

面向上肢康复的双臂机器人仿治疗师交互控制

林高¹ 王斐¹ 张鑫²

摘要 具有治疗师般个性化、柔顺且安全交互的康复机器人可有效防止二次伤害并提升康复效率. 本文提出一种基于双臂机器人的新型上肢康复框架, 用于实现机器人治疗师般的交互. 首先, 以安全性为首要目标, 建立七自由度上肢运动学模型, 用于评估上肢末端以及前臂后端的可达训练空间; 利用双臂康复的优势, 提出一种非冗余逆运动学方法以约束关节运动角度, 进而构建任务-关节双重约束下的安全机制. 其次, 考虑个性化与柔顺交互, 设计一种基于势场的按需辅助控制策略, 使双臂机器人能够从单次演示中学习治疗师的个性化牵引特性, 并根据上肢的运动能力和训练参与度提供自适应柔顺辅助. 实验结果表明, 所提方法兼具末端牵引式康复机器人动作适应性高、接触少以及外骨骼式康复机器人精准空间训练的特点, 并能够根据上肢训练状态实施按需辅助. 随着双臂及人形机器人的应用越来越广泛, 所提方法为机器人在医院和家庭环境中实现治疗师般个性化、柔顺且安全的康复训练提供了一条新途径.

关键词 双臂机器人; 仿治疗师交互; 上肢运动学; 演示学习; 按需辅助

引用格式 林高, 王斐, 张鑫. 面向上肢康复的双臂机器人仿治疗师交互控制. 自动化学报, 2026, 52(9): 2005–2018

DOI 10.16383/j.aas.c250599 **CSTR** 32138.14.j.aas.c250599

Therapist-like Interaction Control of a Dual-arm Robot for Upper-limb Rehabilitation

LIN Gao¹ WANG Fei¹ ZHANG Xin²

Abstract Rehabilitation robots with therapist-like personalized, compliant, and safe interaction can effectively prevent secondary injuries and improve rehabilitation efficiency. This paper presents a novel upper-limb rehabilitation framework based on a dual-arm robot to achieve therapist-like interaction. First, with safety as the primary objective, a 7-DOF upper-limb kinematic model is established to evaluate the reachable training spaces of the upper-limb end and the rear end of the forearm. Taking advantage of dual-arm rehabilitation, a non-redundant inverse kinematics method is proposed to constrain joint angles, thereby constructing a safety mechanism under task-joint dual constraints. Second, considering personalized and compliant interaction, a potential-field-based assist-as-needed control strategy is designed. It enables the dual-arm robot to learn therapist-specific personalized traction characteristics from a single demonstration and provide adaptive compliant assistance according to the upper-limb motor ability and engagement. Experimental results show that the proposed method combines the high motion adaptability and minimal physical contact of end-effector-based rehabilitation robots with the precise spatial training capability of exoskeleton robots. It can also implement assist-as-needed training based on the upper-limb training state. As dual-arm and humanoid robots become more widely adopted, the proposed scheme provides a new pathway for delivering therapist-like personalized, compliant, and safe rehabilitation training in clinical and home settings.

Keywords dual-arm robot; emulated therapist interaction; upper-limb kinematics; learning from demonstration; assist-as-needed

Citation Lin Gao, Wang Fei, Zhang Xin. Therapist-like interaction control of a dual-arm robot for upper-limb rehabilitation. *Acta Automatica Sinica*, 2026, 52(9): 2005–2018

收稿日期 2025-11-04 录用日期 2026-03-11

Manuscript received November 4, 2025; accepted March 11, 2026

国家自然科学基金 (62373087), 辽宁省应用基础研究计划 (2025JH2/101300009), 辽宁省兴辽英才计划 (XLYC24110114) 资助

Supported by National Natural Science Foundation of China (62373087), Liaoning Provincial Applied Basic Research Program (2025JH2/101300009), and Liaoning Revitalization Talents Program (XLYC24110114)

本文责任编辑 程龙

Recommended by Associate Editor CHENG Long

1. 东北大学机器人科学与工程学院 沈阳 110167 2. 沈阳市第一人民医院康复医学科 沈阳 110091

1. Faculty of Robot Science and Engineering, Northeastern University, Shenyang 110167 2. Department of Rehabilitation Medicine, Shenyang First People's Hospital, Shenyang 110091

脑卒中是全球第二大死亡原因, 在导致肢体残疾方面居于首位^[1]. 超过 75% 的脑卒中患者患有上肢运动功能障碍, 导致患者生活不能自理并增加家庭负担^[2]. 传统的上肢康复是以治疗师“手把手”牵引患肢的方式进行训练, 虽然这种方式安全、科学和柔顺, 但其训练重复性低并且极大地增加了治疗师的工作负担^[3]. 随着机器人技术的发展, 使用上肢康复机器人进行训练已逐渐成为更加高效且具有潜力的康复方案^[4–5].

上肢康复机器人分为末端牵引式和外骨骼式两种类型. 如图 1 所示, 末端牵引式康复机器人通过




图 1 不同类型的上肢康复机器人 ((a) 末端牵引式康复机器人; (b) 外骨骼式康复机器人; (c) 受治疗师启发的双臂康复机器人)

Fig.1 Different types of upper-limb rehabilitation robots ((a) End-effector rehabilitation robot; (b) Exoskeleton rehabilitation robot; (c) Therapist-inspired dual-arm rehabilitation robot)

牵引患者手部进而带动上肢进行训练, 其具有动作适应性强、穿戴简单、安全舒适、运动范围广等优点^[6]. 例如, Han 等^[7]提出一种末端牵引式机器人的按需辅助策略, 使康复训练能够适应不同运动能力的受试者; Wang 等^[8]提出一种末端牵引式机器人的运动学习框架, 能够随着受试者运动能力的变化提供柔顺响应和个性化训练. 相关研究还包括文献 [9–11] 的工作. 然而, 末端牵引式康复机器人无法精确控制上肢各个关节, 在空间训练中保持正确的上肢姿势尤为困难, 因此, 其多采用低自由度平面训练的方式以确保安全性. 外骨骼式康复机器人则是直接穿戴在上肢上, 通过电机对各个关节进行单独控制, 以实现精准的康复训练^[12]. 例如, Pan 等^[13]提出的 NESM- γ 外骨骼, 可以对肩和肘关节进行精准训练; Zarrin 等^[14]设计的 CLEVERarm 外骨骼通过四个电机精确控制肩关节和肘关节, 使受试者能够进行精确的空间运动. 然而, 上肢高自由度带来的高灵活性使得外骨骼式康复机器人结构设计复杂、控制和穿戴困难、对不同患者的运动学适配性差, 并且人机耦合性高, 容易产生额外的相互作用力和力矩. 此外, 无论是末端牵引式还是外骨骼式康复机器人, 多数只考虑肩关节和肘关节的协同训练, 而忽略腕关节 (远端精细关节) 的训练. 在末端牵引式下的上肢受力点单一, 纳入腕关节会增加动作复杂性, 导致训练动作不准确, 安全性降低; 对于外骨骼式康复机器人, 由于腕关节属于精细关节, 纳入腕关节会极大增加其结构设计和控制难度, 如 ANYexo

2.0^[15] 全肢外骨骼. 因此, 多数研究人员开发了专门针对腕关节训练的康复机器人^[16–18], 但这阻碍了肩-肘-腕关节的协同训练. 综上所述, 可将当前问题归纳为两点: 1) 如何结合末端牵引式康复机器人适应性强、低接触和外骨骼式康复机器人精准空间训练的优点, 同时克服前者不适合精准空间训练和后者运动学适配性差、控制和结构复杂以及额外接触力/力矩的限制. 2) 如何在肩和肘关节训练中纳入更精细的腕关节, 实现肩-肘-腕全关节的协同训练.

在传统的上肢康复中, 治疗师使用双臂牵引患肢进行肩-肘-腕关节的协同训练. 受此启发, 本文假设双臂或人形机器人可以取代表治疗师的双臂, 提供类似治疗师的训练 (如图 1 所示). 最近有关双臂和人形机器人模仿人类操作的研究^[19–25] 为本文的假设提供了支撑. 在双臂机器人-物体-人协作方面, Ovur 等^[19]提出一种多传感器融合框架, 实现了人手和双臂机器人之间物体的自然交接; Sirintuna 等^[20]提出一种人机协作自适应框架, 允许人和双臂机器人在工厂中协同搬运重物. 在双臂类人精细操作方面, Fan 等^[21]提出一种基于学习的框架, 使双臂机器人能够在保持紧密协作的同时熟练地操纵物体; Ze 等^[22]通过在家庭环境中部署双臂机器人模仿人类, 以完成高精度服务任务. 此外, 一些研究使用双臂机器人在二维和三维空间中操纵柔性材料, 使其弯曲成指定形状, 可达到人类操作的效果^[23–25]. 综上所述, 双臂机器人能够对物体进行精准的空间操控, 这解决了当前末端牵引式康复机器人的一个关键限制, 并凸显了外骨骼式康复机器人的优势. 然而, 目前的双臂研究主要集中在机器人-物体-人或机器人-物体场景中的仿人协作, 人类的参与是间接的. 相比之下, 上肢康复属于直接、密切的物理人机交互. 此外, 大多数现有研究只是模仿人类的外部行为 (imitation learning), 而忽略对内部动态的模拟 (emulation learning). 鉴于这些差异, 本研究将从目前的双臂仿人协作 (外在行为模仿, 人类间接参与) 转向仿治疗师康复 (外在行为和内在交互动态模仿, 物理人机交互) 任务, 旨在使机器人具备治疗师般个性化、柔顺且安全交互的能力.

