arXiv:2603.02458v1 [cs.RO] 2 Mar 2026

从治疗师-外骨骼-患者交互中学习治疗师策略

Grayson Snyder、Lorenzo Vianello、Levi Hargrove、Matthew L. Elwin、Jose Pons

摘要——**卒中后患者通常需要接受康复治疗，以恢复正常步态。然而，常见的治疗过程可能令治疗师精疲力竭、身心负担沉重，进而随着时间推移降低治疗强度、时长和连续性。我们提出患者-治疗师力场（PTFF），用于可视化治疗师对患者运动学的响应；并提出合成治疗师（ST）机器学习模型，在治疗师与患者进行机器人介导的双人身体交互治疗时为治疗师提供支持。前者利用变分自编码器（VAE）将患者和治疗师的步态周期运动学编码到共享的低维潜在流形中，并通过高斯混合模型（GMM）对双方的交互进行建模。该模型学习一个概率向量场，将患者的潜在状态映射为治疗师响应。这种表示能够直观呈现患者-治疗师交互的动态特性，为治疗策略和机器人控制器设计提供参考。后者则采用长短期记忆网络（LSTM），通过患者-治疗师交互数据进行训练，根据患者运动学预测治疗师施加的关节力矩。该模型使用八名卒中后患者的数据进行训练，并通过留一交叉验证进行验证；随后将其集成到基于机器人操作系统（ROS）的外骨骼控制器中，根据预测的治疗师响应实时生成力矩辅助。离线结果和初步测试表明，这些方法有望成为卒中后外骨骼治疗的替代方案。PTFF有助于理解治疗师的操作，而ST则使治疗师无需再直接操作外骨骼，从而能够持续监测患者细微的状况变化。**

I. 引言

在物理治疗中，运动障碍患者往往依赖治疗师直接提供身体辅助，以恢复行动能力并改善运动功能 [1]。目前的干预主要侧重于由物理治疗师实施的高强度步态训练 [2]。例如，在卒中后步态康复过程中，治疗师经常引导患者进行足部放置，以纠正异常的行走模式。

这种方法需要治疗师付出大量体力，可能导致工伤 [3] ，并限制他们提供全身引导和评估的能力。由于在全身交互过程中需要与患者的多个接触点进行互动，训练通常需要多名治疗师协调干预，同时处理多个关节 [4]。

下肢外骨骼可支持高强度多关节步态康复，减轻治疗师付出的努力、支撑患者体重，并提供客观的表现测量指标 [2], [5], [6]。常见的控制策略包括按需辅助，沿预定义轨迹引导患者，以支持学习 [2], [7], [8], ；以及误差增强，通过引入阻力或偏差促进适应 [9], [10]。

然而，在外骨骼治疗中，如何确定最佳参考轨迹，以及如何调节适当的辅助或阻力水平，仍是有待解决的难题 [2], [11]。在实践中，许多系统依赖基于健全人步态得出的预定义轨迹，无法适应个体患者损伤。此外，固定的辅助水平可能无法反映患者不断变化的运动能力，而当前的控制策略往往未能充分利用治疗师的专业知识，无法进行细致的实时调整 [12]。因此，治疗师在治疗过程中调节引导的能力有限，这可能会降低功能获益，并阻碍基于外骨骼的康复在临床上的应用 [8], [13]。

物理人-机器人-人交互（pHRHI）利用机器人设备介导人与人之间的物理交互，将人类的运动认知技能与机器人的能力相结合 [14], [15]。在 pHRHI 中，两名用户分别与独立的机器人交互，这些机器人通过虚拟弹簧和阻尼器相连，使每位用户都能感知并响应另一位用户的动作。在上肢 [16], [17] 和下肢 [18]–[22] 任务中的研究已在健康人群中取得了令人鼓舞的成果，表明其能够改善运动表现并提高参与度。近期研究也报告了上肢任务在卒中后人群中的积极结果 [23]。在我们此前的工作中，我们验证了这一方法用于下肢康复的可行性：通过虚拟连接两台外骨骼，实现一名治疗师与八名卒中后患者之间的交互 [24]。

因此，通过深入分析患者与治疗师在临床相关康复练习中虚拟连接时收集的数据，我们提出了一种初步方法，利用 pHRHI 交互，通过机器学习技术捕捉治疗师的专业知识，该技术能够（1）识别治疗师矫正策略；（2）重现这些动作，以便在延长的训练过程中为治疗师提供支持或部分替代治疗师。

本研究的贡献有两方面：（1）我们提出患者-治疗师力场（PTFF），这是一种将治疗师对患者运动学的响应可视化的新方法，从而更好地理解治疗师在治疗过程中的动作与决策；（2）一种合成治疗师（合成治疗师），它从患者-治疗师示范中学习，并基于患者运动学的短时历史推断治疗师的响应。这两种方法均已在先前收集的八名卒中后患者的数据上得到验证，并有潜力更好地理解治疗师的动作，在

通讯作者：lvianello@sralab.org G. Snyder、M. Elwin 任职于美国伊利诺伊州埃文斯顿西北大学机器人与生物系统中心。L. Vianello、L. Hargrove 和 J. Pons 任职于美国伊利诺伊州芝加哥雪莉·瑞安能力实验室腿部与步行实验室。

治疗的同时，使治疗师摆脱外骨骼。图1展示了本工作所呈现的整体架构。

本文结构如下：在第二节中，我们定义治疗师策略的概念，回顾试图识别并重建此类策略的初步研究，并呈现一份先前收集的、涵盖八名卒中后患者的整体数据集，以支持策略的创建。第三节描述所提出的两种方法，即PTFF和合成治疗师。本文最后在第四节对结果进行验证，并讨论这两种方法。

II. 背景

在本节中，我们讨论创建治疗师策略时的问题（第II-A节），以及此前为理解和建模治疗师策略所做的尝试（$\pi(.)$）（第II-B节）；而在下一节（第II-C节）中，我们呈现可能使我们能够对所讨论的全部信息进行编码的初步数据。

