

DOI: 10.13382/j.jemi.B2609314

下肢康复机器人生物-机械信号跨模态步态预测模型*

阎妍 宋永献 马泽宇

(南京晓庄学院电子工程学院 南京 211171)

摘要:针对下肢康复机器人在复杂运动环境下因多源传感器信号互相干扰导致的感知精度低、轨迹追踪鲁棒性差等问题,研究了多源传感器信号的自适应融合与建模方法,提出一种动态门控驱动的生物-机械信号跨模态步态(gate-temporal attention contextual dynamics, Gate-TACD)预测模型。模型搭建了双分支特征提取架构,生物分支通过融合表面肌电信号的运动意图与量角器提供的关节静态背景特征,捕捉人体的生物-姿态状态;机械动力学分支提取惯性测量单元的时序上下文特征。设计动态门控机制,通过实时自适应调节生物与机械模态特征对步态估计的贡献权重,抑制传感器滑移等工况下的信号互扰与表征失真。构造基于生物力学最小抖动原理(minimum jerk principle)的物理启发式损失函数,在遵循人体运动学规律的前提下约束预测轨迹,确保输出步态的连续性与顺滑性。基于Camargo数据集的多地形实验结果表明, Gate-TACD模型展现出较好的预测性能,决定系数 R^2 最高达0.99,常规工况下均方根误差(root mean squared error, RMSE)多稳定在 $0.3^\circ \sim 0.7^\circ$,显著优于长短期记忆网络与门控循环单元模型。特别是在引入传感器滑移噪声的恶劣工况下,模型的平均RMSE仅为 1.31° ,相较于单一机械动力学模态模型预测误差降低约16%。该研究为下肢康复机器人的智能控制与实时追踪提供了一种兼具高精度与高鲁棒性的跨模态感知方案。

关键词: 下肢康复机器人;步态预测;跨模态深度学习;动态门控机制;最小抖动原理

中图分类号: TN98 **文献标识码:** A **国家标准学科分类代码:** 510.40

Cross-modal gait prediction model based on bio-mechanical signals for lower-limb rehabilitation robots

Yan Yan Song Yongxian Ma Zeyu

(School of Electronic Engineering, Nanjing Xiaozhuang University, Nanjing 211171, China)

Abstract: To address the challenges of low perception accuracy and poor trajectory tracking robustness in lower-limb rehabilitation robots, which are primarily caused by the mutual interference of multi-source sensor signals in complex environments, this paper investigates adaptive fusion methods and modeling mechanisms for multi-source information. A dynamic gating-driven bio-mechanical cross-modal gait prediction model, termed Gate-TACD, is proposed. The model features a dual-branch feature extraction architecture: the physiological branch fuses motion intent from surface electromyography (sEMG) with joint static background features provided by a goniometer to capture the human bio-postural state; meanwhile, the kinematic branch extracts temporal context features from inertial measurement units (IMUs). A dynamic gating mechanism is designed to adaptively regulate the contribution weights of biological and mechanical modalities in real-time, thereby suppressing signal crosstalk and representation distortion under adverse conditions such as sensor slip. Furthermore, a physics-informed loss function based on the minimum jerk principle is constructed to constrain the predicted trajectories within the bounds of human kinematics, ensuring the continuity and smoothness of the output gait. Experimental results on the Camargo dataset across multiple terrains demonstrate that Gate-TACD achieves superior predictive performance, with the coefficient of determination R^2 reaching up to 0.99 and the root mean square error (RMSE) consistently staying between 0.3° and 0.7° under normal conditions, significantly outperforming baseline LSTM and GRU models. Notably, in challenging scenarios involving sensor slip noise, the model maintains a mean RMSE of only 1.31° , representing a 16% reduction in prediction error compared to unimodal kinematic

收稿日期:2026-04-29 Received Date: 2026-04-29

* 基金项目:江苏省高等学校基础科学(自然科学)研究面上项目(23KJD510007)资助

models. This research provides a high-precision and robust cross-modal perception framework for the intelligent control and real-time tracking of lower-limb rehabilitation robots.

Keywords: lower limb rehabilitation robot; gait prediction; cross-modal deep learning; dynamic gating mechanism; minimum jerk principle

0 引言

随着全球人口老龄化加剧及现代生活方式的转变,由脑卒中、脊髓损伤及慢性运动损伤导致的下肢功能障碍已成为全球公共卫生领域的重要问题^[1]。在康复医学领域,早期、高强度且具有针对性的康复训练被认为是促进神经可塑性重建与步态协调性恢复的关键。然而,传统依靠物理治疗师手工操作的康复模式面临资源严重匮乏、劳动强度大且个体化程度低等局限性。在此背景下,下肢康复机器人凭借其轨迹可控、重复性高及运动数据可量化等优势,已成为辅助康复与智能人机交互领域的研究热点^[2]。