本研究提出一种基于双臂的上肢康复机器人仿治疗师交互控制方法. 鉴于上肢康复属于密切的物理人机交互, 安全性是首要考虑因素, 其次是个性化和柔顺性. 本研究的主要贡献如下:

- 康复策略. 提出一种受治疗师启发的上肢康复框架, 利用双臂机器人有效结合末端牵引式和外骨骼式康复机器人的优势, 同时克服各自的局限性. 此外, 在当前主流的肩和肘关节训练中纳入更精细

的腕关节, 实现肩-肘-腕全关节的协同训练。

- 安全机制. 建立精确的上肢运动学模型, 结合双臂康复的特点, 构建任务-关节空间双重约束下的安全机制。

- 交互控制. 在演示学习中引入基于势场的按需辅助控制策略, 结合主从式协同控制, 实现治疗师般个性化和柔顺交互的目标。

1 安全机制

1.1 上肢运动学

为满足康复训练的高安全性要求, 建立精确的 7-DOF 上肢运动学模型。如图 2 所示, 肩部 3-DOF 用于实现肩关节内旋/外旋、内收/外展和屈曲/伸展; 肘部 1-DOF 用于实现肘关节屈曲/伸展; 腕部 3-DOF 用于实现腕关节旋前/旋后、内收/外展和屈曲/伸展。




图 2 7-DOF 上肢运动学模型

Fig. 2 7-DOF upper-limb kinematic model

基坐标系 $H_0 = [x_0, y_0, z_0]$ 位于肩关节处; 局部坐标系 $H_i = [x_i, y_i, z_i]$ ($i = 1, \dots, 6$) 固定在关节 i 处; 末端坐标系 $H_7 = [x_7, y_7, z_7]$ 位于手掌中心。 l_1 , l_2 和 l_3 分别表示上臂长度、前臂长度和腕纹到掌心之间的距离。 l'_2 和 l''_2 分别表示肘关节到 p_{a2} (末端执行器 B) 和 p_{a2} 到腕关节的距离。如表 1 所示, 上肢运动学参数按照标准 D-H (Denavit-Hartenberg) 约定建立。参数 θ_i 表示沿着 z_{i-1} 方向 x_{i-1} 和 x_i 之间的夹角, a_i 表示沿着 x_i 方向 z_{i-1} 和 z_i 之间的距离, d_i 表示沿着 z_{i-1} 方向 x_{i-1} 和 x_i 之间的距离, α_i 表示沿着 x_i 方向 z_{i-1} 和 z_i 之间的夹角。从坐标系 i 到坐标系 $i-1$ 的变换矩阵 $T_i^{i-1}(q)$ 为:

$$T_i^{i-1}(q) = \begin{bmatrix} c\theta_i & -s\theta_i c\alpha_i & s\theta_i s\alpha_i & a_i c\theta_i \\ s\theta_i & c\theta_i c\alpha_i & -c\theta_i s\alpha_i & a_i s\theta_i \\ 0 & s\alpha_i & c\alpha_i & d_i \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (1)$$

其中, 简写符号 s 和 c 分别表示 sin 和 cos 运算; $q = [\theta_1, \dots, \theta_7]^T \in \mathbf{R}^{7 \times 1}$ 表示关节变量。对于上述模型, 在局部坐标系 j 中的向量 $p_j = [x_j \ y_j \ z_j \ 1]^T$ 在基坐标系 H_0 中表示为:

表 1 上肢运动学模型 D-H 参数

Table 1 D-H parameters of the upper-limb kinematic model

关节	θ_i (°)	a_i	d_i	α_i (°)	范围 (°)
肩旋转	θ_1	0	0	90	-90 ~ 80
肩收展	$\theta_2 - 90$	0	0	-90	0 ~ 90
肩屈伸	θ_3	l_1	0	0	-60 ~ 90
肘屈伸	$\theta_4 / \theta_4 + 90$	$0 / l'_2$	0	-90	-90 ~ 45
腕旋转	θ_5	0	l_2 / l''_2	-90	-90 ~ 0
腕收展	$\theta_6 - 90$	0	0	90	-80 ~ 45
腕屈伸	θ_7	l_3	0	0	-15 ~ 45

$$p_j^0 = \prod_{i=1}^j [T_i^{i-1}(q_i)] p_j = T_j^0(q) p_j \quad (2)$$

因此, 掌心点 $p_{a1} = [x_{a1}, y_{a1}, z_{a1}]$ 和前臂后端点 $p_{a2} = [x_{a2}, y_{a2}, z_{a2}]$ 在基坐标系 H_0 下可表示为:

$$[x_{a1} \ y_{a1} \ z_{a1} \ 1]^T = T_7^0(q_1) [0 \ 0 \ 0 \ 1]^T \quad (3)$$

$$[x_{a2} \ y_{a2} \ z_{a2} \ 1]^T = T_3^0(q_2) [0 \ l'_2 \ 0 \ 1]^T \quad (4)$$

其中, T_7^0 和 $T_3^0 \in \mathbf{R}^{4 \times 4}$ 分别表示从 H_7 和 H_3 到 H_0 的变换矩阵。 $q_1 = q \in \mathbf{R}^{7 \times 1}$ 和 $q_2 = [\theta_1, \dots, \theta_4]^T \in \mathbf{R}^{4 \times 1}$ 。已知以关节变量 q_1 和 q_2 表示的 p_{a1} 和 p_{a2} 任务空间位姿, 可通过任务空间和关节空间约束的功能互补特性, 构建在双重约束下的安全机制。

1.2 双重空间约束

1.2.1 任务空间约束

从整体协同运动的角度出发, 训练一旦越界, 势必会导致多个关节出现异常的运动协同。任务空间约束能够限制上肢特定点位的运动范围, 防止出现过度拉伸、挤压和扭转等非生理性姿态, 从而降低二次受伤风险。基于 7-DOF 上肢运动学模型, 使用蒙特卡洛法计算 p_{a1} 和 p_{a2} 的解空间。

$$E_1 = \left\{ p_{a1} \left| T_7^0 \left(\sum_{i=1}^N q_1^i \right) [0 \ 0 \ 0 \ 1]^T \right. \right\} \quad (5)$$

$$E_2 = \left\{ p_{a2} \left| T_3^0 \left(\sum_{i=1}^N q_2^i \right) [0 \ l'_2 \ 0 \ 1]^T \right. \right\} \quad (6)$$

其中, E_1 和 $E_2 \in \mathbf{R}^{3 \times N}$ 分别表示 p_{a1} 和 p_{a2} 在关节可活动范围下的解空间, N 是随机采样点数。对点集 E_1 和 E_2 进行 Delaunay 三角剖分。定义常数 ε , 过滤边长小于 $1/\varepsilon$ 的三角。连接上述三角, 生成对应的可达训练空间 A_1 和 A_2 。利用射线法实时判断 p_{a1} 和 p_{a2} 是否在 A_1 和 A_2 范围内, 从而实现上肢 p_{a1} 和 p_{a2} 点的任务空间约束。算法 1 总结了任务空

间约束的流程.

算法 1. 任务空间约束流程

输入. p_{a1} 、 p_{a2} 、 ε 和运动学模型.

输出. 真 (p_{a1} 在 A_1 范围内且 p_{a2} 在 A_2 范围内) 或假.

```

1:  $E_1, E_2 \leftarrow$  根据式 (5) 和 (6) 计算
2:  $A_1, A_2 \leftarrow$  使用三角剖分和  $\varepsilon$  生成可达训练空间
3: for  $i = 1, 2$  do
4:   count  $\leftarrow$  计算  $p_{ai}$  与  $A_i$  的交点个数
5:   if count 为奇数 then
6:     返回真 //  $p_{ai}$  在  $A_i$  内, 训练继续
7:     重复步骤 3 ~ 6
8:   else
9:     返回假 // 停止训练
10:  end if
11: end for

```

1.2.2 关节空间约束

即使整体运动在可达任务空间内, 也可能导致单个关节超出其生理负荷. 从单关节运动的角度出发, 关节空间约束精确地作用于每个关节, 确保局部运动符合人体生理结构. 7-DOF 系统具有冗余性, 因为任务空间中的六个方向由七个关节变量共同决定. 这致使运动学逆解不唯一, 进而使得在训练过程中施加准确的关约束变得困难. 本文基于双臂康复的特点, 提出一种简单高效的 7-DOF 非冗余逆运动学求解方法. 通过将 7-DOF ($q = [\theta_1, \dots, \theta_7]^T$) 系统分解为 4-DOF ($q_4 = [\theta_1, \dots, \theta_4]^T$) 和 3-DOF ($q_3 = [\theta_5, \dots, \theta_7]^T$) 的子系统 (每个子系统的 D-H 参数见表 1), 单独对子系统进行求解.