A. 治疗师策略

机器学习已被广泛用于控制下肢外骨骼 [25]。其中，诸如[26]等方法可在不同活动中回归用户辅助等级，为健康人群和患者群体提供辅助。然而，在康复疗程中定义最优控制策略是一项更具差异性的任务，因为每位患者都有特定需求，治疗师必须在每次疗程中加以识别 [27], [28]。例如，治疗师常常选择辅助一个关节并抵抗另一个关节。我们将治疗师策略 定义为一个函数 $\pi : \mathcal{S}_p \rightarrow \mathcal{A}_t$ ，该函数在给定当前患者状态 $s_p \in S_p$时返回治疗师动作$a_t \in \mathcal{A}_t \subset \mathbb{R}^m$。对此类策略的理解及其后续设计仍是一个开放性研究问题。

有几个障碍阻碍了人们系统地理解治疗师在与患者互动时所做的选择。其中一个挑战是设计患者状态空间（$\mathcal{S}_p \subset \mathbb{R}^n$），使其包含多种特征，即功能障碍程度及其部位、由此产生的运动学、动力学和动态特性，甚至情绪和生理方面。这些方面会导致表征的维度很高；也就是说，状态空间具有较大的 n。同样，设计治疗师动作空间（$\mathcal{A}_t \subset \mathbb{R}^m$）也很困难，该空间需要编码治疗师可执行的多通道动作（身体、视觉和声音动作），并使整个系统具备可控性。换言之，哪些动作能让治疗师引导患者达到最佳状态 s_p^*? 另一项挑战是需要确保患者和治疗师具有较高的可测量性。运动学信息可以轻松地从摄像机或惯性系统中提取 [29]，而动力学信息则需要通过肌电图等负担较重的测量方式获取[30]。测量情绪信息、动态特性以及治疗师与患者之间交换的精确作用力，也会带来额外困难 [31]。

B. 相关工作

Luciani等人 [32], [33] 提出了一种示教学习（LbD）框架，首先估计治疗师使用上肢外骨骼操控患者手臂时施加的力。随后利用这些数据学习患者与治疗师之间的交互模型。

同样，在 [34] 中，采用示教学习，基于扩散策略训练模型，使用治疗师—患者二人组与下肢外骨骼连接时采集的数据。其机器学习模型旨在即使治疗师不在场，也能复现治疗师策略，但由于依赖单一患者的数据且推理时间较长，容易过拟合。我们采用不同类型的模型，并使用更多患者的数据进行训练，旨在将推理时间缩短至实时水平，并打造一个可适用于不同患者的泛化能力更强的系统。

此外，先前所有方法都对治疗师动作进行端到端回归，却没有深入分析双方物理交互的机理属性。虽然这条路径更耗时，但它能够通过避免治疗师采取意外且危险的动作来提高安全性，有助于调试，并帮助揭示运动学习机制。朝此方向迈出的第一步，是对患者状态进行最简表示（s_p）。Shushtari [35] 提出了交互画像（IP），可用于以极坐标形式呈现人机外骨骼交互。这种方法能够在易于理解的二维坐标系中展现患者的动态行为，但同时缺乏对治疗师如何响应这些行为的清晰呈现。

C. 治疗师—外骨骼—患者数据集

在我们先前的研究中 [24]，我们对图 1 所示的两台下肢外骨骼（X2，傅利叶智能）进行了改造，以实现用于步态治疗的机器人介导物理交互框架。每台外骨骼都会呈现一个虚拟交互介质，该介质建模为治疗师与患者的髋关节和膝关节之间的扭转弹簧—阻尼元件。每位用户都可以调节这些元件，以设定触觉反馈的强度。训练期间，治疗师和患者面对面站立，双方相对的腿部通过虚拟方式耦合（治疗师的左/右腿与患者的右/左腿相连）。利用交互元件属性和瞬时关节状态（t：治疗师， p：患者），计算每个关节所需的交互力矩：

$$\hat{\tau}_t^* = K_t(\tilde{\theta}_p - \theta_t) + B_t(\dot{\tilde{\theta}}_p - \dot{\theta}_t), \quad (1)$$

$$\hat{\tau}_p^* = K_p(\tilde{\theta}_t - \theta_p) + B_p(\dot{\tilde{\theta}}_t - \dot{\theta}_p), \quad (2)$$

其中，$\hat{\tau}_i^*$： $i \in t,\ p$ 分别为治疗师和患者外骨骼所需的交互力矩；（$K_i,\ B_i$）：$i \in t,\ p$ 分别为刚度和阻尼分量；（$\theta_i,\ \theta_i$）$\tilde{\cdot}$ $\tilde{}$以及（$\theta_i,\ \theta_i$）： $i \in t,\ p$ 分别为两条相对腿的关节角度和速度。按照 [20]所示，将每位用户各关节所需的交互力矩指令发送至对应的外骨骼。

我们先前工作中的开源数据集 [24]包含 8 名慢性偏瘫性脑卒中患者（发病后 > 6 个月），均由同一位持证物理治疗师进行训练。每个二元组（治疗师和患者）进行了三