尽管下肢康复机器人发展迅速,实现柔顺自然的人机交互仍面临挑战。现有方法多依赖预设轨迹,缺乏对运动意图的实时感知,导致人机匹配度不足^[3]。当前运动意图识别主要依赖机械动力学信号和生物本体信号,前者包括惯性测量单元(inertial measurement unit, IMU)信号、足底压力信号等,后者包括表面肌电信号(surface electromyography, sEMG)等。其中,机械信号在复杂环境下易受滑移与振动干扰产生偏差^[4];而 sEMG 虽能反映神经肌肉驱动意图,但受非平稳性影响,难以单独支撑稳定预测^[5-6]。尽管近年来以长短期记忆网络(long short-term memory, LSTM)、Transformer 为代表的深度学习模型在时序预测中展现出较强能力^[7],但这些纯数据驱动的“黑盒”模型往往忽略了生物力学约束,导致预测轨迹在遇到突发扰动时易出现非生理性的高频抖动,严重影响下肢康复机器人的运行安全性与交互舒适度^[8-9]。

近年来,多模态融合已成为克服单模态传感器局限性、提升意图识别鲁棒性的核心路径。密歇根大学的 Camargo 等^[10]于 2021 年发布了目前该领域最全面的生物力学数据集,通过大规模对比实验揭示了深度递归神经网络在跨模态时序建模中的有效性。Huang 等^[11]基于视觉姿态数据预测与步态稳定性相关的多项生物力学指标,实现了跌倒风险的间接评估。Wang 等^[12]通过融合患侧关节振动信号与健侧肌电信号,验证了多源信息融合在预测精度方面的优势。Zhang 等^[13]提出基于时空注意力机制的多模态融合网络,通过专门的编码器和层次化注意力机制,有效整合多源异构信息以提升步态重建精度。

在国内,跨模态异构信号的处理研究正向着自适应与强鲁棒性发展。颜兵兵等^[14]提出一种融合足底压力与姿态信息的步态相位识别方法,识别率突破 97%。刘景源等^[15]面向智能穿戴场景,提出了融合表面肌电信号与惯性测量单元的步态及相位识别方法。李沐等^[16]提出融合运动姿态与表面肌电信号的多流神经网络模型。现有研究在多源信息融合方面已取得一定进展,但在复杂工况下的自适应融合能力与鲁棒性仍有待进一步提升。

尽管深度学习在拟合精度上表现出色,但其端到端的回归过程往往忽略了人体运动的物理本质,导致预测结果缺乏生物力学一致性。Flash 与 Hogan^[17]提出的最小抖动原理(minimum jerk principle)奠定了人体运动轨迹平滑性的理论基础,近期如何将其与深度神经网络结合成为研究热点。Shushtari 等^[18]在训练初期加入 Jerk Penalty(加加速度惩罚项),引导模型生成更自然的运动轨迹。Giannattasio 等^[19]基于最小加加速度规划生成踝关节参考轨迹,实现自适应外骨骼控制。然而,上述研究多侧重于单一物理维度的规律建模,忽视生理意图与复杂地形间的动态关联,导致模型在多工况切换时泛化能力受限。

针对下肢康复机器人感知系统在复杂环境下,难以有效融合多源传感器信息,从而引发信号干扰的问题。本文提出一种动态门控驱动的生物-机械信号跨模态步态预测模型(gate-temporal attention contextual dynamics, Gate-TACD)。生物分支融合 sEMG 的主动意图信号与量角器(goniometer)的姿态特征,确立步态预测的生理基准;而机械分支专注于从 IMU 序列中深度挖掘运动的时序逻辑,实现对复杂上下文信息的有效捕捉。设计动态门控机制,自适应调节生物与机械模态对预测结果的贡献权重,以抑制复杂工况下的信号干扰。搭建基于最小抖动原理的物理启发式损失函数,以约束预测轨迹的连续性与平滑性。最后,经开源数据集实验及 t 分布随机邻域嵌入(t-distributed stochastic neighbor embedding, t-SNE)特征可视化分析,验证模型的有效性。

1 跨模态深度学习架构

针对下肢康复机器人在复杂工况下多源传感器信号表征冲突的问题,本文提出 Gate-TACD 跨模态步态预测模型。模型利用深度学习的特征建模能力,将生物信号

的预见性与机械信号的实时性进行协同表征,实现跨模态信息的有效融合。模型整体由3个核心模块构成:特征提取层、动态门控融合层以及基于生物力学约束的回归层,完成从原始多源信号到关节角度预测的端到端映射。

1.1 跨模态特征融合架构

Gate-TACD 模型采用双分支输入结构,分别处理生物意图信号与机械运动上下文。

生物分支:定义输入序列为 $\mathbf{X}_{bio} = [\mathbf{x}_{emg}, \mathbf{x}_{gon}]$, 其中, $\mathbf{x}_{emg}$ 为经全波整流及低滤波后的 sEMG 包络信号, $\mathbf{x}_{gon}$ 为量角器采集的下肢关节静态位置特征。通过多层感知机 (multilayer perceptron, MLP) 将其映射至高维空间,提取瞬时生物状态特征 $\mathbf{f}_{bio}$:

$$\mathbf{f}_{bio} = \text{RELU}(\mathbf{W}_b \mathbf{X}_{bio} + \mathbf{b}_b) \quad (1)$$