对于 4-DOF 子系统, 点 p_{a2} 在基坐标系 H_0 中表示为:

$$p_{a2}^0 = T_3^0 p_{a2}^3 = T_B^0 p_{a2}^B \quad (7)$$

其中, T_3^0 和 T_B^0 表示 H_3 和机械臂 B (其末端点位于 p_{a2}) 的基坐标系到 H_0 的变换矩阵; p_{a2}^3 和 p_{a2}^B 分别是 p_{a2} 在 H_3 和在机械臂 B 基坐标系下的表示.

同理, 对于 3-DOF 子系统, 点 p_{a1} 在局部坐标系 H_4 中表示为:

$$p_{a1}^4 = T_7^4 p_{a1}^7 = T_0^4 T_A^0 p_{a1}^A \quad (8)$$

基于上述关系, 构建 4-DOF 和 3-DOF 子系统逆运动学求解模型, 以实现康复过程中高效、准确的关约束.

2 仿治疗师交互

在传统康复中, 治疗师通过对患肢进行辅助牵

引与患者共同完成训练任务. 在此过程中, 治疗师发挥轨迹规划、按需辅助和软约束的作用. 受此启发, 所提方法仅需一次演示即可学习这种治疗师般的交互. 该过程分为两个阶段: 牵引演示和演示学习. 本文的目标是使双臂机器人能够从单次演示中学习治疗师的牵引特性. 然后, 在无治疗师参与的情况下, 机器人提供与牵引演示期间相同的辅助, 并可根据患肢实时训练状态自适应调节协助和软约束作用. 上述按需辅助控制器使机器人能够有效模仿治疗师个性化、柔顺且安全的交互行为.

2.1 牵引演示

将治疗师的手臂替换为串联刚性机器人, m -DOF 串联机器人的非线性动力学可以表示为:

$$M(q)\ddot{q} + \left[\frac{1}{2}\dot{M}(q) + S(q, \dot{q}) \right] \dot{q} + g(q) = \tau + J^T(q)F_h \quad (9)$$

$$F_h = F_{in} + F_c \quad (10)$$

$$F_{in} = F_{th} + F_{pa} \quad (11)$$

其中, $q \in \mathbf{R}^m$ 表示关节变量; $M(q) \in \mathbf{R}^{m \times m}$ 表示机器人惯性矩阵; $(1/2)\dot{M}(q)$ 和 $S(q, \dot{q})$ 是向心力矩和 Coriolis 力矩; $g(q) \in \mathbf{R}^m$ 是重力项; $\tau \in \mathbf{R}^m$ 表示关节力矩; $J^T(q) \in \mathbf{R}^{6 \times m}$ 表示关联任务空间和关节空间的雅可比矩阵; $F_h \in \mathbf{R}^6$ 是合力, F_h 可以拆解为作用于机器人末端执行器的外力 $F_{in} \in \mathbf{R}^6$ 和控制系统的控制力 $F_c \in \mathbf{R}^6$; F_{th} 和 F_{pa} 分别表示治疗师的牵引力和患肢主动施加的训练力. 在牵引演示阶段, 治疗师牵引患肢共同完成训练任务, 此时 $F_c = 0$ N. 力与位姿的动态关系可表示为:

$$D_t(\dot{p} - \dot{p}_d) + K_t(p - p_d) = F_{th} + F_{pa} \quad (12)$$

其中, $D_t \in \mathbf{R}^6$ 和 $K_t \in \mathbf{R}^6$ 分别表示机器人初始阻尼和刚度特性; 实际位姿 p 与期望位姿 p_d 之间的差值为位姿偏差, 其导数 $\dot{p} - \dot{p}_d$ 表示速度偏差. 通过将 p 设置为期望位姿 p_d 并累积增量位姿更新, 以实现机器人对治疗师牵引力的跟踪.

$$p_d^{t+1} = (\xi^t + \Delta\xi, \Delta q_{Rp} q_{Rp}^t) \quad (13)$$

其中, p_d^{t+1} 表示下一个控制周期的期望位姿; 当前位置及其偏差分别为 $\xi^t = [x^t \ y^t \ z^t]$ 和 $\Delta\xi = [\Delta x \ \Delta y \ \Delta z]$. 类似地, 当前姿态及其偏差分别为 $q_{Rp}^t = [q_{Rx}^t \ q_{Ry}^t \ q_{Rz}^t]$ 和 $\Delta q_{Rp} = [\Delta q_{Rx} \ \Delta q_{Ry} \ \Delta q_{Rz}]$. 速度偏差 Δv^t 和位姿偏差 $\Delta p^{t+1} \in \mathbf{R}^6$ 计算如下.

$$\Delta v^t = \frac{1}{D_t} (F_{in} - K_t \Delta p^t) \quad (14)$$

$$\Delta p^{t+1} = \Delta p^t + \Delta v^t T_c \quad (15)$$

其中, T_c 表示控制周期. 在演示过程中, 位姿 $p_d \in \mathbf{R}^6$ 、相互作用力 $F_{in} \in \mathbf{R}^6$ 和患肢的训练参与度 $R_d \in \mathbf{R}^1$ 以 $1/T_c$ Hz 的频率记录. 将获取到的特征集下采样为 v 个均匀分布的样本 (以下称为吸引点), 从而构建特征集 V .

$$V = \{[p_d^i; F_{in}^i; R_d^i] \in \mathbf{R}^{13 \times 1}\}_{i=1}^v \in \mathbf{R}^{13 \times v} \quad (16)$$

$$R_d^i = \frac{1}{U} \sum_{u=1}^U \sqrt{\frac{1}{W} \sum_{k=0}^{W-1} r_u^2[i-k]} \quad (17)$$

本文使用肌肉激活水平表示训练参与度; W 表示窗口长度; k 是窗口内偏移量; u 和 U 分别表示当前肌电通道和通道总数; $r_u[i]$ 表示当前新进入的样本. 为降低计算复杂度, 采用递推的更新方式, 在常数时间 $O(1)$ 内实现对 R_d 的更新.

定义 $\{T-N\}^i$ 为第 i 个吸引点的切线-法线坐标系. 该坐标系以吸引点 $\xi_d^i \in \mathbf{R}^3$ 为中心, 切线方向指向下一个吸引点 ξ_d^{i+1} , 法线方向指向当前末端执行器的位置 $\xi \in \mathbf{R}^3$. 期望吸引点 ξ_d^i 通过最小化当前位置 ξ 与点集 $\xi_V \in \mathbf{R}^{3 \times v}$ 之间的欧氏距离得到.

$$\xi_d^i \leftarrow \min_{\xi_V^i \in V} \|\xi - \xi_V^i\|_2^2 \quad (18)$$

其中, $\|\cdot\|_2$ 表示二范数.

