

DOI: 10.19650/j.cnki.cjsi.J2514346

下肢外骨骼电机超调预测-优化双阶段补偿控制策略*

石 欣¹, 唐 佳¹, 范智瑞¹, 杨子祥¹, 秦鹏杰²

(1. 重庆大学自动化学院 重庆 400044; 2. 深圳大学人工智能学院 深圳 518055)

摘 要: 下肢外骨骼技术能够辅助增强人体力量, 应用广泛。然而, 外骨骼电机因电磁惯性和机械负载导致的动态非线性, 因超调引发人机协同运动响应失配, 增加生物力学损伤风险。针对外骨骼电机在人体行走抬腿阶段的惯性超调问题, 提出了一种融合逆向系统模型预测与前向模型优化的双阶段协同超调量预测优化策略。通过构建卷积神经网络-长短期记忆网络-注意力机制 (CNN-LSTM-Attention) 的逆向系统模型, 实时接收电机目标输出, 有效捕捉多变量时间序列数据, 快速生成外骨骼电机初始输入指令; 构建金字塔特征融合-卷积神经网络-双向长短期记忆网络-Transformer (Pyramid-CLT) 的前向优化模型, 采用门控机制和金字塔形全连接层 (Pyramid) 实现多尺度特征整合, 预测输出与目标输出的均方误差作为目标函数, 运用粒子群优化算法 (PSO) 对高均方误差的样本进行迭代优化, 生成精确的电机控制指令, 实现电机超调补偿控制, 并通过下肢刚性外骨骼系统采集电机实际运行数据进行实验验证。结果表明, 预测优化策略能够根据人体运动轨迹精准生成外骨骼电机输入指令, 模型相关指数 (R^2) 为 0.985, 均方根误差 (RMSE) 和平均绝对误差 (MAE) 分别为 0.537 和 0.442; 与单一模型算法和其他预测算法对比, 通过实时动态预测并修正超调量, 使电机输出紧密贴合人体运动轨迹, 有效提升人机协同性, 为下肢外骨骼的精准控制提供了新的方法。

关键词: 下肢外骨骼; 外骨骼电机; 人机协同; 超调; 选择性优化

中图分类号: TP242 TH89 **文献标识码:** A **国家标准学科分类代码:** 510.40

Motor overshoot prediction and optimization of a two-stage compensation strategy for lower limb exoskeletons

Shi Xin¹, Tang Jia¹, Fan Zhirui¹, Yang Zixiang¹, Qin Pengjie²

(1. School of Automation, Chongqing University, Chongqing 400044, China; 2. School of Artificial Intelligence, Shenzhen University, Shenzhen 518055, China)

Abstract: Lower limb exoskeleton technology can assist in enhancing human strength and has a wide range of applications. However, exoskeleton motors exhibit dynamic nonlinearity due to electromagnetic inertia and mechanical loads, leading to overshoot that causes mismatches in human-machine collaborative motion responses and increases the risk of biomechanical injury. To address the inertial overshoot issue in exoskeleton motors during the leg-lifting phase of human walking, a two-stage collaborative overshoot prediction and optimization strategy is proposed, integrating inverse system model prediction with forward model optimization. By constructing a reverse system model based on a CNN-LSTM-Attention architecture, the system receives real-time motor target outputs, effectively captures multivariate time-series patterns, and rapidly generates the initial input commands for the exoskeleton motor. A forward optimization model based on a pyramid feature fusion-CNN-bi-LSTM-Transformer (Pyramid-CLT) architecture is constructed. The model employs a gating mechanism together with pyramid-shaped fully connected layers to achieve multi-scale feature integration. The mean squared error between the predicted output and the target output serves as the objective function. To further improve the prediction accuracy, a particle swarm optimization (PSO) algorithm is applied to iteratively refine samples with high mean square error, enabling the generation of

收稿日期: 2025-08-02 Received Date: 2025-08-02

* 基金项目: 国家重点研发计划 (2023YFB4704003)、国家自然科学基金青年科学基金 (62403453)、广东省基础与应用基础研究基金 (2025A1515011973) 项目资助

precise motor control commands for overshoot compensation. Experimental that the prediction optimization strategy can precisely generate exoskeleton motor input commands based on human movement trajectories, achieving a model correlation coefficient (R^2) of 0.985, root mean square error (RMSE) of 0.537, and mean absolute error (MAE) of 0.442; Compared with single-model algorithms and other prediction algorithms, the proposed method achieves real-time dynamic prediction and correction of overshoot, enabling motor output to closely align with human movement trajectories, thereby effectively enhancing human-machine synergy and providing a new method for precise control of lower-limb exoskeletons.

Keywords: lower limb exoskeleton; exoskeleton motor; human-machine collaboration; overshooting; selective optimization

0 引 言

近年来,外骨骼助力技术迅速发展,通过分散负重和减少身体损伤,显著提升工人劳动效率,降低疲劳和体力消耗,为职业健康提供强有力支持^[1-5]。目前已开发出多个下肢外骨骼机器人用于助力领域,例如 Lopes^[6]、Lokomat^[7]、Walktrainer^[8]和 Alex^[9]。大多数外骨骼采用穿戴式的工作方式^[10],这就要求人体与外骨骼之间能够紧密配合、自然交互。然而在实际的日常活动中,由于电机的二阶惯性^[11],外骨骼系统的人机协同运动控制中存在动态响应失配问题^[12-13],为了追随人体运动速度,电机运行速度往往会过快,其输出角度在跟踪人体真实运动角度时会产生显著的幅值超调,这种非线性动态特性可能引发人机交互力矩突变,造成生物力学损伤风险^[14]。当电机运行速度减缓时,又可能与人体运动状态产生不协调,引发运动冲突。

轨迹控制是实现下肢外骨骼人机协同的关键研究方向。现研究主要从 3 个方面着手:1) 轨迹生成与优化,即根据用户意图和环境条件,规划外骨骼运动路径,使其与人体运动协调一致。Kamali 等^[15]提出了一种基于动态运动基元的膝关节外骨骼轨迹生成与阻抗控制方法,个性化预测由坐到站的运动轨迹并提供有效辅助。Sun 等^[16]提出了一种基于邻域场优化和反向动力学分析的下肢外骨骼参考轨迹优化方法,旨在通过减少人体关节力矩来降低行走时的能量消耗。Huang 等^[17]提出了一种基于运动学模型和人工鱼群算法的下肢外骨骼参考步态轨迹优化方法,通过髋关节运动生成膝关节轨迹;2) 步态偏差校正,通过减小外骨骼的实际运动轨迹与用户预期或自然步态之间的差异,确保外骨骼实时适应用户步伐。Zhang 等^[10]基于极端梯度提升(extreme gradient boosting, XGboost)算法开发了一种步态偏差校正方法,通过建立穿戴者步态与外骨骼轨迹之间的关系模型,基于身体特征参数校正外骨骼参考轨迹。Zhang 等^[18]针对预定义轨迹适应性不足的问题提出了一种基于适应扩展卡尔曼滤波的轨迹误差补偿方法;3) 非线性动态控制,即通过先进的控制算法处理外骨骼与人体交互中的动态变化,确保运动轨迹的精确跟踪、柔顺性和能效优化。Jenhani 等^[19]

针对外骨骼非线性动态及外部扰动引起的控制不稳定问题,提出了一种复合控制策略,通过集成线性状态反馈控制器与非线性控制律,有效解决膝关节外骨骼的非线性动力学难题。Chen 等^[20]基于运动捕捉数据和腿部几何约束,通过正弦函数拟合髋关节和膝关节的参考轨迹,实时估计系统压力中心位置,动态调整参考轨迹以应对内外扰动,确保系统平衡。Perez-San 等^[21]提出了一种用于下肢康复外骨骼的混合位置-力控制器,基于用户运动意图,通过自适应强化约束控制实现人机协同,旨在安全地辅助患者进行步态康复。

尽管上述方法在轨迹生成与优化、步态偏差校正及非线性动态控制等方面为高度耦合的人机外骨骼系统带来了显著进展,但是人与机械结构间的相互影响仍然存在,外骨骼电机受电磁惯性和机械负载影响,输入与输出构成复杂的动态非线性系统^[22],启动、停止和加速时存在时滞或非线性,产生超调、振荡或延迟上升,导致动作与人体意图不同步,影响人机友好协同。传统的物理模型,如微分方程、传递函数等对电机建模,需预先定义转动惯量 J 、阻尼系数 B 等电机动力学参数^[23-24],但这些参数在实际中随负载、温度、机械磨损动态变化导致模型失配。且传统模型难以量化电机超调量与时序震荡衰减过程,非线性动态建模能力不足^[25],降低了系统效率和穿戴舒适性,限制了人机协作的整体性能。