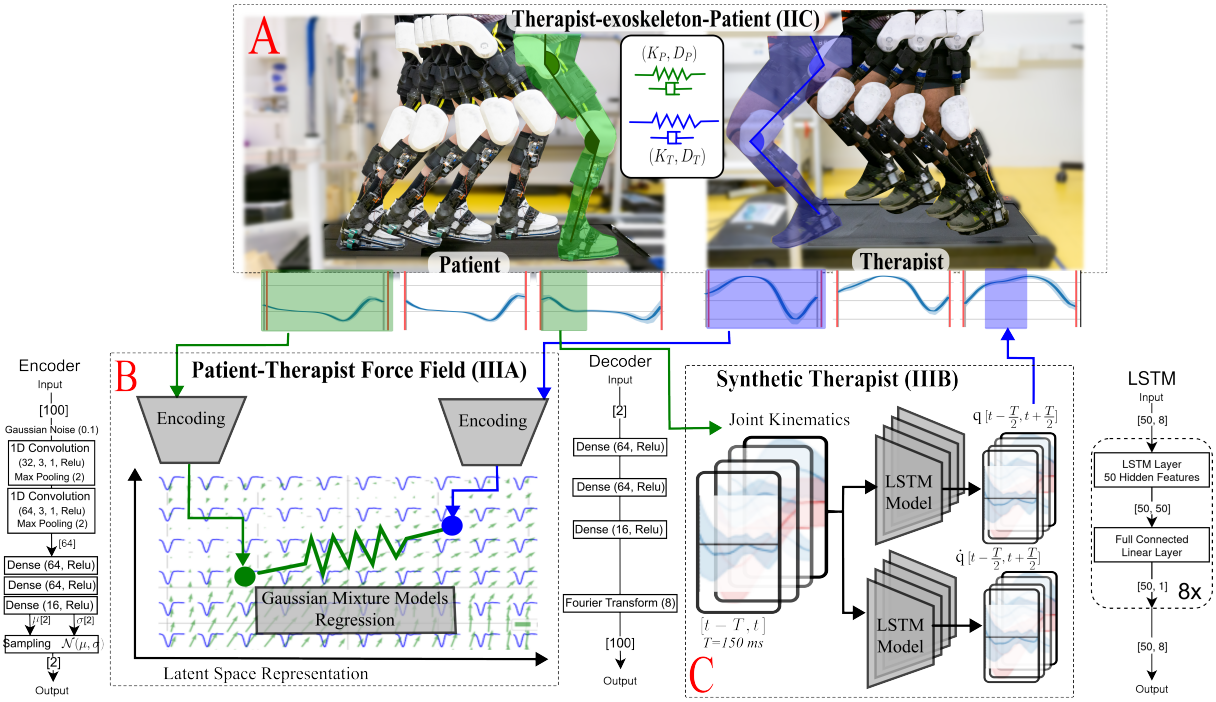

图1：从治疗师–外骨骼–患者交互中学习治疗师策略。(A) 通过两台下肢外骨骼采集的治疗师–外骨骼–患者物理交互数据集。外骨骼通过虚拟弹簧连接患者和治疗师的关节构型。(B) 患者–治疗师力场，以患者和治疗师的步态周期为输入，提取潜在表示，并在较低维度的空间中学习连接二者的力场。该模型采用编码器–解码器架构（图中均有显示）以降低维度。(C) 合成治疗师，以患者的关节运动学为输入，预测相应的治疗师运动学数据。该模型采用长短期记忆网络（LSTM）（图中显示）来推断治疗师的轨迹。

次训练，每次训练持续 10 分钟，期间休息 3 分钟。训练期间，治疗师通过虚拟外骨骼连接和听觉提示提供辅助。在训练阶段之间，治疗师可以调整触觉反馈（即，K_t 在公式 2 中），以便于控制。外骨骼运动学通过髋部和膝部编码器以 333 Hz 的频率记录，同时背包上的惯性测量单元测量躯干方向。

III. 方法

本节介绍本文提出的两个框架，即患者-治疗师力场和合成治疗师。

A. 患者-治疗师力场

PTFF 能够在二维空间中直观呈现患者和治疗师的步态周期执行情况。该方法依赖两个连续的机制：(1) 使用变分自编码器 (VAE) 降低患者和治疗师步态周期的维度；(2) 使用高斯混合模型 (GMM) 学习描述患者和治疗师的低维潜在表示之间关系的力场。在本节中，我们首先介绍如何处理先前收集的数据集（第II-C节），以及如何训练 VAE 并用其提取潜在表示和潜在空间流形。最后，我们将讨论所提出力场的训练和验证。

1) 数据准备：数据通过同步患者和治疗师运动学数据进行处理（q_T，q_P）。所有步态周期均根据患者的足跟着地进行分段，足跟着地通过足板传感器检测与地面的接触来确定。针对每条腿，分别对左、右步态周期进行分段；每个步态周期均由髋关节和膝关节的运动学运动组成 $s = (s_h, s_k) \in \mathbb{R}^{(2,100)}$，并以足跟着地作为起点和终点。异常步态周期定义为超出第 90 百分位数的步态周期，已将其移除。随后将左、右步态周期合并为一个数据集$S \subset \mathbb{R}^{(2,100)}$，共得到 12K 个患者步态周期及其对应的治疗师步态周期。对于每个步态周期，还存储了若干额外特征以便进行后处理，包括步态周期归属（患者或治疗师）、患者 ID、腿侧（左或右）、患者与治疗师步态周期之间的对应关系（$s^p \leftrightarrow s^t$），以及施加于患者和治疗师双方的刚度值（K_p, K_t）。预处理后，使用均值和标准差对所有步态周期进行归一化，并按 70/30 的比例划分为训练集和验证集。

2) 降维：为了可视化所有步态周期（患者和治疗师，双腿）的分布，我们采用降维技术，将每个高维步态周期 $s \in S$ 映射到二维潜在空间表示$z \in Z \subset \mathbb{R}^2$。若干降维

技术得到了评估，包括主成分分析、自编码器和变分自编码器。其中，变分自编码器因三项关键优势而被选中：（i）能够构建紧凑的、呈正态分布的潜在空间；（ii）能够准确重建原始步态周期；（iii）对未见数据具有较强的泛化能力。

VAE 的架构如图1所示。它由编码器（$f:\ \mathbb{R}^{100} \rightarrow \mathbb{R}^2$）和解码器（$f^{-1}:\mathbb{R}^2 \rightarrow \mathbb{R}^{100}$）组成。编码器将高维步态周期映射为紧凑的潜在表示，而解码器则反转这一映射，从潜在空间重建完整的步态周期。VAE 通过自回归方式进行训练：将输入步态周期（按批次处理）与其重建结果进行比较，并使用均方误差作为损失函数。

编码器以步态周期 s 为输入，并依次通过两个交替设置最大池化层的一维卷积层，随后经过一组全连接层。这些层输出潜在分布的参数，即均值（$z_\mu \in \mathbb{R}^2$）和标准差（$z_\sigma \in \mathbb{R}^2$），并用它们采样得到二维潜在表示 z。随后，解码器通过一系列全连接层扩展低维潜在空间，从而重建步态周期。最后一层生成（$a,\ b$）$\in \mathbb{R}^n$个系数，用于加权傅里叶基函数

$$\hat{s}(\tau) = \sum_{k=1}^{n/2} \Big(a_k \cos(\frac{2\pi k\tau}{100}) + b_k \sin(\frac{2\pi k\tau}{100}) \Big), \tau \in [0, 100]. \tag{3}$$

这种基于傅里叶的重建方法可确保重建的步态周期平滑且连续，忠实保留步态的周期性。每个关节（髋关节和膝关节）均独立建模，因此分别建立了两个变分自编码器。我们通过分别考察各个关节，进行了初步优化阶段，以微调每个变分自编码器的参数。最终用于训练的参数集汇总于图 1。每个模型均使用先前收集的数据集 [28]进行预训练，随后以批量大小为 256 训练 1000 轮次，并采用耐心值为 20 轮次的早停准则，以防止过拟合并确保泛化能力。