2.2 演示学习

在无治疗师参与的情况下, 机器人为患肢提供与牵引演示等效的运动辅助. 在此期间, 允许患者与机器人进行柔顺和安全交互, 并且机器人可根据患者实时训练状态进行按需辅助. 如图 3 所示, 本文基于从牵引演示中提取的交互特征, 结合非参数势场函数, 设计按需辅助控制器. 此时, 控制力 F_c 取代治疗师的牵引力 F_{th} , 为上肢运动提供等效的辅助. 因此, F_h 和 F_c 可表示为:

$$F_h = F_{pa} + F_c \quad (19)$$

$$F_c = F_N + F_T \quad (20)$$

其中, F_N 和 F_T 分别表示期望吸引点 ξ_d^i 的吸引力和沿下一个吸引点 ξ_d^{i+1} 的助推力. F_N 为训练提供柔顺性约束, 防止上肢过度偏离期望训练轨迹; F_T 则通过提供推进协助, 帮助上肢到达下一个期望位置. 为了共同生成施加在给定位置的切向力和法向力, 本文构建了一个非参数势场. 该势场通过刚度系数为 K_d^i 的虚拟弹簧将末端执行器的当前位置 ξ 连接到相应的吸引点 ξ_d^i . 第 j 个吸引点 ξ_V^j 在 ξ 处的




图 3 牵引演示与演示学习流程

Fig. 3 Traction demonstration and learning from demonstration process

势能定义为:

$$\phi^i(\xi) = \phi_T^i(\xi) + \phi_N^i(\xi) = F_T^i(\xi) + \frac{K_d^i (\xi - \xi_V^i)}{2} \quad (21)$$

与万有引力类似, 吸引力的贡献应随着与吸引点的距离增加而减小. 高斯核函数通常用于衡量数据点之间的相似性^[26], 本文采用核回归方法, 基于各能量元素 $\phi^i(\xi)$ 构建总能量函数. 在当前位置 ξ 处, 能量元素的贡献由高斯核函数确定.

$$\omega^i(\xi) = e^{-\frac{1}{2\sigma^2}(\xi - \xi_V^i)^T(\xi - \xi_V^i)} \quad (22)$$

其中, 参数 σ 用于调节高斯核函数的平滑度, 并控制其带宽. 当吸引点距离较远时, 它们之间的相互作用可忽略不计. 为了减少计算量、提高控制速度和平滑连续运动过程中的吸引力, 本文选取 ξ_d^i 前后 $v/8$ 个吸引点来计算总势能. 因此, ξ 处的总势能为:

$$\Phi(\xi) = F_T^i(\xi) + \frac{\sum_{n=-v/8}^{v/8} \omega^{d+n}(\xi) \phi^{d+n}(\xi)}{\sum_{m=-v/8}^{v/8} \omega^{d+m}(\xi)} \quad (23)$$

将所有吸引点 $\xi_{v/4+1}$ 的引力进行归一化处理. 每个吸引点 $\xi_{v/4+1}$ 相对 ξ 的引力系数被定义为:

$$\tilde{\omega}^i(\xi) = \frac{\omega^i(\xi)}{\sum_{n=-v/8}^{v/8} \omega^{d+n}(\xi)} \quad (24)$$

对于引力系数 $\tilde{\omega}^i(\xi)$ 有两个属性: $0 < \tilde{\omega}^i(\xi) < 1$ 和 $\sum_{v/4+1} \tilde{\omega}^i(\xi) = 1$. 因此, 式 (23) 可简化为:

$$\Phi(\xi) = F_T^i(\xi) + \sum_{n=-v/8}^{v/8} \tilde{\omega}^{d+n}(\xi) \phi^{d+n}(\xi) \quad (25)$$

与阻尼弹簧系统的能量耗散原理类似, 能量耗散场 $\psi^i(\xi, \Delta \dot{\xi})$ 取决于当前位置 ξ 处的速度偏差 $\dot{\xi}$

$= \dot{\xi} - \dot{\xi}_d^i$ 和对应的阻尼特性 D_d^i .

$$\psi^i(\xi, \Delta\dot{\xi}) = \psi_T^i(\xi, \dot{e}_T) + \psi_N^i(\xi, \dot{e}_N) = D_d^i \left[\left(\dot{\xi}_T - \dot{\xi}_{dT}^i \right) + \left(\dot{\xi}_N - \dot{\xi}_{dN}^i \right) \right] \quad (26)$$

其中, $\psi_T^i(\xi, \dot{e}_T)$ 和 $\psi_N^i(\xi, \dot{e}_N)$ 分别表示在 $\{T-N\}^i$ 坐标系下的能量耗散场. 因此, 总耗散能量 $\Psi(\xi, \Delta\dot{\xi})$ 可通过耗散元素的加权求和得到.

$$\Psi(\xi, \Delta\dot{\xi}) = \psi_T^i(\xi, \dot{e}_T) + \sum_{n=-v/8}^{v/8} \tilde{\omega}^{d+n}(\xi) \psi_N^{d+n}(\xi) \quad (27)$$

因此, ξ 处的总能量 $E(\xi)$ 可由下式得到:

$$E(\xi) = \Phi(\xi) - \Psi(\xi, \Delta\dot{\xi}) \quad (28)$$

回到式 (21), 需要定义 $F_T^i(\xi)$, 使患肢获得与牵引演示等效的助推力. 随着轨迹偏移量的增加, 垂直势场占主导地位, 而非 $F_T^i(\xi)$, 从而降低在期望训练轨迹外助推力带来的安全性风险. $F_T^i(\xi)$ 定义如下:

$$F_T^i(\xi) = \frac{2zF_{in}^i}{1 + h\|\xi - \xi_d^i\|}, \quad 1 \leq h \leq e \quad (29)$$

其中, 常数 h 用于调节助推力带宽, z 用于调节助推力的水平. 当 z 等于 1 时, 表示机器人的助推力与治疗师演示时的助推力完全一致. 通过增加和减小 z , 可实现训练模式的切换. 例如, 可设置被动 ($z = 1.5$)、半主动 ($z = 1$)、主动 ($z = 0$) 训练模式, 以匹配患者在不同康复阶段的运动能力.

2.2.1 按需辅助

高刚度会导致患者训练参与度降低, 而低刚度则无法保证训练强度, 进而影响训练效果. 治疗师可根据患者的实时训练状态调整训练刚度, 以实现按需辅助. 受此启发, 当患者训练参与度较低时, 通过降低训练刚度, 进而增强 F_T 的助推力作用和降低训练难度, 以促进患者的主动参与; 当患者训练参与度较高时, 通过提高训练刚度, 进而降低 F_T 的助推力作用和提升训练难度, 以保证训练强度. K_d 被定义为在牵引演示刚度 K_q 基础上, 根据患肢当前训练参与度 R 进行调节后的训练刚度. 在牵引演示期间, 治疗师和患者共同完成演示训练, 治疗师双臂刚度和机器人初始刚度 K_t 、治疗师的牵引力 F_{th} 和患肢主动训练力 F_{pa} 相关. 因此 K_q^i 可表示为:

$$K_q^i = K_{\min} + (K_{\max} - K_{\min}) \frac{F_{in}^i - F_{in, \min}}{F_{in, \max} - F_{in, \min}} \quad (30)$$

其中, $F_{in, \min}$ 和 $F_{in, \max}$ 分别为特征集 V 中最小和最大交互力 ($F_{in} = F_{th} + F_{pa}$); $K_{\min} = K_t - K_v$

和 $K_{\max} = K_t + K_v$ 表示 K_q 的限值, 即 $K_q^i \in [K_{\min}, K_{\max}]$, K_v 用于调节 K_q 的学习范围. K_d^i 可通过 K_q^i 和训练参与度 R 计算得到.

$$K_d^i = \begin{cases} K_q^i - Z_1 (1 - e^{\Delta R/L_1}), & \Delta R \leq 0 \\ K_q^i + Z_2 (1 - e^{\Delta R/L_2}), & \Delta R > 0 \end{cases} \quad (31)$$

$$\Delta R = R - R_d^i \quad (32)$$

其中, $R_d^i \in V$, Z_1 、 Z_2 、 L_1 和 L_2 分别表示负向刚度变化系数、正向刚度变化系数、衰减长度参数和增益长度参数. 根据患肢实时训练参与度 R 对 K_d^i 进行调节, 以实现在康复过程中机器人的按需辅助.

2.3 主从式协同控制

在传统康复训练中, 治疗师使用双臂来牵引患肢进行多关节协同运动. 根据其辅助作用, 将治疗师的双臂分为主臂和从臂. 主臂用于执行大范围牵引任务, 起到粗调作用; 从臂协助纠正运动姿势, 起到微调作用. 与显微镜的作用一致, 粗调和微调的目的是找寻正确的位置, 但在本研究中粗调和微调同时进行, 以确保每一时刻对应期望位姿的准确性. 本研究规定: 在以前向运动为主的康复训练中, 机械臂 A 作为主臂而机械臂 B 作为从臂; 在以后向运动为主的康复训练中, 机械臂 B 作为主臂而机械臂 A 作为从臂. 在演示学习中, 与主臂当前位姿 $p_m[\xi_m, q_m]$ 对应的期望位姿 $p_{dm}[\xi_{dm}^i, q_{dm}^i]$ 由式 (18) 计算得到. 从臂对应的期望位姿 $p_{ds}[\xi_{ds}^i, q_{ds}^i]$ 则根据 i 对特征集 V 进行索引获取. 因此, 在训练力的作用下, 从臂的当前位姿 $p_s[\xi_s, q_s]$ 可表示为:

$$\xi_s = \xi_{ds}^i + \Delta\xi_s \quad (33)$$

$$q_s = \Delta q_s q_{ds}^i \quad (34)$$

为了避免上肢因过度伸展或挤压而造成的安全性风险, 主臂和从臂末端执行器之间的距离 d_{ms} 应限制在从 p_{a2} 到 p_{a1} 的距离 d_p 范围内.

$$d_p^2 = (l_2'')^2 + l_3^2 + 2l_2''l_3 \cos \theta_6 \cos \theta_7 \quad (35)$$

$$d_{p, |\theta_{\max}|}^2 \leq d_{ms}^2 = \|\xi_m - {}^m\xi_s\|_2^2 \leq d_{p, |\theta_{\min}|}^2 \quad (36)$$

其中, $d_{p, |\theta_{\min}|}$ 、 $d_{p, |\theta_{\max}|}$ 分别为当 θ_6 和 θ_7 取最小、最大值时对应的 d_p 值; ${}^m\xi_s$ 是从臂末端执行器在主臂基坐标系下的位置表示.

