



可拓门控网络驱动的下肢外骨骼智能控制方法研究

余昊阳, 李兴森, 颜伊庆

引用本文:

余昊阳, 李兴森, 颜伊庆. 可拓门控网络驱动的下肢外骨骼智能控制方法研究[J]. 智能系统学报, 2026, 21(5): 1323-1334.

YU Haoyang, LI Xingsen, YAN Yiqing. Extension gating network-driven intelligent control method for lower-limb exoskeletons[J]. CAAI transactions on intelligent systems, 2026, 21(5): 1323-1334.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202510022>

您可能感兴趣的其他文章

循环神经网络前馈补偿的压电驱动器跟踪控制

Tracking control of piezoelectric actuator based on feedforward compensation of recurrent neural network
智能系统学报. 2021, 16(3): 567-574 <https://dx.doi.org/10.11992/tis.202104010>

利用肌电信号求解关节力矩的研究及应用综述

A review of the research and application of calculating joint torque by electromyography signals
智能系统学报. 2020, 15(2): 193-203 <https://dx.doi.org/10.11992/tis.202001013>

仿生机器人运动步态控制: 强化学习方法综述

Locomotion gait control for bionic robots: a review of reinforcement learning methods
智能系统学报. 2020, 15(1): 152-159 <https://dx.doi.org/10.11992/tis.201907052>

基于动态系统的机器人模仿学习方法研究

Research on robot imitation learning method based on dynamical system
智能系统学报. 2019, 14(5): 1026-1034 <https://dx.doi.org/10.11992/tis.201807018>

基于0/-1特征值的网络可控性优化研究

Optimizing network controllability based on eigenvalue 0/-1
智能系统学报. 2019, 14(3): 589-596 <https://dx.doi.org/10.11992/tis.201801007>

下肢外骨骼研究进展及关节运动学解算综述

Research progress of lower-limb exoskeleton and joint kinematics calculation
智能系统学报. 2018, 13(6): 878-888 <https://dx.doi.org/10.11992/tis.201804063>

DOI: 10.11992/tis.202510022

网络出版地址: <https://link.cnki.net/urlid/23.1538.tp.20260320.1420.002>

可拓门控网络驱动的下肢外骨骼智能控制方法研究

余昊阳^{1,2}, 李兴森^{1,2}, 颜伊庆^{1,2}

(1. 广东工业大学 可拓学与创新方法研究所, 广东 广州 510006; 2. 广东工业大学 机电工程学院, 广东 广州 510006)

摘要: 下肢外骨骼技术在康复医疗与日常助行领域展现出广阔应用前景, 但其在复杂地形下的自适应控制智能性不足。针对现有下肢外骨骼在复杂地形中控制策略迁移性差、动态适应性弱等问题, 提出一种融合可拓门控网络与时间卷积专家的混合专家模型。该模型利用可拓距离函数动态量化地形特征与专家模块的匹配度, 实现多源步态信息的智能路由与自适应决策, 并通过时间卷积专家系统的时序建模能力, 生成符合人体运动特征的精准辅助力矩。在包含平地、斜坡等多种地形的实验中, 模型髋关节力矩预测平均误差较 LSTM(long short-term memory) 降低 18.71%, 平均推理时间仅为 37.09 ms。在场景转换实验中, 模型平均误差较 LSTM 降低 17.75%。该模型有效提升了外骨骼系统的跨场景适应能力, 其可拓门控网络路由机制与信息融合架构对多模态机器人决策系统、神经网络路由优化等研究领域均有一定参考价值。

关键词: 可拓神经网络; 时间卷积网络; 混合专家模型; 可拓智能; 可拓距; 下肢外骨骼; 关节力矩估计; 智能控制系统

中图分类号: TP18 **文献标志码:** A **文章编号:** 1673-4785(2026)05-1323-12

中文引用格式: 余昊阳, 李兴森, 颜伊庆. 可拓门控网络驱动的下肢外骨骼智能控制方法研究 [J]. 智能系统学报, 2026, 21(5): 1323-1334.

英文引用格式: YU Haoyang, LI Xingsen, YAN Yiqing. Extension gating network-driven intelligent control method for lower-limb exoskeletons[J]. CAAI transactions on intelligent systems, 2026, 21(5): 1323-1334.