3）力场构建：使用先前训练的编码器降低步态数据集S的维度，得到潜在空间表示 $Z = f(S)$。随后利用该潜在空间计算患者与治疗师之间的虚拟交互力，如下所示：

$$F_p = K_p\,(z_t - z_p), \tag{4}$$

$$F_t = K_t\,(z_p - z_t), \tag{5}$$

其中，z_t 和 z_p 分别表示治疗师和患者运动学的潜在空间表示，而 K_p 和K_t 则分别是与患者和治疗师外骨骼相关的刚度参数。

每个力场均针对每个关节独立计算。所得数据集（Z, F_i）包含关节运动学的潜在空间表示及相应的虚拟力，并被划分为训练集和验证集。

随后使用高斯混合模型（高斯混合模型）学习联合分布：

$$p(z_p, F) = \sum_{k=1}^{K} \pi_k, \mathcal{N}\big([z_p, F]^T \mid \mu_k, \Sigma_k\big), \tag{6}$$

其中，K 表示用于拟合模型的高斯分量数量。为防止过拟合，参数在验证集上进行了优化，最终模型采用了 $K = 10$。

训练完高斯混合模型后，可以重构潜在空间中的完整力场，如图 2 所示。首先，在潜在空间内均匀采样一组点 Z_s，其范围由潜变量 $Z_s \sim U$ 的最小值和最大值定义（min(z)，max(z)）。随后，将这些采样得到的潜在点输入解码器，以重构相应的步态周期（$S_s = f^{-1}(Z_s)$）。最后，对于每个潜在点，根据训练好的高斯混合模型推断期望的交互作用力，表示为 $F = \mathbb{E}[F \mid z]$。在采样潜在空间中，将重构的步态周期 S_s 及其对应的作用力 F 相结合，即可实现连续力场的可视化。该方法全面呈现了治疗师-患者交互动力学，捕捉校正作用力在潜在空间不同区域中的变化，并支持后续对患者特定康复策略进行分析或仿真。

B. 合成治疗师

本节介绍我们如何利用先前收集的患者-治疗师交互数据，为卒中后康复创建合成治疗师（ST）。我们采用长短期记忆网络（LSTM）模型，以捕捉患者与治疗师运动学数据之间的长期依赖关系。我们通过对八名卒中后患者进行留一交叉验证来验证该方法，并借助机器人操作系统（ROS）将其集成到外骨骼控制器中。我们首先介绍数据处理，然后介绍模型设计、训练、验证以及 ROS 集成。

1) 数据处理：第二节 C 中介绍的数据集已在时间上对患者和治疗师进行了对齐。在数据集包含的所有特征中，我们仅保留了以下数据：患者关节位置（$q_p \in \mathbb{R}^4$）和速度（$\dot{q}_p \in \mathbb{R}^4$），以及治疗师关节位置（$q_t \in \mathbb{R}^4$）和速度（$\dot{q}_t \in \mathbb{R}^4$）。在与包含其他参数（例如重量分布 $\alpha \in \mathbb{R}$和交互力矩 $\tau_{int} \in \mathbb{R}^4$）的不同模型进行比较后，我们决定重点关注这些特征。纳入其他特征可能会提供更多有关患者运动学和动态特性的信息；然而，由于用于数据收集的传感器存在局限性，也可能引入额外噪声，具体而言，这些传感器包括力敏电阻（FSR）和应变计。收集更多数据有助于减轻这种噪声的影响。