3 实验方案

3.1 双臂康复机器人平台搭建

如图 4(e) 所示, 两台 Doosan M1509 机械臂用

于模拟治疗师的双臂. 每台机械臂的末端执行器均安装有六维力传感器 (ATI Axia80), 用于感知力的交互. 通过训练手套和魔术贴将受试者上肢固定在末端执行器上, 确保穿戴的便捷性和舒适性.




图 4 实验方案 ((a) ~ (d) 训练动作 1 ~ 3; (e) 双臂康复机器人平台; (f) IMU 和 EMG 传感器放置部位)

Fig. 4 Experimental protocol ((a) ~ (d) Training motions 1 ~ 3; (e) Dual-arm rehabilitation robot platform; (f) Placement locations of the IMU and EMG sensors)

3.2 实验范式

实验包括三种常见的多关节训练. 如图 4(a) ~ 4(d) 所示, 分别为前向手臂上举、后向扩胸以及垂直扩胸配合旋转前推 (复合动作). 训练 1 和训练 3 主要涉及上肢的前向运动, 因此以机械臂 A 作为主臂; 训练 2 以后向运动为主, 对应以机械臂 B 作为主臂. 以上三种训练均涉及肩关节屈曲/伸展、肩关节内收/外展、肩关节内旋/外旋、肘关节屈曲/伸展、腕关节旋前/旋后、腕关节屈曲/伸展和腕关节内收/外展运动. 6 名男性受试者 (S1 ~ S6 (平均值 $\pm$ 标准差): 年龄: 23.8 ± 0.7 岁, 体重: 68.1 ± 9.0 kg, 身高: 174.6 ± 5.4 cm) 参与实验. 首先, IMU (Noraxon MyoMotion) 和 EMG (MYO) 传感器以图 4(f) 所示的位置固定在上肢, 用于获取上肢关节角度、上肢特定点空间位置和肌肉活动; 随后, 治疗师牵引末端执行器, 辅助受试者上肢共同完成一次标准训练动作; 最后, 在无治疗师参与的情况下, 机器人模仿治疗师辅助受试者进行上肢训练. 本研究已获得东北大学伦理委员会 (NEU-EC-2025B058S) 的批准, 并已获得受试者的知情同意.

3.3 控制参数设置

本实验设置中等交互水平 $K_t = 150$ N/m, $K_v = 20$ N/m 和 $D_d = [30, 50]$ N·s/m, 以平衡系统的交互性和安全性. 其他参数设置如下: $W = 20$, $\sigma =$

0.2 , $h = 1$, $Z_1 = 50$, $Z_2 = 75$, $L_1 = 3$ 和 $L_2 = 6$. 此外, F_T 的范围及在该范围内的变化、 K_q 在 $[K_t - K_v, K_t + K_v]$ 范围内的变化通过演示学习直接获得.

4 结果与分析

4.1 训练空间构建

图 5(a) 和图 5(b) 分别显示了采样点数对掌心点 p_{a1} 和前臂后端点 p_{a2} 可达训练空间 A_1 和 A_2 体积的影响. 对于 A_1 , 随着采样点数的增加, 可达训练空间体积呈逐渐上升并趋于稳定的变化趋势. 当采样点较少 (1000 ~ 3000 点) 时, 由于随机分布覆盖不足, 末端位置在边界区域的采样密度较低, 导致估计的空间体积显著偏小. 随着采样点数的增加 (至 7000 点左右), 随机采样逐步覆盖各关节角度组合的主要区域, 体积增长速度减缓. 继续增加采样数量 (至 11000 点) 后, 体积变化趋于收敛. 同理, 对于 A_2 , 采样数量越多, 统计估计的方差越小, 空间边界的分辨率和连续性越高. 然而, 当采样点超过一定阈值 (约 6000 点) 后, 进一步增加样本对体积估计的改善有限, 而计算开销将显著增加. 因此, 综合考虑计算效率与精度后, 本实验分别选择




图 5 参数选择与可达训练空间构建效果 ((a) ~ (b) 可达训练空间 A_1 、 A_2 体积与采样点数之间的关系; (c) ~ (d) 受试者 3 蒙特卡洛 E_1 、 E_2 点集与可达训练空间 A_1 、 A_2 的构建效果)

Fig. 5 Parameter selection and reachable training space construction effects ((a) ~ (b) Relationship between the volumes of reachable training spaces A_1 and A_2 and the number of sampling points; (c) ~ (d) Construction effects of the Monte Carlo point sets E_1 and E_2 and the reachable training spaces A_1 and A_2 for subject 3)

11 000 和 6 000 个采样点作为 A_1 和 A_2 构建的最优采样规模. 以受试者 3 为例, 图 5(c) 展示了蒙特卡洛法生成的空间点云 E_1 和 E_2 , 点在可达性较高的空间上密集分布, 而在可达性受限的区域则相对稀疏, 这与人体上肢的实际运动限制相一致. 图 5(d) 为基于 E_1 和 E_2 点云构建的可达训练空间 A_1 和 A_2 . 与原始点云相比, 构建的可达训练空间滤除了边界随机噪声, 使得边界平滑连续. 生成的训练空间能够完整覆盖原始点云, 有效近似可达训练空间的整体形态, 提升任务空间约束的精确性.

4.2 关节空间约束

本部分旨在验证所提出的 7-DOF 非冗余逆运动学求解方法在关节约束方面的效果. 实验考虑肩、肘及腕部的协同运动, 以模拟上肢康复训练中多关节协同运动场景. 如图 6 所示, 以参考角度为标准, 比较了所提基于双臂的非冗余方法以及传统 7-DOF 冗余方法的差异. 所有逆运动学均基于通用数值优化法求解, 采用均方根误差 (root mean square error, RMSE) 作为评估指标, 用以量化对各关节的解算误差.

所提方法在各关节角度跟踪方面表现出高度一致性. 所有关节的角度曲线几乎完全与参考轨迹重合. RMSE 结果显示, 该方法在七个关节中的误差均接近 0° , 远低于在康复训练中普遍接受的 $5^\circ \sim 10^\circ$ 误差容限. 这表明所提方法在逆运动学求解中具有出色的精度与稳定性, 适用于在康复训练中进行关节约束. 相比之下, 传统冗余方法在上肢独立关节 (肘关节) 中表现出色, RMSE 接近于 0° , 但在

肩和腕的耦合关节上出现了显著的误差. RMSE 高达 $7.6^\circ \sim 33.8^\circ$, 在旋转和屈伸等自由度上出现解算发散现象. 肩旋转、肩收展、腕旋转、腕收展和腕屈伸对应的 RMSE 分别为 14.7° 、 27.3° 、 33.8° 、 17.3° 、 23.0° , 均超过 10.0° . 如果直接应用于康复系统, 这种程度的误差会错误地反映患者的实际关节状态, 导致训练中断甚至患者受伤. 从时间响应特性来看, 所提方法能够在整个运动过程中保持解的连续性和平滑性, 无明显振荡或突变. 冗余方法则在多个关节处出现解的不连续性, 特别是 $5 \sim 7$ s 区间对应的复杂姿态切换阶段, 肩收展出现跳变. 这种不连续的求解结果限制了其直接应用于关节空间约束的能力. 所提方法通过双臂获取上肢其他特定点位的位姿信息, 对冗余自由度进行拆分, 显著提高了解算过程的全局收敛性、精确性和稳定性, 有效避免了冗余解空间中奇异值附近的振荡与发散问题. 因此, 所提方法可以在关节空间约束期间有效降低康复意外中断的频率和关节约束失效的概率, 从而提高了康复系统的稳定性和实用性.

由于实时性直接影响交互训练的流畅性, 解算速度也是一个需要考虑的重要因素. 实验结果表明, 在 Core i9-13900HX 平台上, 所提方法实现了 0.008 s 的平均逆运动学求解时间, 优于冗余方法的 0.014 s, 计算效率提升约 42.9%. 这些结果表明, 所提方法在保持高精度的同时, 具有更高的实时性, 有助于提升康复训练过程的交互质量和安全性.