Extension gating network-driven intelligent control method for lower-limb exoskeletons

YU Haoyang^{1,2}, LI Xingsen^{1,2}, YAN Yiqing^{1,2}

(1. Institute of Extenics and Innovation Methods, Guangdong University of Technology, Guangzhou 510006, China; 2. School of Electromechanical Engineering, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: Lower-limb exoskeleton technology holds substantial promise for applications in rehabilitation medicine and daily mobility assistance. However, achieving adaptive control across complex terrains remains a critical challenge. To address the limited transferability of control strategies and inadequate dynamic adaptability in current systems, this study introduces a mixture-of-experts model that integrates extension gating network with temporal convolutional experts. The model utilizes an extension distance function to dynamically quantify the compatibility between terrain features and expert modules, thereby enabling intelligent routing and adaptive decision-making based on multi-source gait information. By leveraging the temporal modeling capabilities of temporal convolutional experts, the system generates precise assistive torques aligned with human motion patterns. In experiments involving multiple terrains including flat ground and slopes, the proposed model reduced the average hip joint torque prediction error by 18.71% compared to conventional LSTM, with an average inference latency of merely 37.09 ms. In scene transition experiments, the model demonstrates a 17.75% reduction in average error compared to LSTM. This model effectively enhances the cross-terrain adaptability of exoskeleton systems, and its extension gating network routing mechanism and information fusion architecture provide valuable insights for multimodal robotic decision-making and dynamic neural network routing optimization.

Keywords: extension neural network; temporal convolutional network; mixture-of-experts; extension intelligence; extension distance; lower-limb exoskeleton; joint moment estimation; intelligent control system

收稿日期: 2025-10-22. 网络出版日期: 2026-03-23.

基金项目: 国家自然科学基金项目 (72071191); 广东省自然科学基金项目 (2024A1515011324).

通信作者: 李兴森. E-mail: lixingsen@126.com.

随着人口老龄化的加剧及慢性病患者数量的持续攀升, 步态障碍与下肢康复的需求日益迫切^[1-2]。在此背景下, 主动式助力下肢外骨骼机器

人作为一种融合机械设计、传感技术和控制算法等多学科前沿的解决方案,展现出巨大的社会价值与应用潜力^[3-5]。然而,传统外骨骼系统在跨场景适应性和人机交互智能性方面仍存在显著瓶颈:其固定控制参数难以适应楼梯、斜坡及不平路面等地形变化^[6-9];刚性控制策略易引发人机运动冲突,极大制约了设备的实用化进程与应用场景拓展。

当前,外骨骼控制研究的核心聚焦于运动意图识别与动态响应优化两大关键问题。主流研究方法包括:基于表面肌电信号(surface electromyography, sEMG)的生物电控制^[10-11]、依托惯性测量单元(inertial measurement unit, IMU)的运动学控制^[12]、利用足底压力传感器的步态相位检测^[13],以及基于动力学模型的控制策略^[14]。传统外骨骼控制方法通常需依赖用户历史数据估计步态周期,并匹配预设力矩曲线以生成辅助输出,无法通过感知穿戴者的运动意图以实时优化控制策略。近年来,一些研究尝试结合多源传感器与神经网络架构,旨在通过实时运动意图识别实现更自然的人机交互。崔占贺等^[15]设计了 1D-CNN-SVM 混合模型,该轻量级模型在步态识别任务中达到了较高的准确率,但其依赖手工特征提取与单一关节运动信息,难以适应多任务场景下的动态变化;李鑫等^[16]提出了一种基于双源传感器与长短期记忆网络(long short-term memory, LSTM)网络的辨识方法,实现了高精度的步态相位识别,但该模型需依赖预定义相位划分规则,限制了其在复杂动作中的泛化能力;汤璐等^[17]设计的注意力机制 CNN-LSTM 模型实现了端到端的膝关节角度预测,但其依赖高精度肌电传感器,测量时需将电极贴近皮肤表面,容易增加使用者的不适感;Ren 等^[18]提出了基于 Transformer 与变分模态分解(variational mode decomposition, VMD)的 TFSformer 模型,该方法利用足底压力预测双侧髌膝关节角度,其多通道注意力机制能同时融合时间与压力维度特征,并采用 VMD 分解增强趋势提取能力,然而该模型计算复杂度较高,面临着延迟挑战。

在力矩预测的研究中,Zhang 等^[19]提出基于广义力矩特征生成与门控循环单元网络的髌关节力矩估计方法,该方法通过引入身高等身体参数,解决了个体间的差异性,在多种速度条件下降低了关节力矩估算误差,但该方法主要针对平地行走场景,在斜坡、楼梯等复杂地形下的适应性尚未得到充分验证;Molinaro 等^[20-21]开发了基于时间卷积网络(temporal convolutional network, TCN)的髌关节力矩估计方法,该方法利用躯干与