因此为了解决外骨骼控制中人机速度矛盾导致人体期望与电机输出适配难问题,有必要在人体期望运动轨迹与电机实际输出轨迹之间构建一种有效的控制策略。该策略需依据人体的运动特性和电机的输出特性,设定合理的电机期望值,实现较高的人机匹配度。考虑到现有方法多忽略电机动态特性对系统性能的影响以及传统建模手段难以实现对外骨骼电机非线性和时变动态的准确描述,基于深度学习的方法可以从海量运行数据中挖掘出外骨骼电机运行时输入量和输出量的特征信息,通过端到端学习与动态补偿机制,建立电机输入输出之间映射关系,确保外骨骼的输出轨迹与人体期望轨迹相匹配,从而提高外骨骼的柔顺性。

针对外骨骼电机动态特性导致的惯性超调问题及其对人机协同运动的影响,以人体行走模式中抬腿阶段髋关节为研究对象,提出了一种融合逆向系统模型预测与

前向模型优化的双阶段协同超调量预测优化策略,兼顾动态系统指令生成的实时性与精度。具体而言,在第1阶段,构建了基于卷积神经网络-长短期记忆网络-注意力机制(convolutional neural network-long short term memory-attention, CNN-LSTM-Attention)的逆向系统模型,捕捉多变量时间序列数据中的时间和空间依赖关系,通过实时接收人体运动轨迹作为电机目标输出,预测生成电机初始输入指令。在第2阶段,提出基于金字塔特征融合-卷积神经网络-双向长短期记忆网络-Transformer(pyramid-convolutional neural network-bidirectional long short term memory-transformer, Pyramid-CLT)的前向优化模型,对电机初始输入指令进一步优化。通过各模块融合预测生成电机输出轨迹,若电机预测输出与人体运动轨迹的误差超过设定阈值,则采用粒子群(particle swarm optimization, PSO)算法迭代优化生成更精确的电机输入指令。该策略通过逆向建模与前向优化的协同,融合模型预测与进化算法的优势,预测外骨骼电机超调量,实时优化电机输入指令,确保外骨骼电机输出紧密贴合人体运动轨迹,在保持实时性的基础上显著降低稳态误差,为人机协同运动中控制问题提供了新解决方案。

1 数据采集及处理

数据采集包括表面肌电信号(surface electromyography, sEMG)采集和外骨骼实际运动轨迹数据采集,其中 sEMG 用于生成人体运动轨迹,以产生电机输入指令驱动外骨骼运动。同时,采集电机输出的相关数据集,并将外骨骼电机输入指令和输出轨迹数据集作为提出模型的训练和测试数据集。

1.1 人体运动轨迹的生成

为实现下肢外骨骼与穿戴者的高度协同,外骨骼系统需基于人机交互信息准确感知穿戴者的运动意图,并对人体期望步态轨迹进行精确跟踪^[26-29]。其中 sEMG 能够反映神经肌肉活动,具有无创性采集的特点,且信号产生时间比实际动作提前 30~150 ms^[30-31],适用于下肢运动轨迹预测,并在特定场景下展现高可靠性。Liu 等^[32]提出了一种协同步态预测模型使用 sEMG 信号预测个性化步态轨迹,预测轨迹与实际膝关节角度的相关系数高于 0.9,表明高一致性;Koo 等^[33]提出传感器无关的 LSTM 模型,使用 sEMG 数据预测单自由度下肢角度轨迹,克服硬件差异实现跨设备预测,平均 MAE 为 2.8°;Qin 等^[34]基于肌肉协同理论和状态空间模型的方法提取 sEMG 的低维协同特征并结合无迹卡尔曼滤波,可实现 $R^2 > 0.92$, $RMSE < 5^\circ$ 的高精度预测。相较于多源数据,单一 sEMG 方案硬件简单、成本低、易穿戴,且无需复杂数据

同步和校准,降低系统复杂性和功耗,在便携性和实用性优先的场景下, sEMG 方法更具优势。因此采用英国 Biometrics 公司生产的无线表面肌电信号传感器 LE230 和无线双轴测角计 W150,采集行走时的人体下肢 sEMG,如图 1 所示。利用 Qin 等^[34]提出的基于肌肉协同理论和状态空间模型的下肢连续角度估计方法预测得到人体行走髋关节步态轨迹,如图 2 所示。




图1 sEMG 采集

Fig. 1 sEMG collection




图2 基于 sEMG 的人体行走时髋关节角度预测

Fig. 2 Prediction of hip joint angle during human walking based on sEMG

1.2 外骨骼数据采集及处理

由于外骨骼助力主要在人体抬腿阶段克服重力做功,因此本研究选择人体行走模式中抬腿阶段髋关节为研究对象,以 100 ms 为周期将基于 sEMG 预测得到的人体髋关节运动轨迹采样为电机输入指令发送至控制器,由驱动器驱动髋关节电机运动。同时无线姿态传感器以 100 Hz 频率实时采集髋关节的实际角度和速度,得到电机输出轨迹。由于步进电机固有的物理特性,电机输出存在显著超调,所以将此电机输入指令作为输入指令最大值。逐步减小输入指令,直至电机输出值低于人体真实角度,确定最小输入指令。最后通过线性插值生成输入指令集合 X ,驱动电机得到输出集合 Y 。

电机输入指令数据集 X 包含角度集合和速度集合。具体地,设时间步为 $t_i (i = 1, 2, \dots, n)$,每个时间步对应一个角度值 $\theta_{m-input_i}$ 和速度值 $\omega_{m-input_i}$,则数据集 X 可表示为:

$$X = \{(\theta_{m-input_i}, \omega_{m-input_i}) \mid i = 1, 2, \dots, n\} \quad (1)$$

其中, $\theta_{m-input_i} \in \Theta_{m-input}$, $\Theta_{m-input}$ 为角度集合;
 $\omega_{m-input_i} \in \Omega_{m-input}$, $\Omega_{m-input}$ 为速度集合; $t_i = t_0 + i \cdot \Delta t$, $\Delta t = 100 \text{ ms}$ 。

采集 1 864 组样本数据,包括电机输入数据和输出数据。为提升模型预测的准确性,对样本数据采用四分位距(interquartile range, IQR)法进行异常值处理,确保在保留数据集主要统计特性的基础上有效去除不合理值;采用首尾数据部分增强实施数据增强,增加样本多样性,同时保留数据的物理意义和分布特性,避免过度干扰原始数据结构;采用 Min-Max 标准化方法进行归一化处理,

统一量纲,提高模型性能。

2 预测优化策略

2.1 整体框架

文章构建融合逆向系统模型预测与前向模型优化的双阶段协同超调量预测优化策略,如图 3 所示。利用肌电信号传感器采集人体 sEMG 信号,经过处理后获得人体运动轨迹,即电机目标输出 Θ_{target} ,将该轨迹输入双阶段模型进行处理,预测得到电机控制指令 $\Theta_{m-input}$,从而驱动下肢外骨骼运动。

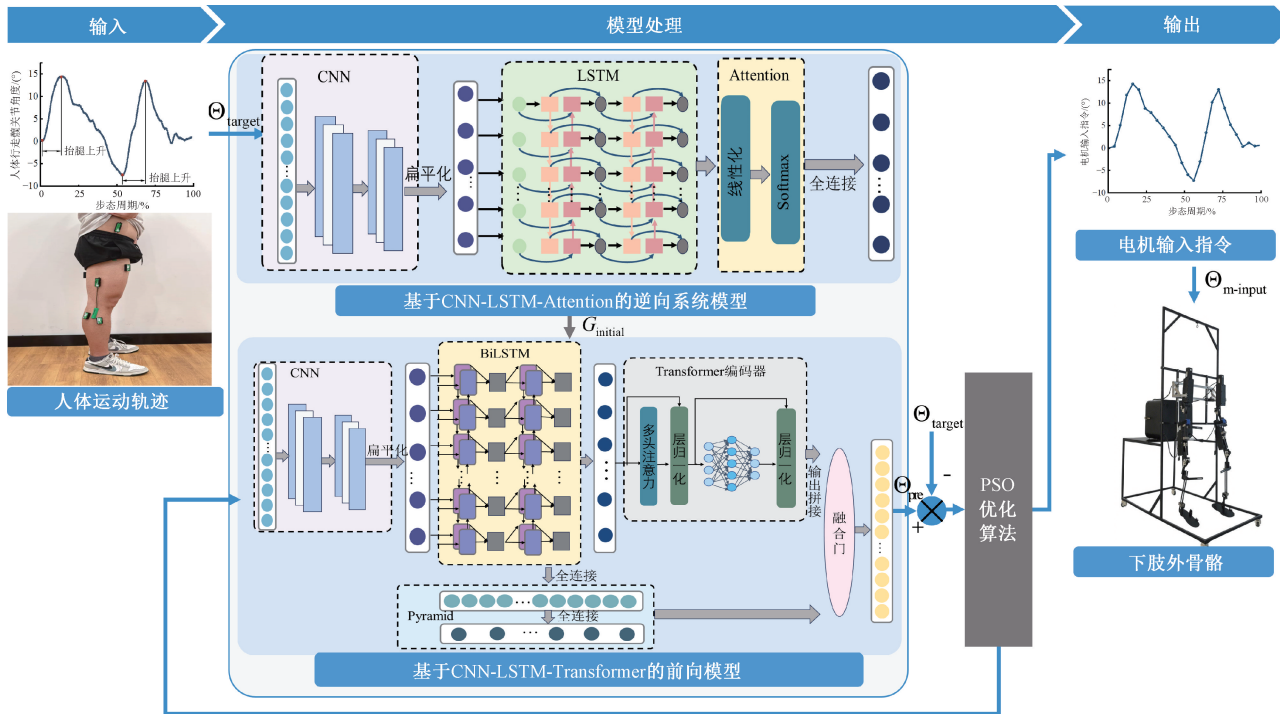


图 3 融合逆向系统模型预测与前向模型优化的双阶段协同超调量预测优化策略整体架构

Fig. 3 Overall architecture of a two-stage collaborative overshoot prediction optimization strategy combining reverse system model prediction and forward model optimization