机械分支:针对 IMU 序列的非线性时序特性,采用

门控循环单元 (gated recurrent unit, GRU)。GRU 能够有效提取步态循环中的动态加速度与角速度变化特征,捕捉步态循环中的演变规律,为模型提供环境背景感知能力^[20]。给定时间窗口 T 内的物理序列 $\mathbf{X}_{imu} = \{\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_T\}$, GRU 的隐状态更新公式为:

$$\mathbf{r}_t = \sigma(\mathbf{W}_r[\mathbf{h}_{t-1}, \mathbf{s}_t] + \mathbf{b}_r) \quad (2)$$

$$\mathbf{z}_t = \sigma(\mathbf{W}_z[\mathbf{h}_{t-1}, \mathbf{s}_t] + \mathbf{b}_z) \quad (3)$$

$$\tilde{\mathbf{h}}_t = \tanh(\mathbf{W}_{\tilde{h}}[\mathbf{r}_t \odot \mathbf{h}_{t-1}, \mathbf{s}_t] + \mathbf{b}_{\tilde{h}}) \quad (4)$$

$$\mathbf{h}_t = (1 - \mathbf{z}_t) \odot \mathbf{h}_{t-1} + \mathbf{z}_t \odot \tilde{\mathbf{h}}_t \quad (5)$$

式中: $\mathbf{W}$ 代表权重矩阵; $\mathbf{b}$ 代表偏置项; σ 为 Sigmoid 激活函数; $\odot$ 为 Hadamard 积。最终提取末端隐状态 $\mathbf{h}_T$ 作为环境背景特征 $\mathbf{f}_{ctx}$ 。特征融合层将两个分支的特征向量进行级联,并通过多层 MLP 回归器输出预测的关节角度。Gate-TACD 模型结构如图 1 所示。




图 1 Gate-TACD 模型结构

Fig. 1 Structure of the Gate-TACD model

由图 1 可见, Gate-TACD 通过 3 个核心模块实现从原始信号到运动轨迹的端到端映射。首先,多模态输入经双分支特征提取层分别建模生物语义与机械运动时序特征;其次,动态门控融合层在生理意图引导下自适应调节生物与机械模态的融合权重,以增强复杂工况下的鲁棒性;最后,回归输出层结合物理启发式损失函数进行优化,从而保证预测轨迹的平滑性与生物力学一致性。

1.2 基于门控机制的自适应特征融合

模型的核心在于动态门控权重 w 的生成。该权重不再是静态的参数,而是由生物分支的即时能量状态驱动

的变量。

门控信号生成:利用拼接后的特征向量计算注意力

得分 s :

$$s = \mathbf{W}_g[\mathbf{f}_{bio}, \mathbf{f}_{ctx}] + \mathbf{b}_g \quad (6)$$

通过 Sigmoid 函数将得分归一化为门控权重 $w \in (0, 1)$:

$$w = \frac{1}{1 + e^{-s}} \quad (7)$$

特征重分配:门控权重 w 直接作用于机械动力学分支特征,而生物分支则作为辅助特征直接输入:

$$\mathbf{F}_{fused} = \text{Concat}[\mathbf{f}_{ctx} \odot (1 - w), \mathbf{f}_{bio}] \quad (8)$$

在步态转换或剧烈运动阶段,生物信号 $\mathbf{f}_{bio}$ 能量激增

导致权重 w 正向拉升,此时 $(1-w)$ 减小,动态抑制了机械模态在剧烈运动下产生的失真与滞后,优先捕获由中枢神经驱动的主动运动意图。本质上,门控机制可视为对模态重要性的动态加权估计。

1.3 物理启发式 Jerk 约束损失函数

在预实验中发现,虽然深度学习模型能实现较低的均方误差,但预测曲线常伴随非生理性的震荡,这会直接导致下肢康复机器人外骨骼驱动器产生抖动,不仅损耗电机,更会引发用户的不适感。

基于生物力学中的最小抖动原理,人类在平滑运动时会自然优化运动轨迹,使角加速度的变化率,即 Jerk 值最小化。本文将这一物理先验转化为正则化约束,构建一个由预测精度和轨迹平滑度共同构成的联合损失函数。

采用均方差约束预测值与真实角度的偏差作为损失函数:

$$L_{MSE} = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2 \quad (9)$$

基于最小抖动原理, Jerk 可表示为关节角度关于时间的三阶导数。对于离散采样的关节角度预测序列,本文采用三阶有限差分近似 Jerk,并构造轨迹平滑约束项:

$$L_{jerk} = \frac{1}{T-3} \sum_{t=4}^T \left(\frac{\hat{y}_t - 3\hat{y}_{t-1} + 3\hat{y}_{t-2} - \hat{y}_{t-3}}{\Delta t^3} \right)^2 \quad (10)$$

最终优化目标:

$$L_{total} = L_{mse} + \alpha L_{jerk} \quad (11)$$

式中: T 为时间序列长度; $\hat{y}_t$ 为第 t 个采样时刻的预测关节角度; Δt 为相邻采样点之间的时间间隔, α 为超参数,用于平衡预测精度与轨迹平滑度。通过引入 Jerk 约束,模型在降低预测误差的同时,可抑制非生理性的高频抖动,使预测轨迹更加平滑并符合人体运动规律。Gate-TACD 模型流程如图 2 所示。