大腿 IMU 数据及髌关节角度计信息,在平地、楼梯、坡道等多种任务中实现了有效的力矩估计;此外,Transformer 架构在力矩预测上表现出了巨大的潜力。Daryakenari 等^[22]设计了 2 个独立的 Transformer 网络,其通过融合 sEMG 和 IMU 信号来预测下肢关节角度和力矩,与传统方法相比,该模型在关节角度预测方面显著优于最新基准方法,将 RMSE(root mean square error)误差降低了一个数量;Zhu 等^[23]将 Transformer 架构应用于可穿戴传感器数据处理,通过自注意力机制捕获步态序列的长期依赖关系,实现了对地面反作用力的高精度估计,该方法克服了以往使用测力台成本高、运动范围受限的问题,其模型在多种运动状态下表现出色。

尽管将传感器与深度学习相结合的力矩预测方法日益成熟,但现有模型在下肢关节力矩估计方面仍面临严峻挑战。一方面,在面对步行到爬楼等跨场景转换的任务中,单一神经网络模型由于缺乏有效的特征-任务解耦机制,容易导致模型性能出现下降;另一方面,Transformer 等高性能架构虽能提供更高精度的力矩预测,但将其部署在性能较弱的设备时,其较高的计算复杂度会带来更长的推理延时,无法满足外骨骼控制的实时性要求^[24]。

可拓学是一门以处理矛盾问题与智能决策为核心的新兴交叉学科,其核心理论包括基元理论、可拓集和可拓距等工具,能够有效处理系统动态变化中的不相容与不确定问题^[25-30]。可拓神经网络^[31](extension neural network, ENN)是可拓学理论与方法和神经网络的结合,该网络通过引入可拓距来量化特征与类别之间的动态关系,具备良好的边界适应能力与模型可解释性,尤其适用于需弹性决策边界和高解释要求的应用场景。此外,ENN 结构简单,具有响应速度快、内存占用少等优势,适合部署在算力资源受限的边缘计算环境,在故障诊断^[32]、智能路径规划^[33]和分类识别^[34]等诸多工程领域取得了良好应用效果。

为解决下肢外骨骼在复杂地形下控制策略迁移性差、动态适应性弱、实时性要求高的问题,本文融合可拓距方法与深度学习技术,在混合专家架构基础上对 ENN 与 TCN 进行协同改进,提出一种融合可拓门控网络(extension gating network, EGN)与时间卷积专家(temporal convolutional experts, TCE)的混合专家模型^[35](mixtures of experts, MoE),EGN-TCE-MoE。本文创新点如下:1)设计了一种混合专家架构 TCE-MoE。实现多专家并行处

理, 配合稀疏激活机制, 在保持低推理延迟的同时, 提升了模型的预测精度。2) 使用基于可拓距的 EGN 替代传统路由机制。通过引入可拓距函数构建动态匹配准则, 实时量化场景特征与专家模块的匹配度, 实现了地形变化的自适应感知, 提高了控制策略的迁移性, 解决了现有方法在场景突变时性能骤降的问题。3) 构建生物力学约束的力矩生成机制。TCE 专家模块采用因果膨胀卷积与残差连接架构, 有效捕捉步态运动的长期依赖特性, 集成生物力学约束机制, 确保输出力矩符合人体运动特征, 同时避免突变冲击。

1 基础模型

1.1 可拓神经网络

可拓神经网络是一种融合可拓学理论方法与人工神经网络技术的分类模型。它通过可拓神经元构成网络结构, 能够对物理对象进行定性及定量分析, 并借助神经网络的自适应能力实现对数据特征的高效学习。如图 1 所示, 可拓神经网络的结构包括输入层、隐藏层、输出层 3 部分。




图 1 可拓神经网络结构

Fig. 1 Structure of extension neural network

输入层用于接收基元输入, 其接受的一维基元可表示为

$$B_{uj}^p = (O_u, c_{uj}, v_{uj}); u = 1, 2, \dots, n; j = 1, 2, \dots, m$$

式中: O_u 为输入样本中的第 u 个分析对象, c_{uj} 表示分析对象 O_u 的第 j 个特征, v_{uj} 表示为该特征对应的量值, p 为样本的真实类别。