在第 1 阶段,系统以 sEMG 处理预测后的人体运动轨迹 Θ_{target} 为基准,构建电机输出-输入指令映射关系。通过建立基于 CNN-LSTM-Attention 的逆向系统模型,实时接收电机目标轨迹 Θ_{target} ,并将其作为模型输入,融合 CNN、LSTM 和 Attention 模块,有效捕捉多变量时间序列数据中的空间和时间依赖关系,生成电机初始输入指令 $G_{initial}$ 。在第 2 阶段,将初始输入指令 $G_{initial}$ 输入到 Pyramid-CLT 前向模型,融合 CNN、BiLSTM 和 Transformer 编码器,通过门控机制和 Pyramid 进行特征整合,最终利用线性回归头输出预测结果生成预测输出 Θ_{pre} ,并计算其与目标输出 Θ_{target} 的均方误差 (mean square error, MSE)。通过设定 MSE 阈值,筛选出误差较高的电机初

始输入指令,采用 PSO 算法迭代优化,最小化预测输出 Θ_{pre} 与目标输出 Θ_{target} 之间的误差,从而优化电机初始输入指令,生成更精确的控制指令 $\Theta_{m-input}$ 。

第 1 阶段通过逆向模型单次推理生成指令,具有计算效率高、响应快的优点,但因逆模型存在多映射特性及误差开环传递问题,预测精度受限。在第 2 阶段,引入模型优化机制以进一步提升指令精度。该阶段基于前一阶段所提供的初始指令,有效缩小了 PSO 算法的搜索空间,从而大幅节约了优化时间。同时,通过选择性优化策略,避免了对逆模型表现良好样本的过度优化,既减少了不必要的计算开销,也抑制了因优化过程引入额外噪声的风险。该策略通过逆向系统模型与前向模型的协同作

用,最终在计算效率与控制精度之间取得了良好平衡。系统不仅保持了优异的实时性,抑制了外骨骼电机的稳态误差与超调,提高升了外骨骼的响应性能与整体稳定性。

2.2 基于 CNN-LSTM-Attention 网络的逆向系统模型

针对外骨骼电机动态响应中的超调现象对人体运动安全构成的潜在风险,在策略第 1 阶段提出基于 CNN-LSTM-Attention 网络的逆向系统模型,其网络结构如图 4 所示。

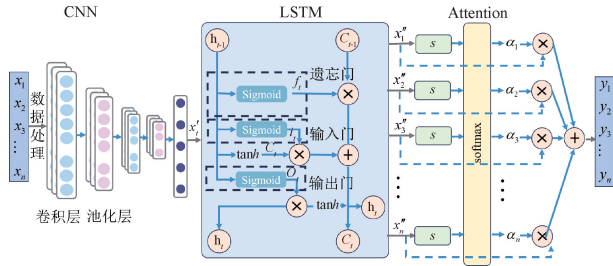


图 4 CNN-LSTM-Attention 网络结构

Fig. 4 CNN-LSTM-Attention network architecture

通过采集穿戴者下肢运动学数据和外骨骼电机的动态响应数据,对历史运行数据进行分析,建立外骨骼电机输出和电机输入指令之间的动态逆向映射关系模型。

逆向系统模型的核心是构建从电机目标输出到电机输入指令的映射函数,利用外骨骼的动态特性驱动电机实现目标输出,数学上可表示为:

$$\Theta_{m-input} = f^{-1}(\Theta_{target}; \alpha) \quad (2)$$

其中, $\Theta_{m-input} \in \mathbb{R}^T$ 是电机输入指令, $\Theta_{target} \in \mathbb{R}^T$ 是电机目标输出,即人体运动轨迹, α 是逆模型的参数。

由于外骨骼控制对实时性的严格要求,模型采用逐步预测方法,每个时间步包含 10 个值。对采集到的人体行走模式外骨骼电机输入和输出序列进行缺失值和归一化处理后,将电机输出序列输入 CNN 层提取有效特征。CNN 模块包含两层卷积操作,每层后接 ReLU 激活函数引入非线性,并通过最大池化将序列长度减半,以降低计算复杂度和增强特征鲁棒性。随后,将 CNN 提取的特征输入 LSTM 层,捕捉输入数据的时序依赖性和序列信息。注意力机制通过两层全连接网络计算注意力分数,并经 softmax 函数归一化为权重,突出对预测任务关键的时间步,提升模型性能。最后,通过全连接层将注意力机制的输出映射至目标值,即外骨骼电机的初始输入指令。

2.3 基于 Pyramid-CLT 的 PSO 选择性优化模型

在模型处理第 2 阶段,提出了一种基于 Pyramid-CLT 的 PSO 选择性优化模型,与第 1 阶段协同配合以提升外骨骼电机控制指令的精度。模型首先利用逆向系统模型生成初始输入指令作为初始值,将其输入 Pyramid-CLT

网络,计算机输出 $\Theta_{m-output}$ 与目标输出 Θ_{target} 的 MSE。若 MSE 低于阈值 1,直接采用初始输入指令;若 MSE 超过 1 时,启动 PSO 优化算法,最小化电机输出与目标输出之间的误差,迭代优化输入指令序列。该方法结合 Pyramid-CLT 的特征融合能力与 PSO 的全局搜索优势,能够动态优化输入指令,从而增强外骨骼系统与人体运动轨迹的适配能力。

1) Pyramid-CLT 模型

Pyramid-CLT 模型是一种混合神经网络,旨在根据输入的角度和速度序列预测外骨骼输出。该模型集成了 CNN、BiLSTM、Transformer 编码器、金字塔融合模块和特征融合门控机制,高效捕捉序列数据中的空间和时间依赖关系,其网络结构如图 5 所示。

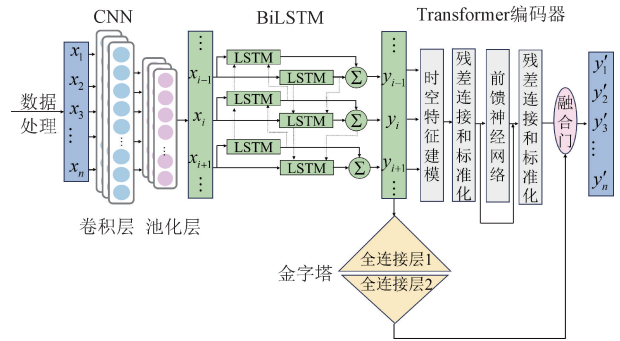


图 5 Pyramid-CLT 网络结构

Fig. 5 Pyramid-CLT network architecture

(1) 局部时序特征提取

在 Pyramid-CLT 模型中, CNN 用于提取输入序列的局部特征,捕捉时间维度上的局部相关性; BiLSTM 接收 CNN 输出,结合双向信息流和长短期记忆机制,捕获长短期依赖关系。通过多阶段架构实现特征提取与序列建模,高效处理外骨骼电机的输入角度和速度。

(2) 全局时空特征提取

Transformer 作为一种高效的时间序列预测工具^[35],能够有效捕捉时序数据中的复杂依赖关系与多尺度特征。其中 Transformer 编码器在提取序列特征、捕捉输入序列中各元素之间的全局依赖关系中起关键作用。采用了两层 Transformer 编码器,通过多头自注意力机制 (multi-head attention, MHA) 和前馈神经网络 (feed-forward neural network, FFN) 对时间步之间的复杂关系进行建模,实现高精度的时间序列预测。

(3) 特征增强表达

Pyramid 是一种用于多尺度特征融合的结构,通过两层全连接网络进行维度扩展和压缩,对 BiLSTM 提取的序列特征进行非线性变换,为后续的特征融合提供高质量的补充特征。

(4) 特征融合

采用门控机制动态融合 Transformer 和 Pyramid 提取的特征,通过自适应权重分配,突出对预测任务更重要的特征。假设输入特征为 X_1, X_2, \dots, X_n , 融合门机制可以表示为:

$$G_i = \text{sigmoid}(\mathbf{W}_g \cdot [X_1, X_2, \dots, X_n] + b_g) \quad (3)$$