时间数据被分割为长度固定的滑动窗口，每个窗口包含 50 个时间步，对应时间域中约 150 毫秒。每个

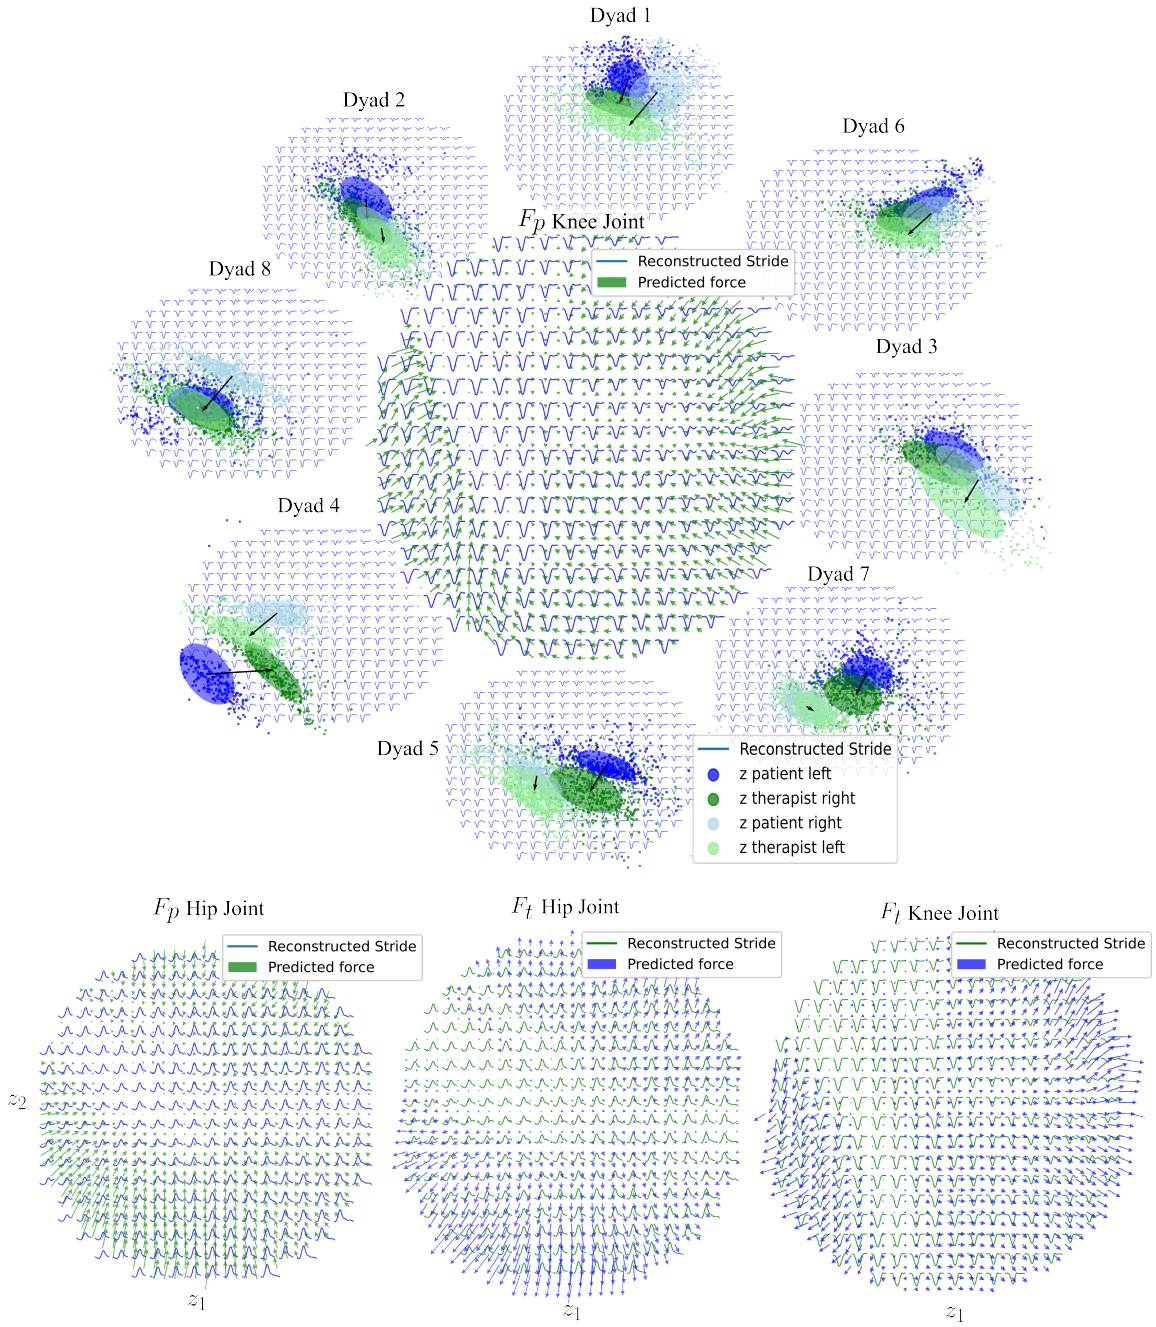

图 2：**上方：**每个二元组的潜在空间表示。每个点代表一个步态周期，椭球显示其分布。蓝色：患者左侧步态周期；绿色：治疗师右侧步态周期；浅蓝色：患者右侧步态周期；浅绿色：治疗师左侧步态周期。连接关系为镜像（患者左侧、治疗师右侧）。中间是使用高斯混合模型拟合所有二元组后计算得到的力场。**下方：**力场（从左到右）：患者髋关节、治疗师髋关节、患者膝关节、治疗师膝关节。

窗口以 10 个时间步（即 30 毫秒）为步长移动。选择 150 毫秒的滑动窗口，是为了在实现快速推理与保留足够数据以提取相关特征之间取得平衡，同时仅关注当前步态周期的运动学信息，避免依赖先前步态周期的信息。训练 ST 模型时使用了一个记忆窗口，其中一半与输入数据重叠，以便学习患者的步态模式；另一半则延伸至输入数据之后，从而进行未来预测。具体而言，给定患者

在间隔 $[t-T,t]$ 、 $T=150$ 毫秒内，合成治疗师根据窗口$[t-\frac{T}{2},t+\frac{T}{2}]$推理治疗师运动学数据。用于推理的确切时间点可根据应用场景和训练要求而有所不同。例如，合成治疗师可以仅利用时间点 t的预测提供引导性响应，也可以结合未来时间步的预测提供主动辅助。这种灵活性使治疗师能够根据患者的需求和治疗目标调整机器人辅助的程度。最后，对于模型训练、验证和测试

流程，针对每个患者-治疗师配对，分别按照 70–20–10 划分数据。

2）模型结构与训练：使用八个独立的长短期记忆网络模型分别预测每一项治疗师特征（q_t， $\dot{q}_t$）。每个模型均在 PyTorch 中实现，并接收长度为 50 的滑动窗口内的八项患者特征（q_p， $\dot{q}_p$）。所得输入张量的维度为（50,8）。输入首先由长短期记忆网络处理，随后传入线性层，如图1所示。模型的输出是针对特定特征的未来治疗师运动学数据（50，1）。模型参数通过初步启发式搜索进行优化，而独立训练每一项特征的决定旨在降低输出相关性，并已在初步实验中得到验证。

每个模型均独立训练 150 个训练轮次，并在每个训练轮次进行验证，采用批量大小为 256、样本打乱以及 Adam 优化器中的学习率 1×10^{-5}。随后将八个已训练模型合并为一个模型，并脚本化以便进行性能优化与部署。合并后的模型接收完整的患者运动学（50，8），并返回该时间窗口的治疗师运动学数据（50，8）。

合成治疗师采用留一法进行验证：模型经过多次迭代训练，每次使用八名患者中的七名进行训练，并在剩余的一名患者上进行测试。该方法用于考察模型对在不同实验条件下采集的未见数据的泛化能力。在留一法中，窗口大小与ST模型保持一致，为50个时间步，其中点为患者输入数据之后的下一个时间步。在计算合成治疗师预测相对于真实治疗师数据的均方根误差时，整个窗口用于生成一个数据点，这意味着最终的均方根误差包含所有时间步上全部窗口的信息。

3) 机器人操作系统集成：该模型被集成到当前的外骨骼控制器中，以验证推理时间，并支持未来训练方案的初步实现。具体而言，我们开发了基于机器人操作系统的合成治疗师集成方案，该方案接收来自外骨骼的患者运动学数据，并推断相应的治疗师行为。使用最大长度为50（与滑动窗口一致）的环形缓冲区来存储传入的患者外骨骼关节运动学数据，同时节点以333 Hz的速率运行模型推理，以匹配传入数据的频率。机器人操作系统集成在离线采集的数据以及来自外骨骼的实时流数据上均得到了验证。