4.3 势场参数的影响

图 7 显示了不同参数 K_d (在式 (21) 中, 控制势场强度)、 σ (在式 (22) 中, 控制势场精度和平滑度) 和 F_T (在式 (29) 中, 控制助推力) 对势场的影响. 颜色的深浅代表势场的强弱, 箭头代表其方向. 从图 7(a) 到图 7(b), 随着 σ 的增加, 势场变得更加平滑, 但局部细节减少. 这导致势场变得模糊, 并使得势场与期望训练轨迹欠拟合. 在本研究中, 通过多次测试, 确定 $\sigma = 0.2$ 为最优值, 并据此进行了实验, 以平衡势场的精度和平滑度. 从图 7(a) 到图 7(c), 随着 K_d 的减小, 势场强度减弱, 使得交互能力和柔顺性增加. 然而, 过小的 K_d 会降低势场的软约束能力, 从而增加安全风险; 过高的 K_d 则会降低人机交互性能和柔顺性, 但对患肢震颤和痉挛等异常运动的约束能力提高, 进而增加训练安全性. 因此, 本文根据患者的实时训练参与度按需调整 K_d 大小, 以平衡训练的柔顺性和安全性. 从图 7(a) 到图 7(d), 只有 F_T 发生变化, 致使助推力导向目标点. 因此, 可以通过调整 F_T 的大小或方向, 例如设计被动、半




图 6 所提非冗余和冗余关节空间约束效果对比

Fig. 6 Comparison of the proposed non-redundant and redundant joint-space constraint effects

主动、主动和阻力的针对性康复模式,使训练强度与患者的运动能力相匹配。

4.4 柔顺性约束

图 8(a) 可视化了在康复训练 2 中随机选取的受试者 3 的演示特性。用不同颜色表示轨迹在不同阶段下的助推力大小,范围从 2.5 N 到 19.5 N。七个等距采样的圆形横截面展示了不同演示阶段势场的各向异性吸引力分布。在脑卒中临床表现中,患者常出现震颤、痉挛等异常运动。为了评估系统在异常运动中的临床稳健性,本节进行了不同程度的扰动实验。如图 8(b) 所示,在 5 N、10 N、15 N 和 20 N 的扰动下,上肢最大位移分别为 4.9 ~ 5.8 mm、10.2 ~ 11.5 mm、15.5 ~ 17.3 mm 和 21.0 ~ 23.2 mm。上述结果表明,当施加扰动时,上肢会偏离轨迹,直到势场产生的恢复力与扰动力平衡,从而达到稳定的最大偏差。值得注意的是,在相同的扰动下,最大位移并不是固定的,而是在演示的不同阶段随着系统刚度的变化而自适应变化,体现了其动态柔顺调节的能力。该机制有效地限制了偏差的范围,从而提高了训练安全性。同时,由于不再将运动限制在单一固定的轨迹上,提供了更高的柔顺性。当扰动消除后,势场引导上肢平稳地回到期望轨迹,展现了该系统在不同程度扰动下出色的临床稳健性。




图 7 在不同参数影响下的势场可视化效果

Fig.7 Visualization effects of the potential field under different parameter influence

4.5 双臂牵引效果

本节将所提方法与当前的末端牵引式方法^[7-8, 10](基于主臂进行牵引)进行了比较,并以演示训练(效果等同于理想条件下的全肢外骨骼)作为参考。表 2 和表 3 展示了所有受试者的关节角度以及空间特定点位的平均对比结果,使用 RMSE、平均绝对误差 (mean absolute error, MAE) 和皮尔逊相关系数 (Pearson correlation coefficient, PCC) 作为评估指标。

在关节角度跟踪方面,以 RMSE 作为度量指标,反映训练角度相对于演示角度的整体偏差。如表 2 所示,所提的双臂方法在所有被测关节上的 RMSE 均显著优于基线方法,在训练 1 ~ 3 中分别实现了 0.87° ~ 2.06°、0.97° ~ 1.63° 和 0.83° ~ 2.40° 的 RMSE 值,尤其是在主导运动(肩和肘关节)的自由度上, RMSE 多数控制在 2° 以内,与演示训练




图 8 势场可视化与柔顺约束效果 ((a) 在康复训练 2 中受试者 3 对应的势场可视化效果; (b) 在不同程度扰动下系统的柔顺约束效果)

Fig.8 Potential field visualization and compliance constraint effects ((a) Visualization effect of the potential field corresponding to subject 3 during rehabilitation training 2; (b) Compliant constraint effects of the system under different levels of perturbation)

表 2 关节空间下所提方法与基线方法训练效果对比

Table 2 Comparison of training performance between the proposed method and baseline methods in joint space

关节空间	训练 1				训练 2				训练 3			
	双臂		基线		双臂		基线		双臂		基线	
	RMSE (°)	PCC	RMSE (°)	PCC	RMSE (°)	PCC	RMSE (°)	PCC	RMSE (°)	PCC	RMSE (°)	PCC
肩高举	0.98	0.99	20.75	0.78	1.06	1.00	3.63	0.99	0.88	1.00	21.68	0.86
肩内旋	0.99	0.99	11.24	0.85	0.97	0.99	2.44	0.97	1.31	0.95	22.26	-0.37
肩屈曲	1.53	0.90	3.45	0.57	1.43	1.00	1.88	1.00	2.40	0.99	16.01	0.45
肩外展	0.87	1.00	21.43	0.93	0.97	0.99	2.55	0.99	0.85	1.00	22.69	0.94
肘屈曲	2.06	0.99	6.14	0.99	1.63	0.99	5.05	0.99	1.74	0.99	5.44	0.93
腕伸展	1.12	0.99	5.11	0.53	1.43	0.92	6.98	0.22	1.25	0.99	8.47	0.66
腕外展	1.07	0.67	12.31	0.05	1.14	0.78	1.95	0.54	0.83	0.83	14.31	0.20
腕旋后	1.06	0.99	16.20	0.99	1.05	0.99	21.53	-0.92	0.93	0.99	25.78	0.99

表 3 任务空间下所提方法与基线方法训练效果对比 (°)

Table 3 Comparison of training performance between the proposed method and baseline methods in task space (°)

任务空间	训练 1				训练 2				训练 3			
	双臂		基线		双臂		基线		双臂		基线	
	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE
肘部	5.89	4.64	92.74	78.76	6.28	5.04	25.24	21.32	8.94	6.84	101.89	91.70
腕部	6.75	5.52	46.85	38.43	8.88	6.98	32.87	28.46	9.87	7.87	54.60	47.19
手部	6.73	5.48	39.61	31.91	8.32	6.61	68.56	53.99	9.81	8.09	62.58	56.05

的效果近乎一致. 相比之下, 在基线方法中, 关节的 RMSE 值多数超过 10°, 部分自由度如肩外展、肩上架甚至超过 20°, 表明单臂系统难以兼顾多关节协同运动. 值得注意的是, 单臂方法在高耦合关节 (如腕关节和肩关节) 处误差峰值尤为突出, 远高于康复训练中普遍接受的 5° ~ 10° 关节误差容限. 若将其直接应用于空间训练, 将严重影响训练效果并增加患肢二次受伤的风险. 从训练对比结果来看, 训练 3 的平均 RMSE 为 17.08°, 略高于训练 1 的 12.08°, 显著高于训练 2 的 5.75°. 训练 3 作为复合动作, 肩、肘、腕多个自由度的同步协调更加复杂, 单臂的方法无法确保复杂运动下的精确关节控制. 相反, 所提双臂方法在训练 1 ~ 3 中的 RMSE 变化范围仅为 0.83° ~ 2.40°, 进一步说明所提双臂方法在不同复杂度训练下均能保持稳定的控制性能.

在关节运动一致性和同步性方面, PCC 提供了相关性度量. 双臂方法在肩、肘、腕上均呈现出稳定且高相关的时序特征. 具体而言, 在所有训练中, 本文所提方法肩部的 PCC 值几乎接近 1.00, 肘部亦稳定在 0.99. 这表明在主要驱动关节处, 双臂系统实现了与演示训练的高度时间同步, 保证动作执行的流畅性和连续性. 值得注意的是, 腕部虽然属于远端精细关节, 但在双臂方法下的 PCC 值仍维持在 0.67 ~ 0.99, 即便在训练 3 中也未出现相关性显著下降的情况. 这说明双臂方法不仅提升了运动主导关节的同步精度, 同时对远端精细关节的运动一致性亦具有出色的跟踪性能, 系统整体在全关节的时序协调上表现出强鲁棒性. 相反, 单臂方法在多个关节的 PCC 值显著降低甚至出现负相关. 例如, 在训练 3 中的肩内旋和训练 2 中的腕旋后分别为 -0.37 与 -0.92. 这意味着其输出运动方向与演示动作相反, 表现出反向跟踪现象. 在训练 2 的腕部运动中, PCC 范围仅为 [-0.92, 0.22], 表现出明显的时序错位与角度偏移. 这种现象表明单臂方法在多自由度协同运动过程中存在严重的动态不一致性. 一方面, 牵引力作用部位单一, 导致对上肢的关节扭矩分布不合理且姿态耦合误差积累. 另一方面, 单臂康复系统缺乏从臂的实时辅助校正, 造成关节


运动滞后和相位反转. 这种时间相关性缺失不仅无法确保训练动作的正确性, 还会导致训练时诱发关节反向受力, 增加肌腱拉伤的风险.