其中, \mathbf{W}_g 为可学习权重矩阵, b_g 为偏置项, $[X_1, X_2, \dots, X_n]$ 表示特征拼接。

2) PSO 选择性优化

PSO 是一种基于群体智能的优化算法^[36],在第 2 阶段中用于优化由逆向系统模型生成的初始输入指令。逆向模型根据目标轨迹生成初始的电机控制指令,但这些初始预测指令可能与真实输入存在较大误差,导致前向模型的预测输出与目标输出之间的差值较大。PSO 以初始指令为起点,定义搜索空间为初始猜测附近的角速度范围。通过最小化目标函数,迭代搜索最优输入序列,使预测输出与目标轨迹的 MSE 尽可能小,同时考虑输入的平滑性和与初始指令的偏差。

PSO 并非对所有样本都进行优化,而是通过设定阈值 $MSE=1$ 筛选需要优化的样本:如果初始指令的 MSE 已经足够低 ($MSE < 1$),则跳过 PSO 优化直接使用初始预测指令,减少计算开销。对于 MSE 较高的样本,PSO 通过迭代搜索优化输入指令,显著降低预测输出与目标输出的误差。这种选择性优化策略平衡了计算效率和优化效果,仅对误差较高的样本进行 PSO 优化。其实现步骤为:

(1) 初始化参数和粒子群,设置粒子群在初始指令附近均匀分布,范围为:

$$[\max(lb, G_{\text{initial}} - 0.075 \cdot (ub - lb)), \min(lb, G_{\text{initial}} + 0.075 \cdot (ub - lb))] \quad (4)$$

其中, lb 和 ub 为输入变量每个维度的上下界,速度 v 初始化为 0,缩小搜索空间,提高效率。

(2) 迭代更新粒子位置和速度,表达式为式(5)和(6),逐步逼近目标函数的最优解,即:

$$x = x + v, \quad x \in (lb, ub) \quad (5)$$

$$v = \omega \cdot v + \phi_p \cdot r_1 \cdot (pbest_x - x) + \phi_g \cdot r_2 \cdot (gbest_x - x) \quad (6)$$

其中, ω 为动态惯性矩阵, ϕ_p 为认知因子, ϕ_g 为社交因子。 r_1 和 r_2 为随机矩阵, $pbest_x$ 为个人最佳位置矩阵, $gbest_x$ 为全局最佳位置矩阵。

(3) 评估适应度函数,计算粒子适应度函数 f 为 MSE、平滑性惩罚 (smooth penalty, SP) 和正则化惩罚 (L2 penalty, LP) 的和,具体表达式如式(7)所示。

$$f = MSE + SP + LP \quad (7)$$

其中 MSE 表达式为:

$$MSE = \frac{1}{N} \sum (\Theta_{\text{pre}} - \Theta_{\text{target}}) \quad (8)$$

式中: Θ_{pre} 为预测输出; Θ_{target} 为目标输出。

SP 鼓励输入序列在时间上平滑,防止优化输入出现剧烈波动,其表达式为:

$$SP = \sum_{i=0}^{N-2} (x_{\text{seq}}[i+1] - x_{\text{seq}}[i])^2 \cdot w_i \cdot \frac{r}{100} \quad (9)$$

式中: x_{seq} 为输出序列; w_i 为平滑性权重; r 为输入角度范围。

LP 防止优化输入偏离初始猜测过远,其表达式为:

$$LP = \sum (x_{\text{seq}} - G_{\text{initial}})^2 \cdot 0.2 \quad (10)$$

PSO 的目标是通过优化一组输入,使模型输出尽可能接近目标序列。MSE 直接衡量了预测输出与目标输出的误差,是优化任务的核心目标。为避免输入序列剧烈变化并确保优化结果不过分偏离初始猜测,适应度函数引入了 SP 和 LP。由于第 1 阶段逆模型生成的电机初始输入指令已较为接近真实解,当前适应度函数设计简单而有效,能够使 PSO 快速收敛到目标解。

(4) 根据当前的目标函数值更新个人最佳和全局最佳,引导粒子朝更优解移动,确保 PSO 始终追踪最优解。

2.4 模型评价指标

将人体运动轨迹作为电机目标输出,预测电机最优输入指令,这一过程属于回归任务,选择均方根误差 (root mean square error, RMSE)、相关指数 (R^2) 和平均绝对误差 (mean absolute error, MAE) 作为评价指标,以量化预测角度与目标角度的偏差。

RMSE 用于衡量预测值和实际值之间的平均误差,其取值范围为 $(0, +\infty)$,数值越靠近 0 表示模型性能越好,表达式为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (11)$$

式中: n 为样本个数; y_i 为真实值; \hat{y}_i 为预测值。

MAE 是预测值与实际值差的绝对值的平均值,其取值范围为 $(0, +\infty)$,数值越靠近 0 表示预测模型性能越好,表达式为:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (12)$$

R^2 表示模型解释的因变量变异占总变异的比,反映了模型预测值与实际值之间的拟合程度,其取值范围为 $(-1, 1)$,数值越大表示模型拟合程度越好,表达式为:

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

3 实验验证

3.1 实验平台

实验平台由上位机数据处理与模型训练平台及下肢刚性外骨骼系统构成。

基于 Pytorch2. 6. 0+cuda12. 4 搭建上位机数据处理与模型训练平台,系统为 Windows11 ,GPU 为 RTX 4090。

基于人体自由度分析^[37-39],外骨骼下肢简化为两个自由度,因踝关节在运动过程中动作幅度较小,设计为被动式刚性结构满足实验需求,并在下肢外骨骼周围设计跟随式架构以防穿戴者摔倒,如图 6 所示。

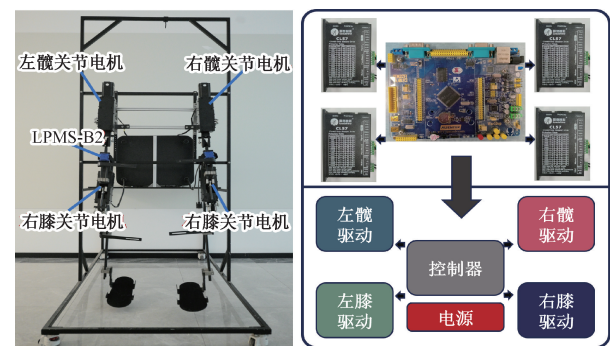


图 6 下肢外骨骼系统
Fig. 6 Lower limb exoskeleton system

采用肌电信号传感器获取人体下肢 sEMG,得到人体运动轨迹;采用无线姿态传感器获取外骨骼运动的角度、角速度等数据,得到外骨骼输出轨迹;通过旋转编码器获取驱动电机的旋转圈数、角度等数据。所用传感器名称及型号如表 1 所示。

表 1 传感器名称及型号
Table 1 Sensor name and model

传感器名称	传感器型号
肌电信号传感器	Biometrics LE230
无线姿态传感器	LPMS-B2
光电旋转编码器	OMRON E6B2-CWZ6C

为满足下肢外骨骼系统对控制精度和通信效率的需求,选用 STM32 系列 STM32F103ZET6 作为控制器,其性能能够有效支持系统的实时控制与数据交互要求;基于人体行走过程中髋关节以矢状面屈伸运动为主的特性,采用步进电机 57CME23 搭配 CL57 数字式闭环步进驱动器作为驱动单元,实现髋关节屈伸运动的精确控制。

3.2 模型参数设置

采集 1 864 个样本,包含电机输入指令样本和电机输出样本,将其按照 8:2 随机将其划分为训练集和测试集。

选择 CNN-LSTM-Attention 模型参数时,主要针对 CNN 卷积层、LSTM 隐藏层和隐藏单元进行参数设置,为获取更有效的模型参数,测试不同超参数的模型性能,实验结果如表 2 所示。当卷积层层数为 2,LSTM 隐藏层数为 2,LSTM 隐藏单元数为 64 时,模型达到最佳性能。同时设置初始学习率为 0. 001,正则化参数为 0. 000 1,损失函数为 MSE,优化函数为 Adam。

表 2 基于 CNN-LSTM-Attention 的逆向系统模型
超参数选取评价结果

参数名称	参数值	RMSE	MAE	R ²
卷积层	1	0. 846	0. 601	0. 793
	2	0. 655	0. 517	0. 980
	3	0. 830	0. 584	0. 812
LSTM 隐藏层数	1	0. 805	0. 555	0. 814
	2	0. 655	0. 517	0. 980
	3	0. 805	0. 554	0. 824
LSTM 隐藏单元	32	0. 820	0. 567	0. 825
	64	0. 655	0. 517	0. 980
	128	0. 816	0. 575	0. 814
	256	1. 600	1. 070	0. 590

选择基于 Pyramid-CLT 的 PSO 选择性优化模型参数时,主要针对 CNN 卷积层、LSTM 隐藏层和隐藏单元、Transformer 编码器层数和注意力头数进行参数设置,实验结果如表 3 所示。当卷积层层数为 1、LSTM 隐藏层数为 3、LSTM 隐藏单元数为 64、Transformer 编码器层数为 2、注意力头数为 8 时,模型达到最佳性能。同时设置初始学习率为 0. 001,学习率调度器为 Warm-up Scheduler,PSO 粒子数和最大迭代次数为 10。