IV. 结果与讨论

A. 患者-治疗师力场

变分自编码器对整体数据集的关节运动学进行重建，髋关节的均方根误差为 4.54 ± 1.65度（均值均方根误差 ±标准差），膝关节为 4.20 ± 2.14。这些结果因步态周期来源不同而存在显著差异。对于患者，总体均方根误差为 4.57 ± 1.73，而对于治疗师则为 4.67 ± 1.68。这种变异性甚至更大

		均方根误差（度，度/秒）	
训练/验证集	测试集	位置平均值	速度平均值
PT_{1-8}	PT_{1-8}	4.30 ± 0.41	20.67 ± 1.47
PT_{2-8}	PT_1	5.93 ± 1.20	25.13 ± 4.54
$PT_{1,3-8}$	PT_2	5.77 ± 1.12	25.47 ± 5.03
$PT_{1,2,4-8}$	PT_3	6.48 ± 0.67	33.62 ± 3.87
$PT_{1-3,5-8}$	PT_4	4.95 ± 1.00	20.66 ± 1.70
$PT_{1-4,\ 6-8}$	PT_5	3.76 ± 0.15	18.27 ± 1.08
物理治疗师$_{1-5,\ 7,\ 8}$	PT_6	5.07 ± 1.22	23.38 ± 2.06
物理治疗师$_{1-6}$,8	PT_7	4.43 ± 0.98	19.51 ± 1.21
物理治疗师$_{1-7}$	PT_8	4.00 ± 0.43	19.51 ± 1.61

表 I：长短期记忆网络模型对关节位置和关节速度进行预测的均方根误差（rMSE）均值所表示的预测准确度。我们进行了跨用户泛化评估：每次使用除一名用户（PT_i）之外的所有用户进行训练，并在被排除的用户上进行测试。

在逐一检查每位患者并比较左腿与右腿时。例如，患者4的左腿均方根误差为 3.18 ± 0.95 ，右腿为 5.09 ± 1.44 ，而治疗师相应腿的数值分别为 3.58 ± 1.14和 4.76 ± 1.10。这些差异可归因于患者的步态周期与平均步态轮廓相差的程度，并可能作为功能障碍程度的指标。与此同时，治疗师试图过度补偿患者的运动学，这也会导致异常的步态模式。

虽然潜在特征由变分自编码器自动选出，但其表示揭示了若干有趣的属性。首先，部分患者左右腿潜在位置之间的距离（如图 2 上方所示）凸显了其步态模式的不对称性。例如，患者 4 的距离是患者 5 的三倍多。其次， z_1 坐标编码了膝关节屈曲时机的偏移，而 z_2则表示其幅度，这表明这两个指标可作为表示步态模式的有意义潜在特征。最后，尽管同一位治疗师对所有患者进行了训练，但治疗师的潜在轮廓会因患者而异。例如，对于患者 1，治疗师运动学的潜在表示位于潜在空间的右上半球；而对于患者 4，则位于相反的半球。这一结果表明，治疗师会调整其运动学，而非仅仅呈现自然步态，并会根据每位患者的具体需求进行调整——且针对每条腿分别调整。

图 2 展示了两个力场：带有虚拟力 F_p 的患者力场和带有虚拟力 F_t的治疗师力场，涵盖髋关节和膝关节。高斯混合模型对力场分布进行拟合，髋关节和膝关节的对数似然分别为-4.4 ± 2.15 和 -4.75 ± 1.90 。从患者力场图中可以看出，某些区域会成为患者运动学的吸引子。也就是说，治疗师试图引导患者进入特定的运动学区域，这些区域被认为具有更大的临床相关性。相反，治疗师力场表明，治疗师感知到的触觉反馈会将其推离这些相同的区域。

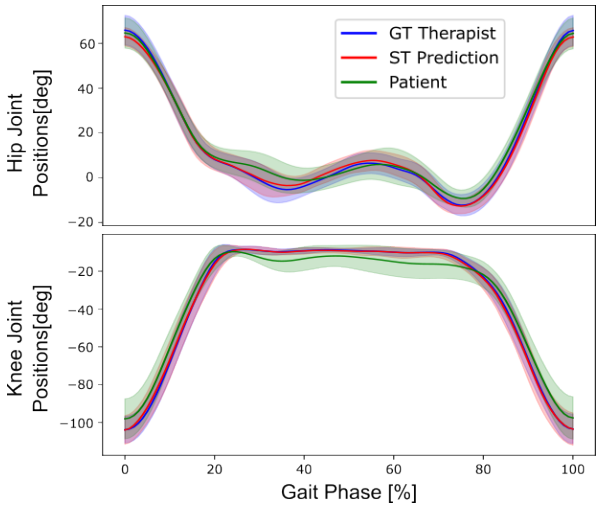

图 3：合成治疗师预测结果示例（预测未来 75 ms），与相应的真实治疗师数据和患者数据叠加显示。上方为髋关节，下方为膝关节。

乍看之下，这两个力场似乎是对称的（即 $F_t = -F_p$），但在许多实验场景中，治疗师刚度是患者刚度经过缩放（降低）后的版本。这些刚度参数由治疗师在训练过程中选择，而可视化结果初步展示了此类参数的选择方式。一种假设是，治疗师在行走时可能会有意改变自身“不稳定区域”的形状，同时希望在其他临床相关区域获得强烈的触觉反馈。尽管这些图仅仅是可视化此类行为的第一步，但它们可为未来设计治疗师刚度自适应调节策略的方法奠定基础。

B. 合成治疗师

表 I 展示了留一法的结果。为概括八个模型的数据，我们报告四项位置和速度均方根误差的均值。

留一法中的每个模型对未见过的患者数据进行了预测，准确度各不相同，这可能是由患者功能障碍程度、患者与治疗师之间的协调性或患者关节活动范围造成的。PT_5 在关节位置和速度方面的均方根误差均最低，表明与其他患者相比，该患者采集的数据与训练集更为相似；而 PT_3,的位置和速度指标均表现最差，尽管整个数据采集过程中使用的是同一位治疗师。无论如何，位置均方根误差的最小值与最大值相差不到 3 度，速度均方根误差的差值略高于每秒 15 度。因此，所有留一模型的位置均方根误差均值为 5.05 ± 0.85 度，速度均方根误差均值为 23.19 ± 2.64 度/秒。

ST以 4.30 ± 0.41度的关节位置和 20.67 ± 1.47度/秒的关节速度预测治疗师对患者输入数据的反应。ST模型在所有患者数据集上训练，并在所有患者测试数据的汇总集上进行测试（模型此前未见过这些数据），其关节位置和速度的均方根误差均值低于大多数留一法模型，表明它能够跨患者泛化。