在任务空间轨迹跟踪方面, 使用 RMSE 和 MAE 作为度量指标, 反映训练轨迹相对于演示轨迹的整体偏差和局部误差. 对于单臂方法, 训练 1 和训练 3 的腕部 (训练 1: RMSE = 46.85°, MAE = 38.43°; 训练 3: RMSE = 54.60°, MAE = 47.19°) 和手部 (训练 1: RMSE = 39.61°, MAE = 31.91°; 训练 3: RMSE = 62.58°, MAE = 56.05°) 指标明显低于肘部 (训练 1: RMSE = 92.74°, MAE = 78.76°; 训练 3: RMSE = 101.89°, MAE = 91.70°), 这表明牵引手部进行空间训练可以提升上肢端点位置的准确性, 但无法控制肘部运动, 导致整体训练姿态出现较大偏差. 与之相反, 训练 2 的腕部 (RMSE = 32.87°, MAE = 28.46°) 和手部 (RMSE = 68.56°, MAE = 53.99°) 指标均高于肘部 (RMSE = 25.24°, MAE = 21.32°), 这表明仅牵引前臂后端进行空间训练虽然提高了肩部和肘部的运动精度, 但对远端精细关节的控制仍然不足. 这直接导致手、腕部的空间和关节相关指标较差 (手、腕部: RMSE = [32.87°, 68.56°], MAE = [28.46°, 53.99°]; 腕关节: PCC = [-0.92, 0.54]). 如图 9 和图 10 所示, 我们随机选取受试者 1、3 和 6, 并绘制其关节角度和空间轨迹训练曲线. 在所有训练中, 双臂方法通过增加从臂的运动辅助, 显著提高了关节和空间运动精度. 其中, 双臂方法在腕部、肩部的复杂关节上的控制性能显著优于单臂方法, 表明其在执行精细复杂动作方面具有更出色的能力. 因此, 与基线方法相比, 所提框架在实现高自由度且精确的康复训练方面表现出明显的优势.

4.6 按需辅助效果

为了使训练或辅助强度与患者的疲劳程度或训练参与度相匹配, 本文设置了被动 ($F_T = 1.5F_{in}$)、半主动 ($F_T = F_{in}$) 和主动 ($F_T = 0$) 三种训练模式, 并测试了三种模式下的机器人按需辅助效果.


如图 11 所示, 在三种模式下进行 5 次往复训练, 被动、半主动和主动模式的上肢平均轨迹偏移量



注: $a_1 \sim a_8$ 、 $b_1 \sim b_8$ 和 $c_1 \sim c_8$ 分别表示在训练 1 中受试者 1、训练 2 中受试者 3 和训练 3 中受试者 6 的关节角度变化。

图 9 关节空间下所提方法与基线方法训练效果对比

Fig.9 Comparison of training performance in joint space between the proposed and baseline methods



注: $a_1 \sim a_3$ 、 $b_1 \sim b_3$ 和 $c_1 \sim c_3$ 分别表示在训练 1 中受试者 1、训练 2 中受试者 3 和训练 3 中受试者 6 的任务空间轨迹变化。

图 10 任务空间下所提方法与基线方法训练效果对比

Fig.10 Comparison of training performance in task space between the proposed and baseline methods

(当前位置到训练轨迹的最短距离) 分别为: 训练 1 对应 6.93 mm、4.10 mm 和 4.85 mm; 训练 2 对应 6.78 mm、4.02 mm 和 5.87 mm; 训练 3 对应 7.58 mm、5.41 mm 和 5.83 mm. 在半主动模式下, 整体偏差较主动模式小. 结合图 12 所示, 此时上肢在机器人辅助下共同完成训练任务, 受试者训练参与度与演示期间相近, 系统刚度调节范围与演示刚度范围接近, 从而保证了训练偏差最小和动作一致性最高. 主动模式下虽然训练参与度最高、系统刚度最大, 并使得势场作用更明显, 但由于缺乏机器人的助推引导作用, 导致垂直方向的力稳定性下降. 然而, 在势场作用下, 轨迹偏移量依然维持在平均 5.52 mm 的范围内, 表明系统在无助推力、高训练参与度情况下仍具备良好的鲁棒性、柔顺性与安全性. 整体来看, 被动模式下的轨迹偏移量最大. 由图 12 可知, 被动训练对应的训练参与度小于演示期间的训练参与度, 导致训练过程整体刚度较低. 由于刚度变低但重力作用不变, 导致整体训练轨迹下移. 然而, 该偏差稳定维持在 7.10 mm 左右, 说明系统在被动训练下具有良好的稳定性和运动一致性. 轨迹偏移量波动较小, 体现了训练过程的稳定可控性. 但我们建议在被动训练中适当增加机器人初始刚度以提高训练刚度的范围, 进而降低重力作

用的影响. 从动作间对比来看, 训练 3 的轨迹偏移量普遍大于训练 1 和训练 2. 这是由于复合运动包含更复杂的多关节协同作用和轨迹路径, 从而导致轨迹偏移量增大. 但即便如此, 系统仍能在不同训练模式下将轨迹偏移量维持在 [5.41, 7.58] mm 范围内, 表明系统在多关节复杂训练下的控制稳定性依然可靠. 以上结果表明, 所提方法在多种交互模式下均能实现良好的柔顺性和控制稳定性, 并能够根据患者的运动能力提供辅助强度可调的个性化、多模式康复训练.

在机器人辅助受试者一同完成训练任务的情况下, 从受试者训练参与度和机器人训练刚度的变化趋势进行分析. 当受试者表现为积极训练、训练参与度较高时 ($R_1 = 12.2 \pm 1.1$, $R_2 = 8.6 \pm 1.5$, $R_3 = 9.6 \pm 1.2$; 其中 1~3 表示动作 1~3), 系统会自适应增加训练刚度 ($K_{d1} \sim K_{d3} \in [176.6, 202.4]$ N/m), 以提高训练强度, 进而增强训练效果. 当检测到受试者训练积极性下降或出现一定程度的肌肉疲劳时 ($R_1 = 7.8 \pm 1.1$, $R_2 = 4.8 \pm 1.0$, $R_3 = 6.0 \pm 0.9$), 系统会降低训练刚度 ($K_{d1} \sim K_{d3} \in [149.8, 179.2]$ N/m), 以增强受试者的主动训练力和机器人的辅助引导作用, 从而降低训练难度, 促进受试者主动训练参与. 当受试者表现为完全肌肉疲劳, 即训练参与度下降至约 2 时, 系统进一步降低刚度, 促使机器人辅助引导效果更加明显, 进入近乎被动的辅助状态. 综上所述, 所提方法可通过实时训练参与度, 自适应调节机器人的训练辅助, 实现对康复训练的按需辅助.

从训练参与度和刚度变化趋势对系统按需辅助的稳定性进行分析. 在主动训练模式下训练参与度最高, 标准差最大, 对应的训练刚度亦最高, 但刚度的误差范围相对较小. 这是由于在高交互情况下, 系统通过衰减长度参数 L_1 、 L_2 与刚度变化系数 Z_1 、 Z_2 的约束, 使刚度变化不会随参与度波动而显著放大, 从而确保主动训练过程的训练稳定性. 半主动模式下的训练参与度略低于主动模式, 但刚度的标准差最大, 反映出系统在该模式下通过更宽的刚度调节区间实现更高的柔顺性与交互适应性, 以促进训练参与. 被动模式的训练参与度最小, 对应刚度误差棒也最小, 表明系统在被动训练中保持较小范围的刚度变化, 体现了无主动训练力下系统较高的训练稳定性.

5 结束语

本文提出一种受治疗师启发的双臂康复框架并验证了其有效性. 实验结果表明, 该框架能够有效




图 11 三种不同模式下训练 1~3 对应的空间轨迹

Fig.11 Spatial trajectories corresponding to training 1~3 under three different modes




图 12 三种不同模式下训练 1~3 的训练参与度与训练刚度之间的关系

Fig.12 Relationship between training participation and training stiffness for training 1~3 under three different modes

地从外部牵引行为和内部交互特性中学习, 并通过按需辅助策略, 实现治疗师般个性化、柔顺且安全的康复训练. 其中双臂牵引实验表明, 该框架具有末端牵引式康复机器人动作适应性强、穿戴简单以及外骨骼式康复机器人精准空间训练的特点, 从而克服了当前两种类型康复机器人的局限性. 此外, 在三种多关节空间运动下验证了所提方法对肩-肘-腕关节协同训练的可行性. 通过模拟患者震颤和痉挛等异常运动, 验证了所提系统的临床稳健性. 最后, 在不同训练参与度下的按需辅助实验进一步验证了所提方法的个性化康复能力.