3.3 模型性能验证及分析

1) 选择性优化阈值选取实验

在构建的融合逆向系统模型预测与前向模型优化的双阶段协同超调量预测优化策略中,当第 1 阶段逆向系统模型给出电机初始指令后,是否启动第 2 阶段的 PSO 优化算法,是由基于 Pyramid-CLT 的前向模型的预测输出和目标输出之间的 MSE 决定的,所以 MSE 的阈值设置至关重要。设置 MSE 阈值为 0. 5、1、1. 5、2 和 2. 5,分别进行模型测试,评价结果如表 4 所示,在相同的数据集上的 RMSE、MAE 和 R² 的变化情况如图 7 所示。

表 3 基于 Pyramid-CLT 的 PSO 选择性优化模型超参数选取评价结果

Table 3 Evaluation results of hyperparameter selection for the PSO selective optimization model based on Pyramid-CLT

参数名称	参数值	RMSE	MAE	R ²
卷积层	1	0.537	0.442	0.985
	2	1.841	1.289	0.941
	3	0.594	0.487	0.982
LSTM 隐藏层数	1	0.594	0.483	0.982
	2	0.549	0.453	0.984
	3	0.537	0.442	0.985
LSTM 隐藏单元	64	0.537	0.442	0.985
	128	0.630	0.514	0.975
	256	0.564	0.450	0.975
Transformer 编码器层数	1	0.578	0.476	0.982
	2	0.537	0.442	0.985
	3	0.544	0.451	0.982
注意力头数	8	0.537	0.442	0.985
	16	0.562	0.454	0.983

表 4 不同阈值模型性能评价结果

Table 4 Performance evaluation of different threshold models

评价结果	MSE=0.5	MSE=1	MSE=1.5	MSE=2	MSE=2.5
RMSE	0.613	0.537	0.789	0.839	0.833
MAE	0.465	0.442	0.554	0.592	0.585
R ²	0.920	0.985	0.819	0.701	0.722

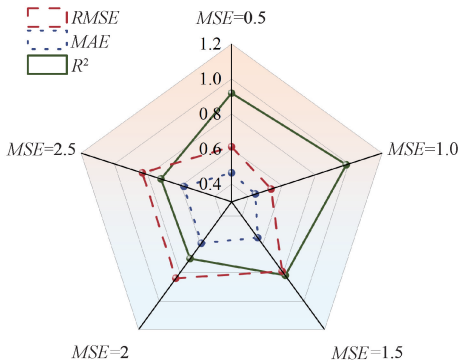


图 7 不同阈值模型性能实验结果

Fig. 7 Model performance with different thresholds

由图 7 可知,选择性优化模型的启动阈值最佳值为 1。阈值过小会导致更多样本(包括误差较小的样本)触发 PSO 算法,可能引发过拟合,且 PSO 在处理大量样

本时易陷入局部最优或迭代效率下降,群体智能难以有效收敛。阈值过大时,仅误差较大的样本触发优化,未优化的样本可能导致累积误差。适中阈值能平衡泛化能力与关键误差修正,提升模型整体性能。

2) 基于 CNN-LSTM-Attention 的逆向系统模型性能验证实验

将样本数据输入协同模型的第一阶段基于 CNN-LSTM-Attention 的逆向系统模型进行训练和测试。随机选取 200 个样本的模型预测结果如图 8 所示。




图 8 基于 CNN-LSTM-Attention 的逆向系统模型预测结果

Fig. 8 Prediction results of inverse system model based on CNN-LSTM-Attention

由图 8 可以直观看出,基于 CNN-LSTM-Attention 的逆向系统模型预测得到的电机初始输入指令与实际电机输入指令之间高度一致,预测精度高。这一结果充分验证了该模型的优异性能,为后续第 2 阶段的优化调整提供了精准可靠的初始值,并为整个预测优化策略的有效性奠定了坚实基础。

3) 基于 Pyramid-CLT 的前向模型性能验证实验

第 2 阶段中基于 Pyramid-CLT 的前向模型接收到电机初始输入指令后预测电机输出,预测结果的准确性直接影响 PSO 优化效果。将样本数据输入前向模型进行训练和测试,模型评估结果如表 5 所示。在整个抬腿上升阶段, RMSE 和 MAE 均保持在较低水平, R² 达到 0.974,表明模型性能优异。各时间步的 RMSE、MAE 和 R² 同样显示出前向模型的出色性能,为 PSO 优化的有效性提供了坚实的基础。

表 5 Pyramid-CLT 模型性能评价结果

Table 5 Performance evaluation of Pyramid-CLT model

评价结果	T	t ₁	t ₂	t ₃	t ₄
RMSE	1.085	0.194	0.537	1.073	1.597
MAE	0.818	0.167	0.503	1.004	1.566
R ²	0.974	0.783	0.837	0.947	0.958

基于 Pyramid-CLT 的前向模型的模型预测结果如图 9 所示,每个时间步 t_i 的模型预测结果如图 10 所示。可以看出,对于每个时间步,基于 Pyramid-CLT 的前向模型预测得到的电机输出都接近于电机真实输出,预测精度高,说明该模型性能优秀,为第 2 阶段的 PSO 迭代优化提供了必要条件。




图 9 Pyramid-CLT 模型预测结果

Fig. 9 Prediction results of Pyramid-CLT model

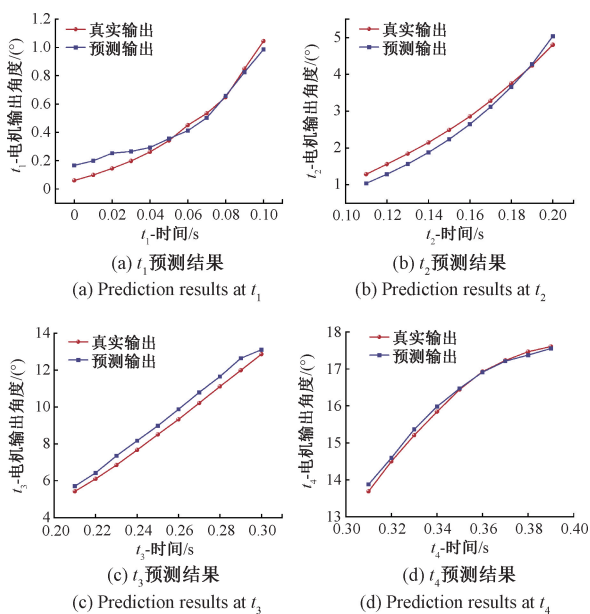


图 10 单时间步 Pyramid-CLT 模型预测结果

Fig. 10 Prediction of Pyramid-CLT model in a single time step

4) 双阶段协同模型性能验证实验

将采集到的样本输入到逆向系统模型中,生成电机初始输入指令。随后,将该指令输入基于 Pyramid-CLT 的前向模型,得到电机预测输出,并计算预测输出与电机目标输出之间的 MSE。若 MSE 超过阈值,采用 PSO 进行优化。双阶段协同模型在随机选取的 200 个样本上每个时间步的预测结果如图 11 所示,PSO 收敛曲线如图 12 所示。

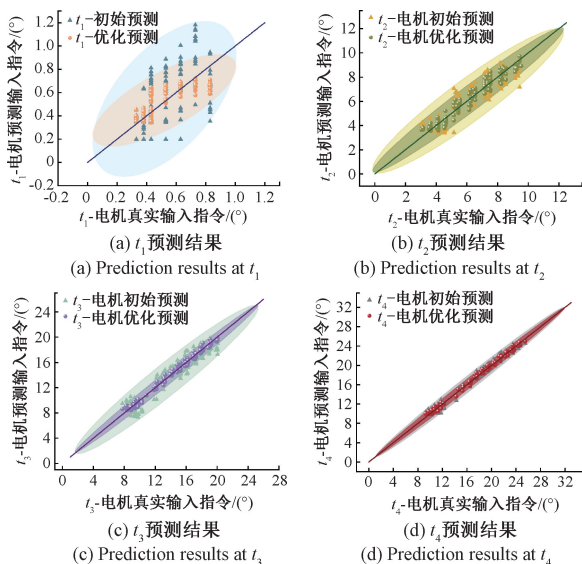


图 11 整体模型单时间步预测结果

Fig. 11 Prediction of the overall model in a single time step




图 12 PSO 算法迭代收敛曲线

Fig. 12 Convergence curve of PSO algorithm iterations

由图 11 可知,对于每个时间步,基于 CNN-LSTM-Attention 的逆向系统模型能够生成较为精准的电机初始输入指令。经过基于 Pyramid-CLT 的 PSO 选择性优化模型进一步精化后,最终得到的电机输入指令与真实指令的匹配度显著提高,误差明显减小。特别是后 3 个时间步的预测结果表现出更高的精度,充分验证了逆向系统模型与优化模型的有效性。然而,受限于髋关节变化幅度较小、电机启动初期的非稳定性以及前后步信息不足的影响,首个时间步的预测性能略有不足,但对整体系统影响较小。随着时间序列的延长,预测精度显著提升,进一步证实了本研究提出的双阶段协同超调量预测优化模型的有效性。