如图 2 所示,模型首先对生物与机械两类输入信号进行分支编码,分别提取生理状态特征与时序动态信息;随后通过门控机制实现跨模态特征的自适应融合,并结合时序注意力进一步强化关键阶段信息;最终输出连续的关节角度预测结果,并通过权重可视化揭示模型对不同时段的重要性分配。

2 实验结果与分析

为了全面、客观地验证 Gate-TACD 模型在康复机器人下肢步态预测任务中的实际性能,本文开展多维度的对比验证实验。实验选取包含多种地形工况的生物力学数据集,从定量误差评估、长序列预测稳定性以及深层特征表征能力等多个层面,系统性地对比本文模型与主流




图 2 Gate-TACD 网络流程图

Fig. 2 Workflow of the Gate-TACD network

深度学习算法 (LSTM^[21]、GRU) 的差异。

2.1 实验数据集与评价指标

本研究采用由佐治亚理工学院 EPIC 实验室提供的 Camargo 等^[10]公开的大规模生物力学数据集。该数据集专门用于康复机器人下肢外骨骼与假肢的控制算法研究,具有极高的公认定与数据规范性。数据集包含 22 名受试者 (12 名女性, 10 名男性), 平均年龄为 22.2 ± 4 岁, 平均身高为 173.0 ± 8.9 cm, 平均体重为 70.1 ± 12.0 kg。虽然原始数据集涵盖了多种连续地形, 但针对本文研究重点, 提取受试者在平地步行 (level)、楼梯攀爬 (stair) 以及稳态跑步机 (treadmill) 3 种核心工况下的同步数据。

本文采用 RMSE 与 R^2 作为评估模型追踪精度的核心指标。其中, RMSE 用于衡量预测误差大小, R^2 用于反映模型拟合程度。

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (12)$$

决定系数 R^2 的计算公式如式(13)所示。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (13)$$

式中: y_i 为真实角度; $\hat{y}_i$ 为 Gate-TACD 模型预测角度; $\bar{y}$ 为真实角度的平均值。

2.2 不同模型长序列预测对比分析

为了全面评估 Gate-TACD 模型在复杂地形下的连续运动预测性能,首先开展长序列步态轨迹预测对比实验。楼梯地形由于其包含剧烈的关节角度起伏和复杂的肌肉收缩模式,是检验康复机器人步态预测模型性能最重要的场景。通过提取包含多个步态周期的长序列样本(2 000 个采样点),将 Gate-TACD 模型的输出轨迹与基于逆运动学的真实角度以及两种主流深度神经网络(LSTM、GRU)进行直观对比,实验结果如图3所示。

通过观察图3可知,在长达2 000个采样点的连续测试中, Gate-TACD 模型与真实角度表现出极高的一致性。相比之下,深度学习模型 LSTM 和 GRU 虽然能捕捉整体趋势,但在整个时间轴上频繁出现预测幅值偏离和不规





图3 长序列下不同模型的关节角度预测轨迹对比(楼梯工况)

Fig. 3 Comparison of joint angle prediction trajectories of different models under long sequence (stair)


则震荡。这表明 Gate-TACD 模型在处理长时、连续的步态数据时具有更强的稳定性。

楼梯地形的关节角度变化具有明显的非线性特征。观察 500~750 样本点以及 1 600~1 800 样本点动态区间可以发现, LSTM 与 GRU 模型在角度极大值和极小值处出现了显著的峰值衰减现象。而 Gate-TACD 凭借生物特征驱动的门控机制,能够更精准地还原这些运动极端时刻。这对于下肢康复机器人的实时辅助至关重要,因为峰值通常对应着步态转换的关键受力点。

为了进一步验证 Gate-TACD 模型在不同运动环境下的泛化性能,引入平地与跑步机两种典型工况进行对比分析,实验结果如图4所示。



(a) 平地工况
(a) Level



(b) 跑步机工况
(b) Treadmill

图4 长序列下不同模型的关节角度预测轨迹对比

Fig. 4 Comparison of joint angle prediction trajectories of different models under long sequence

在平地与跑步机两种典型工况的长序列预测对比图中, Gate-TACD 模型在 2 000 个采样点范围内均展现出最优的预测性能,其轨迹与真实值保持高度一致性。相比之下,最常用的 LSTM 与 GRU 模型在运动特征剧烈波动时表现出显著的滞后与幅度衰减,且在跑步机的高频微震干扰下预测曲线不够平滑。实验结果表明, Gate-TACD 模型通过门控机制有效融合生物和机械动力学特征,不

仅能够精准捕捉步态极值点,且在长时评估中未出现累计误差偏移,证明其在不同行走环境下均具有较好的预测稳定性。

尽管上述预测结果已展现出极高的预测精度,但为了更客观、定量地衡量算法在处理不同个体及复杂环境时的通用性,本研究进一步随机挑选 3 名受试者(Subject 06、08 及 10)开展全工况下的 RMSE 与 R^2 对比实验。实