隐藏层由 s 个可拓神经元组成, s 对应类别总数。每个可拓神经元均接受来自输入层的 m 维特征, 并通过可拓距函数, 计算该对象与类别 l 之间的可拓距; 设 V_{uj} 表示基元 B_{uj} 的量值区间, 其最大值、最小值分别为 $v_{uj}^{\max}$ 和 $v_{uj}^{\min}$, 区间最优值为 v_{0uj} 。则可拓神经元的输出可表示为

$$y^l = 1 - \frac{1}{m} \sum_{j=1}^m e(v_{uj}, v_{0uj}, V_{uj})$$

式中 e 是基元 B_{uj} 的特征 c_{uj} 所对应的量值 v_{uj} 与区间 V_{uj} 的关于可拓距 ρ 的可拓距函数, 其计算公式为

$$e(v_{uj}, v_{0uj}, V_{uj}) = \begin{cases} \frac{\rho_{\text{left}}(v_{uj}, v_{0uj}, V_{uj})}{|v_{uj}^{\max} - v_{0uj}|} + 1, & v_{0uj} \in \left(v_{uj}^{\min}, \frac{v_{uj}^{\max} + v_{uj}^{\min}}{2}\right) \\ \frac{\rho_{\text{mid}}(v_{uj}, v_{0uj}, V_{uj})}{|v_{uj}^{\max} - v_{0uj}|} + 1, & v_{0uj} = \frac{v_{uj}^{\max} + v_{uj}^{\min}}{2} \\ \frac{\rho_{\text{right}}(v_{uj}, v_{0uj}, V_{uj})}{|v_{0uj} - v_{uj}^{\min}|} + 1, & v_{0uj} \in \left(\frac{v_{uj}^{\max} + v_{uj}^{\min}}{2}, v_{uj}^{\max}\right) \end{cases} \quad (1)$$

当最优点 v_{0uj} 位于区间中点时, 定义

$$\rho_{\text{mid}}(v_{uj}, v_{0uj}, V_{uj}) = |v_{uj} - v_{0uj}| - \frac{(v_{uj}^{\max} - v_{uj}^{\min})}{2}$$

为输入特征量值 v_{uj} 与区间 V_{uj} 关于 v_{0uj} 的中点可拓距。

对于给定特征量值区间为 $V_{uj} = [v_{uj}^{\max}, v_{uj}^{\min}]$, 当其最优点 $v_{0uj} \in \left(v_{uj}^{\min}, \frac{v_{uj}^{\max} + v_{uj}^{\min}}{2}\right)$ 时, 定义

$$\rho_{\text{left}}(v_{uj}, v_{0uj}, V_{uj}) = \begin{cases} v_{uj}^{\min} - v_{uj}, & v_{uj} \leq v_{uj}^{\min} \\ \frac{v_{uj}^{\max} - v_{0uj}}{v_{uj}^{\min} - v_{0uj}} (v_{uj} - v_{uj}^{\min}), & v_{uj} \in (v_{uj}^{\min}, v_{0uj}) \\ v_{uj} - v_{uj}^{\max}, & v_{uj} \geq v_{0uj} \end{cases}$$

为输入特征量值 v_{uj} 与区间 V_{uj} 关于 v_{0uj} 的左侧可拓距。特别地, 当 $v_{0uj} = v_{uj}^{\min}$ 时, 取

$$\rho_{\text{left}}(v_{uj}, v_{uj}^{\min}, V_{uj}) = \begin{cases} v_{uj}^{\min} - v_{uj}, & v_{uj} < v_{uj}^{\min} \\ a_z, & v_{uj} = v_{uj}^{\min} \\ v_{uj} - v_{uj}^{\max}, & v_{uj} > v_{uj}^{\min} \end{cases}$$

其中

$$a_z = \rho_{\text{left}}(v_{uj}^{\min}, v_{uj}^{\min}, V_{uj}) = \begin{cases} 0, & v_{uj}^{\min} \notin V_{uj} \\ v_{uj}^{\min} - v_{uj}^{\max}, & v_{uj}^{\min} \in V_{uj} \end{cases}$$

当最优点 v_{0uj} 位于区间右侧时, 选用右侧可拓距, 其实现可参考左侧可拓距。

输出层接收隐藏层的输出结果, 并通过取最大值确定样本所属类别 $k^* = \text{argmax}[y^1, y^2, \dots, y^s]$ 。

1.2 时间卷积网络

时间卷积网络是一种为时序数据建模设计的深度学习架构。TCN 凭借因果膨胀卷积与残差连接机制, 在保持较低计算复杂度的同时, 能够有效捕捉长期时序依赖。TCN 的网络结构由多层时间卷积块堆叠构成, 每层时间卷积块结构如图 2 所示。定义第 l 层的输入为 $X^{(l)} \in \mathbb{R}^{T \times C^{(l)}}$, 其中 $C^{(l)}$ 为通道数, 则其计算公式为

$$X^{(l+1)} = R(W_2 * R(W_1 * X^{(l)})) + X^{(l)}$$

式中: $*$ 表示膨胀因子为 2^l 的一维卷积操作, W_1 、 W_2 为可学习权重矩阵, $R(\cdot)$ 为 ReLU 激活函数。其膨胀因子随网络层深呈指数增长, 确保感受野迅速扩展, 从而有效捕捉步态等周期性运动中的长程依赖关系。而残差连接则有助于缓解梯度消失问题、加速训练并增强网络稳定性。