3.4 消融实验

1) 协同模型消融实验

为验证提出的基于 CNN-LSTM-Attention 的逆向系统

模型(设为 A 模型)和基于 Pyramid-CLT 的 PSO 选择性优化模型(设为 B 模型)的有效性和必要性,采用相同的样本数据集,对双阶段协同模型(设为 A+B)进行消融实验。针对 A 模型,无需其他操作,直接预测得到电机的输入指令;针对 B 模型,基于样本数据的全局统计、历史优化结果聚类 and 拉丁超立方采样^[40]给出 PSO 算法的初始值,对比评价结果如表 6 所示。

表 6 协同模型消融实验对比评价结果
Table 6 Comparative evaluation results of the ablation study on the collaborative model

算法模型	RMSE	MAE	R^2	平均预测时间/ms
A	0.655	0.517	0.980	4.402
B	3.258	1.796	0.753	216.135
A+B	0.537	0.442	0.985	16.343

实验结果表明,提出的双阶段协同模型在性能上显著优于单阶段模型 A 和 B。具体而言,协同模型的 RMSE 和 MAE 较单阶段模型显著降低,同时 R^2 显著提升。双阶段协同模型的平均预测时间为 16.343 ms,虽略高于模型 A,但其预测精度更高,且预测时间仍满足实时控制的要求,综合性能优于模型 A。相较于模型 B 的平均预测时间 216.135 ms,协同模型的预测时间大幅减少。外骨骼系统在辅助人体运动时,需要实时解读用户意图并生成电机指令,以实现同步助力。任何控制延迟都会导致人机不同步,从而放大用户的生理负担,甚至引发跌倒风险。Tucker 等^[41]通过生理-工程交叉分析指出,人体总运动循环约为 200~300 ms,其中人体固有延迟约为 70~100 ms。为实现有效的前馈助力,外骨骼必须在这一“前端”窗口介入,提供预测性补偿。为此,他们将控制延迟补偿目标设定为<30 ms,即外骨骼的整体延迟需显著低于人体延迟水平,否则将产生“滞后反馈”,降低系统透明度和用户体验。文章提出的双阶段协同模型,其平均预测时间仅为 16.343 ms,远低于 30 ms 要求,从而确保在外骨骼控制链路中有效补偿 70~100 ms 的人体延迟,避免滞后干扰,并提升整体同步性和安全性。

上述结果充分验证了基于 CNN-LSTM-Attention 的逆向系统模型与基于 Pyramid-CLT 的 PSO 选择性优化模型的协同效应,两者互为补充,不可或缺,共同显著提升了电机输入指令预测的精度和模型的整体性能。

2) 模型组件消融实验

为深入理解模型中各个组件的贡献,分别对两个模型进行消融实验。针对 CNN-LSTM-Attention 模型分别建立 CNN、LSTM、CNN-LSTM、CNN-LSTM-Attention 模型来对比验证,在相同数据集上的对比评价结果如表 7 所示。

表 7 CNN-LSTM-Attention 消融实验对比评价结果
Table 7 Comparative evaluation results of CNN-LSTM-Attention ablation experiments

算法模型	RMSE	MAE	R^2
CNN	0.985	0.685	0.734
LSTM	1.341	0.958	0.697
CNN-LSTM	0.757	0.540	0.766
CNN-Attention	0.897	0.637	0.789
LSTM-Attention	0.820	0.575	0.811
CNN-LSTM-Attention	0.655	0.517	0.980

实验结果表明,构建的 CNN-LSTM-Attention 模型的 R^2 为 0.980,相较于 CNN、LSTM、CNN-LSTM、CNN-Attention 和 LSTM-Attention 分别提升了 25.05%、28.88%、21.83%、24.21% 和 20.84%;RMSE 和 MAE 分别为 0.655 和 0.517,与其他组件相比, RMSE 降低了 33.49%、51.17%、13.50%、26.98% 和 20.12%, MAE 降低了 24.62%、46.09%、4.37%、18.84% 和 10.09%。

CNN 能够提取局部特征,减少特征冗余,为 LSTM 提供更高质量的输入;LSTM 捕捉长短期依赖关系,使模型能够学习更复杂的序列模式,为 Attention 提供丰富的上下文信息,便于后续聚焦重要时间步;Attention 注意力机制对 LSTM 的输出加权,聚焦关键时间步。通过降维、序列建模和加权,协同模型能够有效利用输入数据中的信息。综上,CNN、LSTM 和 Attention 模块的协同作用显著提高了模型性能,每个模块在构建指令预测模型中均发挥了重要作用,缺一不可。

针对 Pyramid-CLT 模型分别建立 CNN、LSTM、Transformer 编码器、CNN-LSTM、CNN-Transformer、LSTM-Transformer、CNN-LSTM-Transformer、Pyramid-CLT 模型来对比验证,在相同数据集上的对比评价结果如表 8 所示。

表 8 Pyramid-CLT 消融实验对比评价结果
Table 8 Comparative evaluation results of Pyramid-CLT ablation experiments

算法模型	RMSE	MAE	R^2
CNN	1.326	0.999	0.964
LSTM	1.181	0.901	0.971
Transformer 编码器	4.129	2.868	0.768
CNN-LSTM	1.169	0.881	0.972
CNN-Transformer	2.927	1.082	0.963
LSTM-Transformer	5.298	3.533	0.458
CNN-LSTM-Transformer	4.898	3.274	0.677
Pyramid-CLT	1.085	0.818	0.974

由实验结果可知,构建的 Pyramid-CLT 模型的 R^2 为 0.974,相较于 CNN、LSTM、Transformer、CNN-LSTM、CNN-Transformer、LSTM-Transformer 和 CNN-LSTM-Transformer 分别提升了 1.03%、0.33%、21.13%、0.25%、1.14%、112.66% 和 30.50%。RMSE 和 MAE 分别为 1.085 和 0.818,与 CNN、LSTM、Transformer、CNN-LSTM、CNN-Transformer、LSTM-Transformer 和 CNNLSTM-Transformer 相比, RMSE 降低了 18.17%、8.11%、73.73%、7.22%、62.9%、79.5% 和 77.85%。MAE 降低了 18.13%、9.21%、71.47%、7.15%、24.4%、76.8% 和 75.01%。

CNN 作为特征提取器,捕捉相邻时间步之间的局部模式,为 LSTM 提供更丰富的输入;LSTM 桥接 CNN 的局部特征与 Transformer 的全局注意力,将序列编码成上下文丰富的表示,有效处理梯度消失;Transformer 作为全局整合器,将 LSTM 的局部时序表示转化为注意力加权的全局视图,帮助模型在短序列上捕捉复杂交互;Pyramid 融合多尺度特征,丰富了 CNN 输出特征的表达能力,为后续的 LSTM 和 Transformer 提供更全面的输入。移除 Pyramid 后,模型丢失了多尺度特征提取能力,削弱了对复杂序列模式的建模,从而降低了模型性能,由表 8 可知移除 Pyramid 的 CNN-LSTM-Transformer 模型 RMSE 和 MAE 明显上升, R^2 明显下降,表明其对预测外骨骼电机输出指令任务有重要作用。综合以上分析,验证了对于外骨骼输入输出关系预测任务,所设模型结构的有效性和必要性。

3) PSO 适应度函数消融实验

在融合逆向系统模型预测与前向模型优化的双阶段协同超调量预测优化策略中,设置 PSO 的适应度函数为 $f=MSE+SP+LP$,通过迭代优化第 1 阶段逆向模型提供的预测输出 Θ_{pre} 与目标输出 Θ_{target} 之间的 f ,从而优化电机输入指令。针对适应度函数分别设置 $f=MSE$, $f=MSE+SP$, $f=MSE+LP$, $f=MSE+SP+LP$ 来对比验证,在相同数据集上的对比评价结果如表 9 所示。

表 9 PSO 适应度函数消融实验对比评价结果

Table 9 Comparative evaluation results of the ablation study on PSO fitness function

适应度函数	RMSE	MAE	R^2
$f=MSE$	0.593	0.484	0.984
$f=MSE+SP$	0.602	0.494	0.977
$f=MSE+LP$	0.558	0.456	0.979
$f=MSE+SP+LP$	0.537	0.442	0.985