验结果如表 1、2 所示。

由表 1 和 2 的定量实验结果可知, Gate-TACD 模型

表 1 不同地形工况下各模型的关节角度预测误差 RMSE 对比

Table 1 Comparison of joint angle prediction RMSE of various models under different terrain conditions (°)				
受试者	地形(工况)	LSTM RMSE	GRU RMSE	Gate-TACD RMSE
06	level	1.246 7	1.350 9	0.304 2
	stair	2.009 1	2.249 3	0.345 3
	treadmill	0.933 4	0.935 7	0.434 6
08	level	2.633 1	2.659 1	0.463 4
	stair	2.859 3	2.913 3	0.387 8
	treadmill	1.349 2	1.355 6	0.636 1
10	level	4.900 4	5.063 4	1.112 5
	stair	3.785 9	3.842 3	0.754 2
	treadmill	1.536 7	1.469 9	0.825 0

表 2 不同地形工况下各模型的关节角度预测决定系数 R^2 对比(无量纲)

Table 2 Comparison of the coefficient of determination R^2 for joint angle prediction by various models under different terrain conditions				
受试者	地形(工况)	LSTM R^2	GRU R^2	Gate-TACD R^2
06	level	0.691	0.685	0.982
	stair	0.497	0.401	0.983
	treadmill	0.476	0.474	0.853
08	level	0.562	0.531	0.986
	stair	0.552	0.532	0.990
	treadmill	0.356	0.354	0.854
10	level	0.409	0.369	0.970
	stair	0.240	0.271	0.970
	treadmill	0.451	0.498	0.842

在不同受试者及典型地形工况下,预测性能均大幅领先于 LSTM 和 GRU 模型。在平地、楼梯及跑步机等工况下,本文方法展现出极高的拟合精度,决定系数 R^2 最高可达 0.990,而对比的深度神经网络在多数复杂工况下的 R^2 甚至低于 0.5。在误差控制方面,本文方法将 RMSE 稳定控制在 $0.3^{\circ}\sim1.15^{\circ}$,实现精度的跨越式提升。特别值得注意的是,在信号非平稳性极强的受试者 10 的平地测试中,当对比模型因难以捕获复杂的跨模态关联导致 RMSE 飙升至 5.0° 左右时, Gate-TACD 凭借门控机制对生物与机械动力学特征的非对称融合与自适应权衡,依然将误差压制在 1.1125° 的较低水平。这有力证明双分支架构能有效抑制康复机器人在复杂环境下的观测噪声,在处理个体步态特征差异及多变地形干扰方面具备卓越的鲁棒性与准确性。

2.3 地形切换动态响应分析

在人体连续运动过程中,地形的突然改变,如从平地踏上楼梯,会导致生物力学信号产生非平稳的瞬态波动,这对下肢康复机器人步态预测模型的实时自适应能力提出了挑战。为了验证 Gate-TACD 模型在地形剧烈切换时的动态响应速度与跟踪稳定性,进行地形切换动态响应

分析实验,实验结果如图 5 所示。




图 5 不同地形切换过程中的动态响应对比分析
Fig. 5 Comparative analysis of dynamic response in different terrain switching process

在不同地形切换过程中的动态响应实验中,本文提出的 Gate-TACD 模型在 $T=500\text{ ms}$ 的工况转换瞬时表现出卓越的自适应能力与跟踪精度。观察对比曲线可见,当运动状态从平地行走切换至上下楼梯时,作为对照组的 LSTM 和 GRU 模型均出现显著的预测滞后与幅值偏差,甚至在切换初期产生较长时间的调整波动,这揭示了单纯的深度学习模型在面对模态信号突变时,往往难以

快速识别复杂的时空非线性特征。

相比之下, Gate-TACD 模型凭借跨模态特征融合架构,通过内置门控单元实时优化多维传感信息的权重分配,特别是生物本体分支中的运动意图预见性,从而在运动发生剧烈变化前实现预测逻辑的平滑过渡。这种生物驱动机械的融合机制确保预测轨迹在动态过渡区间依然能与真实值保持高度一致,不仅解决传统模型在地形切换点的精度崩塌问题,更显著增强下肢康复机器人系统的泛化能力。

2.4 决策机制可视化与门控权重分析

由于人体在复杂地形行走时, IMU 信号、sEMG 信号与 Goniometer 信号的贡献度随步态周期动态变化,仅通过 RMSE 这类宏观评估指标难以解释模型如何协同不同模态。因此,本实验通过提取并对比门控调节权重 w 与生物特征能量强度的实时关联性,直观展示模型在肌肉爆发点等关键时段如何自动增加生物模态权重,实验结果如图 6 所示。




图 6 Gate-TACD 内部门控调节权重分析图

Fig. 6 Internal gating-weight analysis of Gate-TACD

由图 6(a) 可知,在上下楼梯这种高强度肢体运动场景中, Gate-TACD 模型展现出极强的生物信号敏感度。当样本序列进入肌肉发力密集的阶段时,生物模态 (sEMG 与 Goniometer) 的归一化能量迅速增加,这种能量激增被门控机制捕获,并直接转化为门控调节权重 w 的正向拉升。

这种权重变化并非简单的数值叠加,而是反映了模

型对特征重要性的动态调整,使系统能够跨越传感器在剧烈运动下可能产生的振荡或延迟,优先捕捉由神经驱动的主动运动意图。随着步态周期进入能量消耗较低的摆动期,门控决策逻辑表现出向机械惯性约束的快速回归。此时权重 w 迅速向蓝色区域偏移,模型将预测依据转向更为稳健的 IMU 惯性序列上。这种权重曲线与生物能量曲线在时间轴上的高度重合,证明本文模型不仅具备对复杂地形轨迹的拟合能力,更拥有生物学上的可解释性,即能够在主动驱动与被动约束之间进行平衡,从而在地形切换点附近表现出远超 LSTM 和 GRU 等基础模型的实时响应速度与运动轨迹贴合度。