图3展示了合成治疗师在一个步态模式中对髋关节和膝关节进行预测的示例。所有患者均观察到类似结果。对于髋关节（上图），模型预测与真实运动学数据之间的最大偏差出现在支撑期，该阶段因患者对地面交互和重心转移的反应不同而更具变异性。此外，重心转移过程中力敏电阻传感器的噪声可能在支撑腿中引入振荡伪影，这一效应在髋关节中更为明显：与膝关节（下图）相比，髋关节预测往往更偏离目标值，这可能是由于膝关节惯性较低，从而减少了振荡行为。

合成治疗师被集成到一个ROS节点中，用于关节运动学的实时预测，从而能够在实际训练环节中进行后续验证。使用Intel Core i9-14900HX CPU，该模型的平均推理时间不到3毫秒，处于期望范围内，并支持333Hz的流式频率，以实现实时部署。

V. 结论

在本研究中，我们提出两种新颖方法：1）一种患者-治疗师力场，用于可视化治疗师对患者运动学的响应，从而更好地理解治疗师策略。该方法将变分自编码器与高斯混合回归相结合：前者学习表征患者与治疗师关节运动学的潜在特征，后者对吸引治疗师与患者之间这些特征的力场进行建模。该方法有望揭示治疗师的策略，并为新型康复机器人控制器的设计提供依据。

2）一种 合成治疗师，它从患者–治疗师示范中学习，利用长短期记忆网络和滑动时间窗口推断治疗师响应。合成治疗师可预测未来最多75 ms的治疗师响应，推理时间不足3 ms，并已集成到ROS节点中，嵌入患者外骨骼控制回路，以提供期望的关节角度和速度，从而产生交互力矩。未来工作包括对训练集中的同一批卒中后患者以及新患者实时测试所提出的方法。

这两种方法都可以通过进一步收集数据，更好地了解其泛化能力。此外，针对不同患者群体和不同机械连接开展实验，有助于阐明连接参数（即刚度和阻尼）的作用。

参考文献

[1] A.-S. Rudberg, E. Berge, A.-C. Laska, S. Jutterstr¨om, P. N¨asman, K. S. Sunnerhagen, and E. Lundstr¨om, 《卒中幸存者对卒中后生活相关研究的优先事项》