实验结果表明,以 MSE 为主导的适应度函数有效提高了电机优化输入指令与真实指令的匹配度。SP 促进了输入序列的连续性,而 LP 则使优化输入更接近初始猜

测。三者协同作用显著降低了优化指令与真实指令的 MSE 和 MAE,最终使 R^2 达到 0.985,从而提升了电机输入指令预测的精度和模型的整体性能。

3.5 不同预测方法对比分析

为了验证提出的双阶段优化策略有效性,在相同数据集上与多种经典及前沿算法进行对比实验,包括常见的反向传播神经网络(back propagation neural network, BPNN)、支持向量机(support vector machine, SVM)、循环神经网络(recurrent neural network, RNN)、深度神经网络(deep neural networks, DNN)和时间卷积网络(temporal convolutional network, TCN)以及目前预测任务领域先进的残差自注意力时间卷积网络(temporal convolutional network with residual self-attention, TCN-RSA)^[42],一种将 TCN 的局部特征提取能力与 RSA 的全局依赖建模能力相结合的融合模型,能够高效并行计算,增强稳定性;用于可解释时间序列预测的神经基础扩展分析(neural basis expansion analysis for interpretable time series, N-BEATS)^[43],一种通过堆叠全连接神经网络,将时间序列分解为趋势和季节性分量,并通过基函数扩展进行预测的模型;TimesNet^[44],一种通过将一维时序数据转换为二维张量,并使用 2D 卷积捕捉内周期和间周期变异的创新时序模型;基于自回归循环网络的概率预测(deep autoregressive recurrent networks, DeepAR)^[45],能够从相关时间序列集合中联合学习全局模式。

为确保模型的泛化性能,实现各模型间的公平比较,采用 5 折交叉验证结合网格搜索进行超参数优化,对比结果如表 10 所示,模型预测对比结果如图 13 所示。

表 10 不同预测方法对比实验评价结果

Table 10 Comparison of different prediction methods

算法模型	RMSE	MAE	R^2
BP	1.055	0.730	0.739
SVM	0.761	0.580	0.927
RNN	0.925	0.651	0.742
DNN	1.029	0.728	0.675
TCN	0.804	0.564	0.742
TCN-RSA	0.826	0.590	0.807
N-BEATS	0.712	0.469	0.878
TimesNet	0.819	0.540	0.844
DeepAR	0.965	0.673	0.777
Proposed	0.537	0.442	0.985

相较于提出的模型,经典算法和用于对比的两种先进算法的 RMSE 和 MAE 均有不同程度的升高, R^2 均有不同程度的下降。其中, BPNN、SVM 和 RNN 处理时序

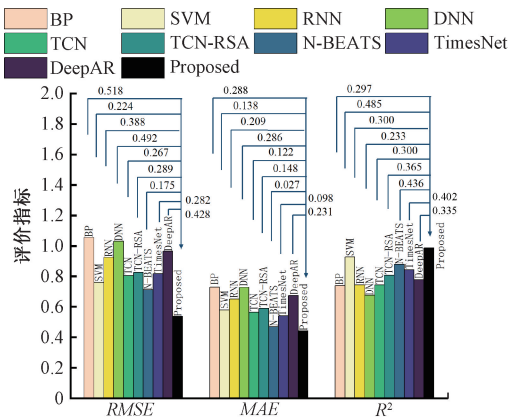


图 13 不同预测方法对比实验

Fig. 13 Comparison of different prediction methods

数据时都无法显式捕捉时间依赖关系,难以平衡各输出变量的预测精度导致性能较差;DNN 忽略时序数据的顺序信息,需将序列展平或构造时间窗特征,丢失动态特性;TCN 因感受野不足和对非线性的建模能力有限导致对某些输出的预测偏差较大。TCN-RSA 对复杂动态变化的外骨骼电机输出数据的建模能力较弱,更适合局部规律性模式,导致模型性能较差;N-BEATS 缺乏显式时序结构建模,且对噪声或异常值较为敏感,导致其在外骨骼电机指令预测上表现不佳;TimesNet 对变量间非线性交互建模不足,缺乏有效的长距离依赖捕捉机制,在处理外骨骼电机输出的非平稳和突发变化时,预测精度下降,导致其在外骨骼电机指令预测上表现不佳;DeepAR 的自回归机制在多步预测中,早期错误累积导致长时程预测不稳定并且作为 RNN 变体,DeepAR 易受异常影响。文章提出的双阶段模型,能够高效提取外骨骼电机的非周期性、非线性输入输出指令的局部与全局特征,通过注意力机制动态加权平衡多个时间步预测,得到初始预测指令,并结合前向模型和 PSO 优化算法进一步提高预测精度,确保外骨骼实时、精准地响应人体下肢运动意图。

4 结 论

针对下肢外骨骼电机动态特性导致的惯性超调问题,以人体行走模式抬腿阶段髋关节为研究对象,提出了一种融合逆模型预测与前向模型优化的双阶段协同超调量预测优化策略。该策略以人体下肢运动轨迹作为电机目标值,在第 1 阶段通过基于 CNN-LSTM-Attention 的逆向系统模型生成电机初始预测输入指令;在第 2 阶段利用基于 CNN-LSTM-Transformer 的 PSO 选择性优化模型对输入指令进行进一步优化调整,从而在保证实时性的同时显著提升了预测精度。实验验证

表明,提出的模型能够有效提取电机输入输出特征,精准捕获数据依赖关系,与其他预测算法相比,表现出更优的性能。该方法有效实现了外骨骼电机输出的超调修正,确保外骨骼能够实时、精确地响应人体下肢运动意图,为下肢外骨骼的控制优化提供了新的理论和技术,可供参考。

在后续研究工作中,将考虑引入重力因素,纳入放腿阶段的电机指令预测,实现行走模式全周期的预测覆盖。同时,通过结合更多工况的数据,进一步验证所提方法的实际应用能力,以提升其鲁棒性和泛化性能,从而更好地满足下肢外骨骼实时控制的任务需求。

参考文献

- [1] LIM C D, WANG C M, CHENG C Y, et al. Sensory cues guided rehabilitation robotic walker realized by depth image-based gait analysis [J]. IEEE Transactions on Automation Science & Engineering, 2016, 13(1): 171-180.
- [2] MAGGIONI S, MELENDEZ-CALDERON C, VAN ASSELDONK E, et al. Robot-aided assessment of lower extremity functions: A review [J]. Journal of Neuro-engineering & Rehabilitation, 2016, 13(1): 72.
- [3] LIANG F, QIN P J, SHI X, et al. A novel method of lower limbs locomotion transition and steady modes classification based on sEMG signals [J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 1-14.
- [4] 孟琳, 宋钊熙, 董洪涛, 等. 被动踝足外骨骼对平地行走时运动表现的影响 [J]. 电子测量与仪器学报, 2023, 37(6): 14-21.
- MENG L, SONG ZH X, DONG H T, et al. Effects of a passive ankle-foot exoskeleton on motion performance during overground walking [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(6): 14-21.
- [5] 范玫杉, 陈春杰, 王灿, 等. 脑瘫儿童康复助行外骨骼机器人研究与展望 [J]. 仪器仪表学报, 2023, 44(6): 1-10.
- FAN M SH, CHEN CH J, WANG C, et al. Research status and the prospect of the lower limb exoskeleton robots for children with cerebral palsy [J]. Chinese Journal of Scientific Instrument, 2023, 44(6): 1-10.
- [6] MEULEMAN J, VAN ASSELDONK E, VAN OORT G, et al. LOPES II—Design and evaluation of an admittance