为了避免偶然性结果,对跑步机地形进行决策机制可视化,如图 6(b) 所示, Gate-TACD 模型中的门控网络成功建立从生物特征能量到跨模态融合权重的正向映射。门控权重的动态走势与生物特征能量高度一致,证明模型能够精准感知人体的主动发力状态,并在肌肉爆发点自动提升生物特征的融合比重,权重上升至 0.8 左右,从而实现符合人体生物力学逻辑的动态自适应调整。

2.5 消融对比分析实验

为了定量评估 Gate-TACD 模型中各模块对下肢关节角度预测精度的贡献,设计一系列消融实验,通过构建两个退化的基准模型与全功能 Gate-TACD 模型,在受试者 06 数据集上进行对比分析。

其中, Bio-Only 变体通过移除动态上下文分支,即 IMU 序列输入,保留了由 sEMG 与量角器构成的生物分支,验证在缺乏上下文信息的情况下,仅依靠生物意图与静态姿态特征进行预测的性能局限性。而 IMU-Only 变体则切断生物分支的输入,使模型退化为纯机械信号驱动的递归神经网络架构,以此验证在缺乏生理运动意图引导的情况下,系统应对传感器漂移噪声及环境随机干扰的鲁棒性表现。实验结果如表 3 与图 7 所示。

表 3 Gate-TACD 模型及其消融模型的步态预测 RMSE 性能对比

Table 3 Comparison of gait prediction RMSE between Gate-TACD model and ablation model (°)				
实验环境	模型版本	Level RMSE	Stair RMSE	Treadmill RMSE
理想环境	Bio-Only	0.501 0	0.747 8	0.609 0
	IMU-only	0.661 2	0.649 8	0.629 5
	Gate-TACD	0.649 2	0.739 2	0.571 9
噪声环境	Bio-Only	1.525 6	2.086 2	0.905 7
	IMU-only	1.591 4	2.193 0	0.902 4
	Gate-TACD	1.345 1	1.757 6	0.833 7

由表 3 和图 7 可知,不同实验环境下各模型的性能表现存在明显差异。在理想环境中,如图 7(a) 所示,由于传感器信号质量较高, sEMG、Goniometer 与 IMU 等信号均能够较稳定地反映人体运动状态,因此单一传感器

输入与多传感器联合输入之间并不存在绝对优劣关系。不同模型在 Level、Stair 和 Treadmill 工况下表现出各有优势的结果,说明在外界扰动较弱、信号采集较稳定的条件下,模型性能更多受具体运动场景、传感器响应特性以及数据分布差异影响,而不能简单判断单模态方法或跨模态融合方法哪一种必然更优。

然而,在噪声环境中,如图 7(b) 所示,单模态模型的预测误差明显增加,尤其是 IMU-only 模型在 Level 和 Stair 工况下出现较大误差波动,表明机械动力学信号对传感器滑移和外界扰动较为敏感。相比之下, Gate-TACD 能够通过门控机制自适应调整生物模态与机械模态的融合权重,在机械信号受扰动时提高生物意图信息的贡献,从而降低异常机械信号对预测结果的影响。实验结果显示, Gate-TACD 在噪声环境下 3 个工况均取得最低 RMSE,平均误差为 1.312 1°,相比 IMU-only 机械动力学单模态模型,平均 RMSE 降低约 16.0%。因此,本文方法的优势主要体现在复杂扰动环境中的稳定性、抗干扰能力和鲁棒预测能力。




图 7 消融实验步态预测对比分析
Fig. 7 Comparative analysis of gait prediction in the ablation experiment

2.6 跨模态融合特征的可视化分析

为进一步从高维特征空间维度分析 Gate-TACD 模型对不同地形工况的表征能力与判别效果,本节进行跨模态融合特征的 t-SNE 可视化实验。通过将模型提取的高维融合特征映射至二维低维空间,直观展示其在平地、楼梯工况下的特征分布规律,实验结果如图 8 所示。

图 8 展示了 Gate-TACD 模型在平地与楼梯两类工况下提取的跨模态融合特征分布。可以看出,降维后的特征点并未呈现随机离散分布,而是在二维空间中形成了连续的轨迹型流形结构。对于平地工况,特征点整体分布较为平滑,点云之间连接紧密,说明平地行走过程中关节角度变化相对稳定,模型提取的特征能够保持较好的时序连续性。对于楼梯工况,特征分布呈现出更明显的弯曲和分段特征,反映出上下楼梯过程中关节角度变化幅度更大,步态周期内部存在更复杂的动态转换过程。




