全局最优解调整速度和位置, 逐步搜索参数空间; ④在每次迭代中计算目标函数值, 更新粒子局部和全局最优信息; ⑤循环迭代直至达到预设终止条件或目标函数收敛; ⑥获得最优D-H参数配置, 从而使理论与实际误差降至最低, 提高运动学精度。

RBFNN^[13]: ①利用D-H转角增量计算理论末端位置, 将其与实际拉线测量结果的差值作为训练样本; ②设计网络架构, 选用高斯径向基函数作为隐层激活函数, 对输入数据进行局部响应映射; ③采用反向传播或最小二乘算法训练网络, 优化各隐节点的中心及宽度参数, 确保模型能拟合复杂的测量误差分布; ④训练完成后, 利用网络输出的补偿信号实时修正D-H参数引起的误差, 实现运动学误差在线补偿与精度提升。

LSTM^[17]: ①基于D-H转角增量推演计算理论末端位置, 并将连续时刻实际测量偏差构成时间序列输入; ②构建含有遗忘门、输入门和输出门的LSTM网络, 提取输入误差序列中潜藏的动态变化特征; ③通过反复训练使网络学习运动误差的时序预测规律; ④利用训练后的网络在线预测未来短时段误差, 并输出补偿信号; ⑤将补偿结果反馈至D-H参数调整模块, 实现理论与实际测量误差的实时减小和整体运动学精度的优化。

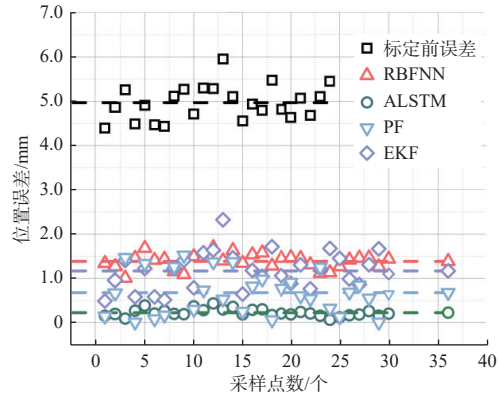
上述算法来源: <https://github.com/Lizhibing149/0183152/The-novel-code-for-CFE-calibrator>。

本文采用通用的D-H (Denavit-Hartenberg) 模型^[24], 进行机器人运动学建模, 描述机器人的运动参数:


$${}^{i-1}T = \text{Rot}(z, \theta_i) \text{Trans}(z, d_i) \text{Trans}(x, a_i) \text{Rot}(x, \alpha_i) \quad (7)$$
 式中: a_i 为连杆长度, d_i 为连杆偏距, α_i 为连杆扭转角, θ_i 为关节转角。 ${}^{i-1}T$ 是从机器人关节坐标系 $\{i-1\}$ 到机器人关节坐标系 $\{i\}$ 的转换矩阵。

图1比较了各个算法标定前后的机器人定位误差及不同标定方法的误差分布。

本文采用一些评价指标评估机器人标定方法的有效性: 均方根误差 (root mean square error, RMSE), 标准平均误差 (standard error of the mean, SEM) 和最大误差 (MAX)。



(a) RBFNN、ALSTM、EKF、PF算法标定误差和标定前误差比较
(a) Comparison of errors before calibration and calibration errors of RBFNN, ALSTM, EKF and PF algorithms



(b) 不同标定方法的误差分布
(b) Error distribution of different calibration methods

图1 标定后各个算法的误差比较
Fig.1 Error comparison of various algorithms after calibration

$$\left\{ \begin{array}{l} \text{RMSE} = \sqrt{(1/n) \sum_{i=1}^n (Y_i - Y'_i)^2} \\ \text{SEM} = \frac{1}{n} \sum_{i=1}^n |Y_i - Y'_i| \\ \text{MAX} = \max \{ |Y_i - Y'_i| \}, i = 1, 2, \dots, n \end{array} \right. \quad (8)$$

表2和表3展示了各个算法的标定精度和训练总时间花费, 表4给出了经过ALSTM标定后的最优D-H参数。

经过图1、表2、表3和表4的分析可得如下结论:

(1) 图1描述了110个样本中的30个样本经过各个算法标定后的误差比较, 虚线展示样本的误差平均值。经过ALSTM算法标定后, 机器人的定位误差明显降低且误差分布集中、波动小, 表现最优; ALSTM的箱体明显低于其他方法, 且离群点极少, 显示其标定精度和稳定性优势, 单因素方差分析显示, 不同算法之间的位置误差均值存在显著差异 ($F=68.77, P<0.001$)。