- controlled gait training robot with shadow-leg approach[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2016, 24(3): 352-363.
- [7] RIENER R, LÜNBURGER L, MAIER I C, et al. Locomotor training in subjects with sensori-motor deficits: An overview of the robotic gait orthosis lokomat[J]. Journal of Healthcare Engineering, 2010, 1(2): 197-216.
- [8] STAUFFER Y, ALLEMAND Y, BOURI M, et al. The walktrainer—a new generation of walking reeducation device combining orthoses and muscle stimulation[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2009, 17(1): 38-45.
- [9] BANALA S K, KIM S H, AGRAWAL S K, et al. Robot assisted gait training with active leg exoskeleton (ALEX)[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2009, 17(1): 2-8.
- [10] ZHANG SH SH, GUAN X, YE J, et al. Gait deviation correction method for gait rehabilitation with a lower limb exoskeleton robot[J]. IEEE Transactions on Medical Robotics and Bionics, 2022, 4(3): 754-763.
- [11] DORF R C, BISHOP R H. Modern control systems: Twelfth edition[M]. London: Pearson, 2010.
- [12] PRATT J E, KRUPP B T, MORSE C J, et al. The RoboKnee: An exoskeleton for enhancing strength and endurance during walking[C]. 2004 IEEE International Conference on Robotics and Automation, 2004: 2430-2435.
- [13] ZHANG J J, FIERS P, WITTE K A, et al. Human-in-the-loop optimization of exoskeleton assistance during walking[J]. Science, 2017, 356(6344): 1280-1284.
- [14] YOUNG, A J, FERRIS D P. State of the art and future directions for lower limb robotic exoskeletons[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2017, 25(2): 171-182.
- [15] KAMALI K, AKBARI A A, AKBARZADEH A. Trajectory generation and control of a knee exoskeleton based on dynamic movement primitives for sit-to-stand assistance[J]. Advanced Robotics, 2016, 30(13): 846-860.
- [16] SUN T Y, CHEN ZH L, GUO Q, et al. Optimization of exoskeleton trajectory toward minimizing human joint torques[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2025, 33: 1231-1241.
- [17] HUANG R, CHENG, H, CHEN Y, et al. Optimisation of reference gait trajectory of a lower limb exoskeleton[J]. International Journal of Social Robotics, 2016, 8: 223-225.
- [18] ZHANG Y P, CAO G ZH, Li L L, et al. AEKF-based trajectory-error compensation of knee exoskeleton for human-exoskeleton interaction control[J]. Robotic Intelligence and Automation, 2024, 44(1): 84-95.
- [19] JENHANI S, GRITLI H, NARAYAN J. LMI-based robust control of a knee rehabilitation exoskeleton robot using a nonlinear composite controller[C]. 2025 IEEE International Conference on Interdisciplinary Approaches in Technology and Management for Social Innovation, 2025: 1-6.
- [20] CHEN B, ZHONG CH H, ZHAO X, et al. Reference joint trajectories generation of CUHK-EXO exoskeleton for system balance in walking assistance[J]. IEEE Access, 2019, 2019(7): 33809-33821.
- [21] PEREZ-SAN LAZAROR, FUENTES-AGUILAR R Q, CHAIREZ I. Human-robot cooperative adaptive reinforcement constraint control for a lower limb rehabilitation exoskeleton based on user's movement intention[J]. IEEE Transactions on Medical Robotics and Bionics, 2025, 7(2): 607-620.
- [22] 王成元, 夏加宽, 孙宜标. 现代电机控制技术[M]. 北京: 机械工业出版社, 2018.
- WANG CH Y, XIA J K, SUN Y B. Modern electric motor control technology[M]. Beijing: Mechanical Industry Press, 2018.
- [23] 尹诗菊, 郑志安, 朱俊杰. 基于延迟补偿的永磁同步电机并行自抗扰控制[J]. 仪器仪表学报, 2024, 45(3): 275-285.
- YIN SH X, ZHENG ZH AN, ZHU J J. Time delay compensation-based parallel active disturbance rejection control for permanent magnet synchronous motors[J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 275-285.
- [24] 邓聪颖, 舒杰, 陈翔, 等. 多参数变化下基于参数辨识的永磁同步电机偏差解耦控制方法[J]. 仪器仪表学报, 2022, 43(6): 260-268.
- DENG C Y, SHU J, CHEN X, et al. A deviation decoupling control method of permanent magnet

- synchronous motor based on parameter identification under multi-parameter variation[J]. Chinese Journal of Scientific Instrument, 2022, 43(6): 260-268.
- [25] 哈利勒·哈桑·K. 非线性系统(第三版)[M]. 北京: 电子工业出版社, 2017.
- KHALIL H K. Nonlinear systems (third edition)[M]. Beijing: Publishing House of Electronics Industry, 2017.
- [26] SHAMAEI K, NAPOLITANO P C, DOLLAR A M. Design and functional evaluation of a quasi-passive compliant stance control knee-ankle-foot orthosis[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2014, 22(2): 258-268.
- [27] QIU SH Y, GUO W, CALDWELL D, et al. Exoskeleton online learning and estimation of human walking intention based on dynamical movement primitives[J]. IEEE Transactions on Cognitive and Developmental Systems, 2021, 13(1): 67-79.
- [28] 刘成菊, 耿铨东, 张长柱, 等. 基于自学习中枢模式发生器的仿人机器人适应性行走控制[J]. 自动化学报, 2021, 47(9): 2170-2181.
- LIU CH J, GENG W D, ZHANG CH ZH, et al. Adaptive locomotion control of humanoid robot based on self-learning CPG[J]. Acta Automatica Sinica, 2021, 47(9): 2170-2181.
- [29] GUI K, LIU H H, ZHANG D G. A practical and adaptive method to achieve EMG-based torque estimation for a robotic exoskeleton[J]. IEEE/ASME Transactions on Mechatronics, 2019, 24(2): 483-494.
- [30] 石欣, 敖钰民, 范智瑞, 等. 基于 sEMG 的下肢连续运动切换态实时识别方法[J]. 仪器仪表学报, 2024, 45(4): 165-174.
- SHI X, AO Y M, FAN ZH R, et al. Real-time recognition method of switching states of continuous lower limb movements based on sEMG[J]. Chinese Journal of Scientific Instrument, 2024, 45(4): 165-174.
- [31] 石欣, 余可祺, 敖钰民, 等. 基于下肢 sEMG 的疲劳模糊增量熵表征方法研究[J]. 仪器仪表学报, 2024, 45(5): 271-280.
- SHI X, YU K Q, AO Y M, et al. Research on entropy of incremental fuzzy entropy representation model for lower limb fatigue based on sEMG[J]. Chinese Journal of Scientific Instrument, 2024, 45(5): 271-280.
- [32] LIU H J, ZHU CH, ZHOU Z, et al. Synergetic gait prediction and compliant control of SEA-driven knee exoskeleton for gait rehabilitation[J]. Front Bioeng Biotechnol. 2024, 12: 1358022.
- [33] KOO B H, SIU H C, PETERSEN L G. Sensor-agnostic, LSTM-based human motion prediction using sEMG data[J]. Sensors, 2025, 25(17): 5474.
- [34] QIN P J, SHI X, ZHANG CH M, et al. Continuous estimation of the lower-limb multi-joint angles based on muscle synergy theory and state-space model[J]. IEEE Sensors Journal, 2023, 23(8): 8491-8503.
- [35] XU P, ZHU X T, CLIFTON D A. Multimodal learning with transformers: A survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45: 12113-12132.
- [36] SHAMI T M, EL-SALEH A A, ALSWAITTI M, et al. Particle swarm optimization: A comprehensive survey[J]. IEEE Access, 2022, 10: 10031-10061.
- [37] LEVANGIE P K, NORKIN C C. Joint structure and function: A comprehensive analysis[M]. Philadelphia: F. A. Davis Company, 2005.
- [38] RAJAGOPAL A, DEMBIA C L, DEMERS M S, et al. Full-body musculoskeletal model for muscle-driven simulation of human gait[J]. IEEE Transactions on Biomedical Engineering, 2016, 63(10): 2068-2079.
- [39] NORKIN C C, WHITE D J. Measurement of joint motion: A guide to goniometry (fifth edition)[M]. Philadelphia: F. A. Davis Company, 2016.
- [40] SHU ZH, JIRUTITIJAROEN P. Latin hypercube sampling techniques for power systems reliability analysis with renewable energy sources[J]. IEEE Transactions on Power Systems, 2011, 26(4): 2066-2073.
- [41] TUCKER M R, OLIVIER J, PAGEL A, et al. Control strategies for active lower extremity prosthetics and orthotics: A review[J]. Journal of NeuroEngineering and Rehabilitation, 2015, 12(1): 1.
- [42] CAO Y D, DING Y F, JIA M P, et al. A novel temporal convolutional network with residual self-attention mechanism for remaining useful life prediction of rolling bearings[J]. Reliability Engineering & System Safety, 2021, 215: 107813.
- [43] VAN BELLE J, CREVITS R, CALJON D, et al. Probabilistic forecasting with modified N-BEATS networks[J]. IEEE Transactions on Neural Networks and Learning

Systems, 2024, 35(12): 18872-18885.

[44] WU H X, HU T G, LIU Y, et al. TimesNet: Temporal 2D-variation modeling for general time series analysis[C]. The Eleventh International Conference on Learning Repre-sentations, 2023.

[45] SALINAS D, FLUNKERT V, GASTHAUS J, et al. DeepAR: Probabilistic forecasting with autoregressive recurrent networks[J]. International Journal of Forecasting, 2020, 36(3): 1181-1191.

作者简介



石欣(通信作者), 2003 年和 2010 年于重庆大学分别获得硕士学位和博士学位。现为重庆大学教授、博士生导师, 主要研究方向为智能控制、无线传感网络。

E-mail: shixin@cqu.edu.cn

Shi Xin (Corresponding author) received his M. Sc. and Ph. D. degrees both from Chongqing University in 2003 and 2010, respectively. He is currently a professor and Ph. D. advisor at Chongqing University. His main research interests

include intelligent control and wireless sensor network.



唐佳, 2023 年于重庆大学获得学士学位。现于重庆大学攻读硕士学位, 主要研究方向为传感控制与信号处理。

E-mail: 1636727616@qq.com

Tang Jia received her B. Sc. degree from Chongqing University in 2023. She is currently a M. Sc. candidate at Chongqing University. Her main research interests include sensing control and signal processing.



秦鹏杰, 2015 年于重庆科技大学获得学士学位。2023 年于重庆大学获得博士学位。现为深圳大学人工智能学院助理教授。主要从事多模态人机交互研究。

E-mail: pj.qin@szu.edu.cn

Qin Pengjie received his B. Sc. degree from Chongqing University of Science and Technology in 2015, his Ph. D. degree from Chongqing University in 2023. He is currently an assistant professor in the School of Artificial Intelligence at Shenzhen University. His main research interest includes multimodal human-computer interaction.