图 8 Gate-TACD 特征 t-SNE 可视化
Fig. 8 t-SNE visualization of Gate-TACD features

此外,两类工况的特征分布在空间位置上具有一定分离性,说明 Gate-TACD 不仅能够拟合关节角度数值变化,还能够在隐空间中区分不同地形对应的运动模式。局部区域中存在少量相邻或重叠点,可能与步态周期中支撑相和摆动相的过渡阶段有关,此时不同地形下的关节运动模式具有一定相似性。总体来看,t-SNE 可视化结果表明, Gate-TACD 学习到的跨模态融合特征具有较好的连续性、可分性和运动状态表征能力,从特征空间角度解释了其在复杂地形下保持较高预测精度的原因。

3 结 论

本文提出并实现了一种针对下肢康复机器人的 Gate-TACD 模型,旨在解决康复机器人复杂运动工况下生物意图与机械动力学特征融合不充分导致的步态预测误差问题。通过在非对称门控架构中引入生物力学启发式损失函数,本研究实现了数据驱动特征与生物力学约束的深度结合,有效保障步态预测的物理一致性与轨迹平滑度。实验结果证实, Gate-TACD 模型在多地形任务中的预测精度与稳定性均显著优于传统时序网络,尤其在传感器滑移干扰下展现出极强的稳定性,平均误差较单一机械动力学模型降低约 16%。

本研究设计了一个新架构,不仅能发挥深度学习预测的优势,还证明预测结果在一定程度上符合人体运动的物理规律。也为解决下肢康复机器人运动系统中的感知不确定性问题提供重要参考。后续研究将致力于模型的轻量化重构与跨个体迁移学习,探索如何提高复杂多变地形下康复机器人步态预测的适应能力,以期为实际生活场景中的人机交互提供更精准、平滑的辅助支持。

参考文献

[1] Abd-Elsayed A, Robinson C L, Shehata P, et al. Neuromodulation' s role in functional restoration in paraplegic and quadriplegic patients [J]. Biomedicines, 2024, 12(4) : 720.

- [2] 段有康,陈小刚,桂剑,等. 基于相位划分的下肢连续运动预测[J]. 浙江大学学报(工学版),2021,55(1): 89-95.
Duan Youkang, Chen Xiaogang, Gui Jian, et al. Continuous kinematics prediction of lower limbs based on phase division [J]. Journal of Zhejiang University (Engineering Science), 2021, 55(1): 89-95.
- [3] 吴青聪,王兴松,吴洪涛,等. 上肢康复外骨骼机器人的模糊滑模导纳控制[J]. 机器人,2018,40(4): 457-465.
Wu Qingcong, Wang Xingsong, Wu Hongtao, et al. Fuzzy sliding mode admittance control of the upper limb rehabilitation exoskeleton robot[J]. Robot,2018,40(4): 457-465.
- [4] 郝李子翼,周昭丞,郑泓浩,等. 一种面向本体感觉训练的下肢康复机器人系统[J]. 机器人,2026,48(2): 298-311.
Hao Liziyi, Zhou Zhaocheng, Zheng Honghao, et al. A lower-limb rehabilitation robot system for proprioceptive training[J]. Robot, 2026, 48(2): 298-311.
- [5] 孔德智,王文东,郭栋,等. 基于 sEMG 的上肢关节角度预测方法研究[J]. 西北工业大学学报,2022,40(4): 764-770.
Kong Dezhi, Wang Wendong, Guo Dong, et al. Study on upper limb joint angle prediction method based on sEMG[J]. Journal of Northwestern Polytechnical University, 2022, 40(4): 764-770.
- [6] 杜妍辰,孙洁,汪晓铭,等. 基于肌电信号的人体下肢运动意图映射研究进展[J]. 上海理工大学学报,2023,45(2): 128-136,170.
Du Yanchen, Sun Jie, Wang Xiaoming, et al. Advances in human lower limb motion intention mapping based on electromyography[J]. Journal of University of Shanghai for Science and Technology, 2023, 45(2): 128-136,170.
- [7] 汤璐,杨玺霖,王祥瑞,等. 基于注意力机制的 CNN-LSTM 网络下肢膝关节角度预测[J]. 数据采集与处理,2024,39(4): 996-1008.
Tang Lu, Yang Xilin, Wang Xiangrui, et al. An Attention mechanism-based CNN-LSTM framework for lower limb knee joint angle prediction [J]. Journal of Data Acquisition and Processing, 2024, 39(4): 996-1008.
- [8] 汪文淼. 基于 VMD-ELMAN 的肌电信号对下肢关节角度预测[J]. 计算机科学,2024,51(3): 257-264.
Wang Wenmiao. Prediction of lower limb joint angle based on VMD-ELMAN electromyographic signals [J]. Computer Science, 2024, 51(3): 257-264.
- [9] 石永杰,高学山,罗定吉,等. 基于肌电信号和极限学习机的下肢关节运动预测[J]. 兵工自动化,2022,41(2): 87-91, 96.
Shi Yongjie, Gao Xueshan, Luo Dingji, et al. Prediction of lower limb joint motion based on surface emg signal and extreme learning machine [J]. Ordnance Industry Automation, 2022, 41(2): 87-91, 96.
- [10] Camargo J, Ramanathan A, Flanagan W, et al. A comprehensive, open-source dataset of lower limb biomechanics in multiple conditions of stairs, ramps, and level-ground ambulation and transitions [J]. Journal of Biomechanics, 2021, 119:110320.
- [11] Huang X, Wu B, Nishimura S. A gait stability prediction framework via multi-modal fusion and BiLSTM-KAN for treadmill walking [C]//2025 IEEE International Conference on Systems, Man, and Cybernetics (SMC).
- [12] Wang L L, Wang Y X, Guo F, et al. Lower limb joint angle prediction based on multistream signaling and quantile regression, temporal convolution network-bidirectional long short-term memory network neural network[J]. Machines, 2024, 12(12): 901.
- [13] Zhang Y Z, Meng X Q, Jiang C C. ST-AMMFN: A spatio-temporal attention-based multi-modal fusion network for gait data simulation and rehabilitation effect prediction in ankle injury patients [J]. Journal of Engineering & Applied Science, 2025, 72(1).
- [14] 颜兵兵,宋佳宝,单琳娜,等. 基于足压与姿态信息融合的步态相位识别方法[J]. 兵器装备工程学报,2025,46(5): 177-184.
Yan Bingbing, Song Jiabao, Shan Linna, et al. Gait phase recognition method based on fusion of foot pressure and posture information [J]. Journal of Weapons and Equipment Engineering, 2025, 46(5): 177-184.
- [15] 刘景源,张荣良,武鹏飞,等. 基于神经网络的多模态融合步态识别研究[J]. 传感器与微系统,2025,44(11): 28-32,37.
Liu Jingyuan, Zhang Rongliang, Wu Pengfei, et al. Research on multimodal fusion gait recognition based on neural network [J]. Transducer and Microsystem Technologies, 2025, 44(11): 28-32,37.
- [16] 李沐,马超,姚杰,等. 基于运动姿态和表面肌电数据融合的多数据流神经网络步态识别[J]. 电子测量与仪器学报,2026,40(5): 69-77.
Li Mu, Ma Chao, Yao Jie, et al. Gait Recognition based on a multi-stream neural network fusing motion posture and surface electromyography data [J]. Journal of Electronic Measurement and Instrumentation, 2026, 40(5): 69-77.
- [17] Flash T, Hogan N. The coordination of arm movements: An experimentally confirmed mathematical model [J]. The Journal of Neuroscience, 1985, 5(7): 1688-1703.