(2) 如表2所示, 不同算法在机器人系统的误差校准方面表现出了显著的性能差异。在未进行任何校准的初始状态下, 系统的定位误差较大, 且波

动性较强。经过不同算法的校准后，误差得到了不同程度的改善。传统的滤波算法如EKF和PF相较初始状态已显著降低误差，但稳定性仍不足。而智能优化算法如PSO和RBFNN在精度提升方面有所表现，但稳定性方面略显不足。LSTM在精度和稳定性上均优于传统方法，表现出较强的时序建模能力。而本研究所提出的ALSTM在所有算法中表现最为优越，达到了最低的RMSE，较传统模型降低了23.07%~80.39%，全面优于其他对比方法。当以STD和MAX为标定精度的度量标准时，也会获得类似结论。

表2 各个算法的精度
Tab.2 Calibration accuracy of various algorithms

算法	单位: mm		
	RMSE	SEM	MAX
标定前	5.26	5.34	6.31
EKF ^[23]	1.30	1.36	2.42
PF ^[19]	0.81	0.69	1.62
PSO ^[18]	0.73	0.67	1.43
RBFNN ^[13]	1.53	1.51	1.95
LSTM ^[17]	0.39	0.43	0.97
ALSTM	0.30	0.28	0.91

(3) 表3进一步比较了各类算法在参数校准过程中的迭代效率与计算开销。其从“平均迭代次数”和“总花费时间”两个维度进行分析，全面地评估算法在精度与效率之间的权衡能力。从结果看，尽管某些传统算法（EKF与PF）在平均迭代次数上表现较少，但其误差收敛能力较弱，且总耗时仍处于中等偏上水平。相较之下，进化优化算法PSO具备较强的搜索能力，但平均迭代次数高达32次，总耗时达138.95 s，效率明显不足。在神经网络模型中，RBFNN迭代次数最多，总耗时也相对较高，反映出其在收敛速度和资源消耗方面的劣势。相比之下，LSTM表现出良好的效率特性，但仍逊色于改进模型。ALSTM在保证精度的前提下，实现了迭代的高效收敛，且总耗时最低。这表明引入注意力机制可显著提高深度网络的学习效率与收敛速度，在精度与实时性之间达到优异平衡。

表3 各个算法的总时间
Tab.3 Total time cost of various algorithms

算法	平均迭代次数	总花费时间/s
EKF ^[23]	14	25.45
PF ^[19]	13	29.75
PSO ^[18]	32	138.95
RBFNN ^[13]	65	38.54
LSTM ^[17]	20	18.74
ALSTM	15	12.66

(4) 经过ALSTM标定后的最优D-H参数如表4所示，多数关节的扭转角 α_i 保持理论值不变，说明旋转轴间几何关系稳定。相比之下，关节转角 θ_i 在多个关节上存在较明显偏差，这些微小差异虽然量级不大，但对末端执行器的位置和姿态影响显著，表明标定后的姿态补偿精度极高。在线性参数方面，第三、第四、第六关节的偏距经精确修正后，更贴合实际结构尺寸，反映了机器人末端的实际偏移。这些均表明标定后的D-H参数显著提升了机器人的几何模型精度，减少了由制造公差和装配误差带来的累积偏差，符合机器人标定的参数要求。

表4 ALSTM 标定后的 D-H 参数
Tab.4 The obtained D-H parameters after ALSTM

关节 i	a_i /mm	d_i /mm	α_i /($^\circ$)	θ_i /($^\circ$)
1	250	653.5	-90	0.0184
2	900	0	0	-89.9203
3	-205	0	90	179.9962
4	0	1030.2	-90	0.0198
5	0	0	90	89.9428
6	0	200.6	0	-0.0092

后续工作将进一步拓展ALSTM方法在骨科辅助手术机器人、穿刺引导机器人上的应用与验证。

3 结论

本文针对机器人在医疗领域的定位精度问题，建立了参数误差辨识模型，提出了一种基于自适应长短时记忆神经网络的机器人标定方法，该方法实现了长短时记忆神经网络的权重自适应，求解最优D-H参数，得到了真实的机器人机械臂系统性误差参数。本文在HSR-JR680机器人上进行了大量实验验证，结果表明ALSTM有效减少了机器人定位误差，与现有标定算法相比，ALSTM具有更好的标定效果，模型的计算效率得以提升，且经过标定后的最优D-H参数符合机器人标定的参数要求。

标定方法还存在一些暂时性的问题，未来将进一步扩展实验平台，应用于医疗骨科辅助手术机器人、穿刺导航机器人等设备，验证其在不同结构、控制机制下的适应性与稳定性；同时进行轻量化部署，支持实际的在线标定应用。

参考文献

[1] LUO J B, CHEN S L, ZHANG C, et al. Efficient kinematic calibration for articulated robot based on unit dual quaternion[J]. *IEEE Trans Ind Inf*, 2023, 19(12): 11898-11909.
[2] WU L, CRAWFORD R, ROBERTS J. An analytic