本研究与当前多数文献一致, 在健康受试者中验证了所提方法的可行性. 与这些研究相比, 本工作的优势在于与医院治疗师合作, 依据治疗师的专业意见和患者的实际康复需求, 对系统进行设计与改进. 同时, 通过模拟震颤、痉挛和疲劳等患者典型的临床表现, 验证了所提系统在临床情境下的稳健性. 然而, 在上肢物理康复领域, 开展面向患者的临床试验依然任重道远. 未来, 我们计划在具备医疗器械注册资质的康复平台上部署所提方案, 以推进临床试验. 此外, 随着人形机器人应用场景的不断拓展, 我们计划将该系统部署至人形机器人平台, 以实现家庭等日常生活环境中的治疗师般康复训练.

参考文献

- Gallucci L, Sperber C, Guggisberg A G, Kaller C P, Heldner M R, Monsch A U, et al. Post-stroke cognitive impairment remains highly prevalent and disabling despite state-of-the-art stroke treatment. *International Journal of Stroke*, 2024, **19**(8): 888–897
- Song X, van de Ven S S, Liu L, Wouda F J, Wang H, Shull P B, et al. Activities of daily living-based rehabilitation system for arm and hand motor function retraining after stroke. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2022, **19**: 621–631
- Li X, He Y, Wang D, Rezaei M J. Stroke rehabilitation: From diagnosis to therapy. *Frontiers in Neurology*, 2024, **15**: Article No. 1402729
- Guatibonza A, Solaque L, Velasco A, Peñuela L. Assistive robotics for upper limb physical rehabilitation: A systematic review and future prospects. *Chinese Journal of Mechanical Engineering*, 2024, **37**(1): Article No. 69
- Diaz F H, Borrás Pinilla C, García Cena C E. Exploring robotic technologies for upper limb rehabilitation: Current status and future directions. *Journal of Sensor and Actuator Networks*, 2025, **14**(3): Article No. 48
- Peng Liang, Hou Zeng-Guang, Wang Chen, Luo Lin-Cong, Wang Wei-Qun. Physical interaction methods for rehabilitation and assistive robots. *Acta Automatica Sinica*, 2018, **44**(11): 2000–2010
(彭亮, 侯增广, 王晨, 罗林聪, 王卫群. 康复辅助机器人及其物理人机交互方法. 自动化学报, 2018, **44**(11): 2000–2010)
- Han S, Wang H, Yu H. Human-robot interaction evaluation-based AAN control for upper limb rehabilitation robots driven by series elastic actuators. *IEEE Transactions on Robotics*, 2023, **39**(5): 3437–3451
- Wang C, Peng L, Hou Z G. A control framework for adaptation of training task and robotic assistance for promoting motor learning with an upper limb rehabilitation robot. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2022, **52**(12): 7737–7747
- Najafi M, Rossa C, Adams K, Tavakoli M. Using potential field function with a velocity field controller to learn and reproduce the therapist's assistance in robot-assisted rehabilitation. *IEEE/ASME Transactions on Mechatronics*, 2020, **25**(3): 1622–1633
- Xie C, Lyu Y, Li G, Tong R K Y, Xia H, Song R, et al. A cable-driven upper limb rehabilitation robot with muscle-synergy-based myoelectric controller. *IEEE Transactions on Robotics*, 2024, **40**: 3199–3211
- Rossa C, Najafi M, Tavakoli M, Adams K. Robotic rehabilitation and assistance for individuals with movement disorders based on a kinematic model of the upper limb. *IEEE Transactions on Medical Robotics and Bionics*, 2021, **3**(1): 190–203
- Wang Xiao-Feng, Li Xing, Wang Jian-Hui. Active interaction exercise control of exoskeleton upper limb rehabilitation robot using model-free adaptive methods. *Acta Automatica Sinica*, 2016, **42**(12): 1899–1914
(王晓峰, 李醒, 王建辉. 基于无模型自适应的外骨骼式上肢康复机器人主动交互训练控制方法. 自动化学报, 2016, **42**(12): 1899–1914)
- Pan J, Astarita D, Baldoni A, Dell'Agnello F, Crea S, Vitiello N, et al. NESM- γ : An upper-limb exoskeleton with compliant actuators for clinical deployment. *IEEE Robotics and Automation Letters*, 2022, **7**(3): 7708–7715
- Zarrin R S, Zeiaee A, Langari R. A variable-admittance assist-as-needed controller for upper-limb rehabilitation exoskeletons. *IEEE Robotics and Automation Letters*, 2024, **9**(6): 113–124
- Zimmermann Y, Sommerhalder M, Wolf P, Riener R, Hutter M. ANYexo 2.0: A fully actuated upper-limb exoskeleton for manipulation and joint-oriented training in all stages of rehabilitation. *IEEE Transactions on Robotics*, 2023, **39**(3): 2131–2150
- Pehlivan A U, Losey D P, O'Malley M K. Minimal assist-as-needed controller for upper limb robotic rehabilitation. *IEEE Transactions on Robotics*, 2015, **32**(1): 5903–5910
- Zhang L, Yu Z, Su P, Li J, Ge R. Design of a parallel wrist rehabilitation robot and analysis of physiological effect on training. *IEEE/ASME Transactions on Mechatronics*, 2024, **29**(5): 3401–3414
- Hussain S, Jamwal P K, van Vliet P, Ghayesh M H. State-of-the-art robotic devices for wrist rehabilitation: Design and control aspects. *IEEE Transactions on Human-Machine Systems*, 2020, **50**(5): 361–372
- Ovur S E, Demir Y. Naturalistic robot-to-human bimanual handover in complex environments through multi-sensor fusion. *IEEE Transactions on Automation Science and Engineering*, 2023, **21**(3): 3730–3741
- Sirintuna D, Ozdamar I, Ajoudani A. Carrying the uncarriable: A deformation-agnostic and human-cooperative framework for unwieldy objects using multiple robots. In: Proceedings of the 2023 IEEE International Conference on Robotics and Automation (ICRA). London, United Kingdom: IEEE, 2023. 7497–7503
- Fan Y, Li X, Zhang K, Qian C, Zhou F, Li T, et al. Learning robust skills for tightly coordinated arms in contact-rich tasks. *IEEE Robotics and Automation Letters*, 2024, **9**(3): 2973–2980
- Ze Y, Chen Z, Wang W, Chen T, He X, Yuan Y, et al. Generalizable humanoid manipulation with 3D diffusion policies. In: Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Hangzhou, China: IEEE,

2025. 2873–2880

23 Lv N, Liu J, Jia Y. Dynamic modeling and control of deformable linear objects for single-arm and dual-arm robot manipulations. *IEEE Transactions on Robotics*, 2022, **38**(4): 2341–2353

24 Yu M, Lv K, Zhong H, Song S, Li X. Global model learning for large deformation control of elastic deformable linear objects: An efficient and adaptive approach. *IEEE Transactions on Robotics*, 2023, **39**(1): 417–436

25 Wang Z, Gan Y, Dai X. Assembly-oriented task sequence planning for a dual-arm robot. *IEEE Robotics and Automation Letters*, 2022, **7**(3): 8455–8462

26 Khansari-Zadeh S M, Khatib O. Learning potential functions from human demonstrations with encapsulated dynamic and compliant behaviors. *Autonomous Robots*, 2017, **41**(1): 45–69



林 高 东北大学机器人科学与工程学院博士研究生. 主要研究方向为 upper-limb 康复机器人, 模式识别, 物理人机交互技术.
E-mail: 2310767@stu.neu.edu.cn
(**LIN Gao** Ph.D. candidate at the Faculty of Robot Science and Engineering, Northeastern University. His research interests include upper-limb rehabilitation robots, pattern recognition, and physical human-robot interaction technology.)



王 斐 东北大学机器人科学与工程学院教授. 主要研究方向为人机交互和人机协助技术, 生机电融合感知与认知. 本文通信作者.
E-mail: wangfei@mail.neu.edu.cn
(**WANG Fei** Professor at the Faculty of Robot Science and Engineering, Northeastern University. His research interests include human-robot interaction and human-robot assistance technologies, and bio-electro-mechanical integrated perception and cognition. Corresponding author of this paper.)



张 鑫 沈阳市第一人民医院康复医学科副主任医师. 主要研究方向为急性脑血管病, 神经康复.
E-mail: zhangxin0321sy@163.com
(**ZHANG Xin** Associate chief physician in the Department of Rehabilitation Medicine, Shenyang First People's Hospital. Her research interests include acute cerebrovascular diseases and neurorehabilitation.)