[18] Shushtari S M, Weng J, Nasiri R, et al. A Framework for modeling and simulation of neuromuscular control of walking [C]//Progress in Canadian Mechanical Engineering. Volume 4, 2021.

[19] Giannattasio R, Maludrottu S, Zinni G, et al. An adaptable ankle trajectory generation method for lower-limb exoskeletons by means of safety constraints computation and minimum jerk planning [C]//2024 IEEE International Conference on Robotics and Automation (ICRA), 2024:5548-5554.

[20] 高经纬,马超,苏鸿,等. 基于改进机器学习算法的步态识别与预测研究[J]. 生物医学工程学杂志,2022, 39(1):103-111.

Gao Jingwei, Ma Chao, Su Hong, et al. Research on gait recognition and prediction based on optimized machine learning algorithm [J]. Journal of Biomedical Engineering, 2022, 39(1):103-111.

[21] 梅建华,云利军,朱小鹏. 基于长短期记忆网络的红外人体步态识别方法研究[J]. 激光与光电子学进展, 2022, 59 (8):261-267.

Mei Jianhua, Yun Lijun, Zhu Xiaopeng. Infrared human gait recognition method based on long and short term memory network [J]. Laser&Optoelectronics Progress, 2022, 59 (8):261-267.

作者简介



Yan Yan(Corresponding author) received her B. S. degree

阎妍(通信作者),2017 年于南京信息工程大学获学士学位,2022 年于南京信息工程大学获得博士学位,现为南京晓庄学院讲师,主要研究方向为生物医学信号采集与处理、微弱信号检测与处理。

E-mail: yanyan@njxc.edu.cn

from Nanjing University of Information Science and Technology in 2017 and her Ph. D. degree from the same university in 2022. She is currently a lecturer at Nanjing Xiaozhuang University. Her main research interests include biomedical signal acquisition and processing, and weak signal detection and processing.



宋永献,1997 年于淮海工学院获得学士学位,2006 年于江苏大学获得硕士学位,2014 年于江苏大学获得博士学位。现为南京晓庄学院电子工程学院教授、硕士生导师。主要研究方向为物联网与智能系统、工业过程检测与优化控制、康复机器人、深度学习等。

E-mail: soyox@163.com

Song Yongxian received his B. Sc. degree from Huaihai Institute of Technology in 1997, his M. Sc. degree from Jiangsu University in 2006, and his Ph. D. degree from Jiangsu University in 2014. He is currently a professor and M. Sc. supervisor at the School of Electronic Engineering, Nanjing Xiaozhuang University. His main research interests include the Internet of Things and intelligent systems, industrial process detection and optimal control, rehabilitation robots, and deep learning.



马泽宇,2025 年于忻州师范学院获学士学位,现为南京晓庄学院在读硕士研究生,主要研究方向为康复机器人、步态规划。

E-mail: 19834885617@163.com

Ma Zeyu received his B. Sc. degree from Xinzhou Teachers University in 2025. He is currently a M. Sc. candidate in Control Engineering at the School of Electronic Engineering, Nanjing Xiaozhuang University. His main research interests include rehabilitation robotics and gait planning.