，《卒中康复专题》，第 28 卷，第 2 期，第 153–158 页，2021 年。[2] J.-M. Belda-Lois, S. Mena-del Horno, I. Bermejo-Bosch, J. C. Moreno, J. L. Pons, D. Farina, M. Iosa, M. Molinari, F. Tamburella, A. Ramos 等，《卒中后步态康复：迈向自上而下方法的综述》，《神经工程与康复杂志》，第 8 卷，第 1–20 页，2011 年。[3] B. McCrory, J. M. Burnfield, A. R. Darragh, J. L. Meza, S. L. Irons, P. Chernyavskiy, A. M. Link, and G. Brusola，《物理康复治疗师的工伤》，载于《人因与工效学学会年会论文集》，第 58 卷。SAGE 出版社，SAGE CA：洛杉矶，CA，2014 年，第 1072–1076 页。[4] K. M. Stephan and D. P´erennou，《卒中后的行动能力：重新学习行走》，《卒中康复临床路径：循证临床实践建议》，第 123–147 页，2021 年。[5] T. Moeller, F. Moehler, J. Krell-Roesch, M. De˘zman, C. Marquardt, T. Asfour, T. Stein, and A. Woll，《将下肢外骨骼用作人体运动表现评估工具：系统综述》，《传感器》，第 23 卷，第 6 期，第 3032 页，2023 年。[6] R. Gassert and V. Dietz，《用于治疗感觉运动缺陷的康复机器人：神经生理学视角》，《神经工程与康复杂志》，第 15 卷，第 1 期，第 1–15 页，2018 年。[7] B. Hobbs and P. Artemiadis，《机器人辅助下肢卒中治疗综述：步态康复中尚未探索的路径与未来方向》，《神经机器人学前沿》，第 14 卷，第 19 页，2020 年。[8] R. Baud, A. R. Manzoori, A. Ijspeert, and M. Bouri，《辅助步态的下肢外骨骼控制策略综述》，《神经工程与康复杂志》，第 18 卷，第 1 期，第 1–34 页，2021 年。[9] L. Marchal-Crespo, P. Tsangaridis, D. Obwegeser, S. Maggioni, and R. Riener，《学习修正后的步态模式时，触觉误差调节优于视觉误差放大》，《神经科学前沿》，第 13 卷，第 61 页，2019 年。[10] L. Marchal-Crespo and D. J. Reinkensmeyer，《神经损伤后机器人辅助运动训练控制策略综述》，《神经工程与康复杂志》，第 6 卷，第 1 期，2009 年。[11] [ ] 10 1186 1743 0003 6 20 在线。可访问：https://doi.org/ 。 / - - - J. Zhang, P. Fiers, K. A. Witte, R. W. Jackson, K. L. Poggensee, C. G. Atkeson, and S. H. Collins，《行走期间外骨骼辅助的人在回路优化》，《科学》，第 356 卷，第 6344 期，第 1280–1284 页，2017 年。[12] C. J. Hasson, J. Manczurowsky, E. C. Collins, and M. Yarossi，《神经康复机器人技术：治疗师应拥有多少控制权？》，《人类神经科学前沿》，第 17 卷，第 1179418 页，2023 年。[13] C. Celian, V. Swanson, M. Shah, C. Newman, B. Fowler-King, S. Gallik, K. Reilly, D. J. Reinkensmeyer, J. Patton, and M. R. Rafferty，《生命中的一天：临床决策与神经康复技术应用的定性研究》，《神经工程与康复杂志》，第 18 卷，第 1 期，第 1–12 页，2021 年。[14] E. B. K¨uç¨uktabak, S. J. Kim, Y. Wen, K. Lynch, and J. L. Pons，《运动控制与康复中的人机人交互：综述》，《神经工程与康复杂志》，第 18 卷，第 1 期，第 183 页，2021 年 12 月。 [在线]。可访问：https://doi.org/ 10 1186 12984 021 00974 5 。 /s - - - L. Vianello, M. Short, J. Manczurowsky, E. B. Kucuktabak, F. Di Tommaso, A. Noccaro, L. Bandini, S. Clark, A. Fiorenza, F. Lunardini 等，《康复中的机器人介导身体人际交互：立场论文》，《IEEE 生物医学工程评论》，2025 年。[16] N. Beckers, E. H. F. van Asseldonk, and H. van der Kooij，《触觉人际交互无法改善个体的视觉运动适应》，《科学报告》，第 10 卷，第 1 期，第 19902 页，2020 年 11 月。[在线]。可访问：https://doi.org/10.1038/s41598-020-76706-x [17] S. Kager, A. Hussain, A. Cherpin, A. Melendez-Calderon, A. Takagi, S. Endo, E. Burdet, S. Hirche, M. H. Ang, and D. Campolo，《二元交互中的技能水平匹配对描迹任务学习的影响》，IEEE 国际康复机器人会议，第 2019 年 6 月卷，第 824–829 页，2019 年。[18] M. R. Short, D. Ludvig, E. B. K¨uç¨uktabak, Y. Wen, L. Vianello, E. J. Perreault, L. Hargrove, K. Lynch, and J. L. Pons，《踝关节跟踪任务中的触觉人际交互：虚拟连接刚度的影响》，IEEE 神经系统与康复工程汇刊，第 31 卷，第 3864–3873 页，2023 年。[19] M. R. Short, D. Ludvig, F. Di Tommaso, L. Vianello, E. B. K¨uç¨uktabak, E. J. Perreault, L. Hargrove, K. Lynch, E. Burdet, and J. L. Pons，《二元组中单向与双向交互的影响踝关节和腕关节追踪”，IEEE 神经系统与康复工程汇刊，2025。[20] E. B. K¨uç¨uktabak、Y. Wen、M. Short、E. Demirbas、K. Lynch 和 J. Pons，“两台下肢外骨骼的虚拟物理耦合”，载于2023年国际康复机器人会议（ICORR），2023年，第1–6页。[21] L. Vianello、E. B. K¨uç¨uktabak、M. Short、C. Lhoste、L. Amato、K. Lynch 和 J. Pons，“外骨骼介导的坐站康复任务中的人际物理交互”，载于2024年IEEE机器人与自动化国际会议（ICRA）。IEEE，2024年，第4521–4527页。[22] M. H. Koh、S.-C. Yen、L. Y. Leung、S. Gans、K. Sullivan、Y. Adibnia、M. Pavel 和 C. J. Hasson，“利用遥操作机器人技术开展感觉运动康复：运动具身化”，《神经工程与康复杂志》，第18卷，第1–21页，2021年。[23] E. L. Waters、R. J. Mendonca、P. Z. Cacchione 和 M. J. Johnson，“Theradyad：用于多用户卒中康复的经济型机器人的可行性”，载于2024年第十届IEEE RAS/EMBS生物医学机器人与生物机电一体化国际会议（BioRob）。IEEE，2024年，第1498–1503页。[24] E. B. K¨uç¨uktabak、M. R. Short、L. Vianello、D. Ludvig、L. Hargrove、K. Lynch 和 J. Pons，“治疗师—外骨骼—患者交互：沉浸式步态治疗”，arXiv预印本 arXiv:2507.16059，2025年。[25] O. Coser、C. Tamantini、P. Soda 和 L. Zollo，“基于人工智能的下肢外骨骼辅助康复方法：综述”，《机器人与人工智能前沿》，第11卷，文章号1341580，2024年。[26] D. D. Molinaro、K. L. Scherpereel、E. B. Schonhaut、G. Evangelopoulos、M. K. Shepherd 和 A. J. Young，“通过生物关节力矩估计实现任务无关的外骨骼控制”，《自然》，第635卷，第8038期，第337–344页，2024年。[27] K. L. Poggensee 和 S. H. Collins，“适应、训练和个性化如何共同促成外骨骼辅助带来的益处”，《科学·机器人学》，第6卷，第58期，文章号eabf1078，2021年。[28] C. Lhoste、A. Cant´on、E. B. K¨uç¨uktabak、M. R. Short、R. Schwane-mann、S. Clark、D. Ludvig、K. Lynch、L. Hargrove、J. Tornero 等，“用于辅助五种行走模式的下肢外骨骼基准数据集”，《神经工程与康复杂志》，2025年。[29] J. Bartloff、F. Lanotte、M. K. O’Brien 和 A. Jayaraman，“利用可穿戴技术推进步态康复：现状与未来方向”，《医疗器械专家评论》，暂定接受，2025年。[30] M. Munoz-Novoa、M. B. Kristoffersen、K. S. Sunnerhagen、A. Naber、M. Alt Murphy 和 M. Ortiz-Catalan，“基于表面肌电图的上肢卒中康复：系统综述与荟萃分析”，《人类神经科学前沿》，第16卷，文章号897870，2022年。[31] J. A. Galvez、G. Kerdanyan、S. Maneekobkunwong、R. Weber、M. Scott、S. J. Harkema 和 D. J. Reinkensmeyer，“测量人类训练师的技能，以设计更优的脊髓损伤后步态训练机器人控制算法”，载于第九届国际康复机器人会议，2005年。IEEE，2005年，第231–234页。[32] B. Luciani、S. Costante、F. Braghin、A. Pedrocchi 和 M. Gandolla，“利用高斯混合模型和动态运动基元对康复外骨骼进行模仿学习：比较研究”，载于2024年第十届IEEE RAS/EMBS生物医学机器人与生物机电一体化国际会议（BioRob）。IEEE，2024年，第122–127页。[33] B. Luciani、M. Sommerhalder、M. Gandolla、P. Wolf、F. Braghi 和 R. Riener，“治疗师用于上肢康复外骨骼的力轮廓示教与模仿方法”，IEEE 医疗机器人与仿生学汇刊，2024年。[34] A. Sankar、E. B. Kucuktabak、C. Lhoste、M. Short、L. Vianello 和 J. Pons，“用于在外骨骼辅助双人康复中学习治疗师行为的动作扩散”，载于国际神经康复会议，2024年11月。[在线]。网址：https://hal.science/hal-05141147 [35] M. Shushtari、J. Foellmer 和 A. Arami，“人类—外骨骼交互图谱”，《神经工程与康复杂志》，第21卷，第1期，文章号152，2024年。