- approach to converting POE parameters into D-H parameters for serial-link robots[J]. *IEEE Rob Autom Lett*, 2017, 2(4): 2174-2179.
- [3] SCHRÖER K, ALBRIGHT S L, GRETHLEIN M. Complete, minimal and model-continuous kinematic models for robot calibration[J]. *Robot CIM-INT Manuf*, 1997, 13(1): 73-85.
- [4] 白明, 张明路, 张赫, 等. 面向高精度显微手术机器人的RCM机械臂误差补偿方法[J]. *机械工程学报*, 2022, 58(18): 170-180.
- [5] SELAMI Y, TAO W, LV N, et al. Precise robot calibration method-based 3-D positioning and posture sensor[J]. *IEEE Sens J*, 2023, 23(7): 7741-7749.
- [6] WU Z M, GUO P, ZHANG Y, et al. Kinematic calibration for industrial robot using a telescoping ballbar[C]//*Intelligent Robotics and Applications*. Springer, Cham, 2020: 285-295.
- [7] FRACZEK J, BUSKO Z. Calibration of multi-robot system without and under load using electronic theodolites[C]//*Proceedings of the First Workshop on Robot Motion and Control. RoMoCo'99 (Cat. No. 99EX353)*. 1999: 71-75.
- [8] DENAVIT J, HARTENBERG R S. A kinematic notation for lower-pair mechanisms based on matrices[J]. *J Appl Mech*, 1955, 22(2): 215-221.
- [9] NGUYEN H N, ZHOU J, KANG H J. A calibration method for enhancing robot accuracy through integration of an extended Kalman filter algorithm and an artificial neural network[J]. *Neurocomputing*, 2015, 151: 996-1005.
- [10] WANG X, LI D S, WANG M M. Complete calibration of industrial robot with limited parameters and neural network[C]//*2016 IEEE International Symposium on Robotics and Intelligent Sensors (IRIS)*. 2016: 103-108.
- [11] GAO G, LIU F, SAN H J, et al. Hybrid optimal kinematic parameter identification for an industrial robot based on BPNN-PSO[J]. *Complex*, 2018(1): 4258676.
- [12] HWANG M, THANANJEYAN B, PARADIS S, et al. Efficiently calibrating cable-driven surgical robots with RGBD fiducial sensing and recurrent neural networks[J]. *IEEE Rob Autom Lett*, 2020: 4258676.
- [13] CHEN D D, WANG T M, YUAN P J, et al. A positional error compensation method for industrial robots combining error similarity and radial basis function neural network[J]. *Meas Sci Technol*, 2019, 30(12): 125010.
- [14] WANG Z R, CHEN Z W, WANG Y X, et al. A robot calibration method based on joint angle division and an artificial neural network[J]. *Math Probl Eng*, 2019: 9293484.
- [15] SONG Y B, TIAN W J, TIAN Y L, et al. Calibration of a Stewart platform by designing a robust joint compensator with artificial neural networks[J]. *Precis Eng*, 2022, 77: 375-384.
- [16] LE P N, KANG H J. Robot manipulator calibration using a model based identification technique and a neural network with the teaching learning-based optimization[J]. *IEEE Access*, 2020, 8: 105447-105454.
- [17] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neur Comput*, 1997, 9(8): 1735-1780.
- [18] CAO H Q, NGUYEN H X, NGUYEN T T, et al. Robot calibration method based on extended kalman filter-dual quantum behaved particle swarm optimization and adaptive neuro-fuzzy inference system[J]. *IEEE Access*, 2021, 9: 132558-132568.
- [19] DENG X, GE L Z, LI R F, et al. Research on the kinematic parameter calibration method of industrial robot based on LM and PF algorithm[C]//*2020 Chinese Control and Decision Conference (CCDC)*. 2020: 2198-2203.
- [20] JIANG K, YAN F, ZHANG H. Hydrothermal aging factor estimation for two-cell diesel-engine SCR systems via a dual time-scale unscented Kalman filter[J]. *IEEE Trans Ind Electron*, 2020, 67(1): 442-450.
- [21] 张得礼, 王珉, 朱煜, 等. 基于单拉线编码器的机器人几何标定方法[M]. 南京: 南京航空航天大学, 2018.
- [22] MESSAY T, ORDÓÑEZ R, MARCIL E. Computationally efficient and robust kinematic calibration methodologies and their application to industrial robots[J]. *Robot CIM-INT Manuf*, 2016, 37: 33-48.
- [23] JIANG Z H, ZHOU W G, LI H, et al. A new kind of accurate calibration method for robotic kinematic parameters based on the extended Kalman and particle filter algorithm[J]. *IEEE Trans Ind Electron*, 2018, 65(4): 3337-3345.
- [24] CORKE P I. A simple and systematic approach to assigning Denavit-Hartenberg parameters[J]. *IEEE Trans Robot*, 2007, 23(3): 590-594.