图 2 时间卷积块结构

Fig. 2 Structure of temporal convolution block

TCN 在多项时序预测任务中表现出优于循环神经网络及长短期记忆网络的性能, 尤其适用于关节力矩估计等需要高精度计算、低延迟输出的场景。

2 EGN-TCE-MoE 模型构建与方法实现

本文提出了一种融合可拓门控网络与时间卷积专家的 EGN-TCE-MoE 模型。该模型的核心任务是一个回归问题, 其目标是通过多源传感器时序数据, 预测符合人体生物力学特征的髌关节辅助力矩。具体而言, 在给定 t 时刻起回溯时间步长为 T 的 D 维多源传感器时序数据 $X_t \in \mathbb{R}^{T \times D}$, 学习一个映射函数 f , 使其输出未来时刻的髌关节辅助力矩序列 $\hat{\tau}_t$, 并尽可能逼近真实力矩 τ_t 。其优化目标为最小化预测值与真实值之间的 RMSE, 数学定义为

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

2.1 多源时序特征提取

从多源生物力学传感器的动态步态数据中提取具有场景判别性的关键信息, 本文设计基于 CNN 的特征提取架构。该架构通过局部感知野

与层次化抽象实现步态模式的本质表征。定义输入数据为多通道时间序列张量 $X \in \mathbb{R}^{T \times D}$, 其中 T 为时间步长 D 为原始特征维度。输入时序信号首先通过维度置换操作重构张量结构 $X' = P(X) \in \mathbb{R}^{D \times T}$, 该变换将特征维度转换为卷积操作的通道维度, 以适应 CNN 的通道优先处理特性。特征提取流程采用 3 层架构。

1) 初级特征抽象层:

$H^{(1)} = \text{ReLU}(W_3 * X' + b_1)$, 其中 $H^{(1)}$ 表示该层输出; $\text{ReLU}(\cdot)$ 为激活函数; $*$ 表示一维卷积运算; W_3 为可训练卷积核, 其通过卷积操作中对输入数据的局部运动特征进行加权求和, 以捕获关节力矩波动等局部瞬态; b_1 是可训练偏置项, 其用于对输入进行偏移, 进而调整输出范围。

2) 高阶特征融合层:

$H^{(2)} = \text{ReLU}(W_4 * H^{(1)} + b_2)$, 次层卷积在首层卷积的基础上, 整合跨关节协同特征, 形成表征复杂步态模式的生物学行为编码。

3) 自适应最大池化层:

$v = \text{MaxPool}(H^{(2)})$, 最后通过自适应最大值池化压缩时序维度, 在保留各特征通道最显著响应的同时抑制步频波动干扰, 输出凝聚步态周期核心动力学特征的 D 维特征向量 v , 为后续的路由决策提供了标准化输入。

2.2 可拓门控网络构建

在传统混合专家模型中, 门控路由机制主要依据输入特征与专家权重的静态线性组合进行专家选择。然而, 此类方法在应用于下肢外骨骼多场景自适应控制时, 存在一定的局限性。其一, 传统 Softmax 门控的决策边界固定且缺乏弹性, 难以有效量化输入步态特征与不同专家模型能力域之间的动态匹配度, 导致在复杂地形切换时, 门控决策缺乏场景感知能力, 控制策略迁移性差; 其二, 传统 Softmax 门控机制本质上是概率权重分配, 其输出专家权重缺乏可解释的物理或逻辑边界, 无法清晰界定不同专家模型的“能力范围”, 难以适应步态特征动态变化导致的决策边界模糊问题。

为克服上述不足, 本文通过对现有 ENN 进行适配改进, 构建了 EGN 作为路由核心。EGN 将每个 TCE 模块视为一个具有弹性决策边界的量值区间。通过引入可拓距函数, EGN 能够动态计算并量化经过特征缩放后的多源时序输入特征与各专家的可拓距。该函数基于可拓距衡量输入特征相对于专家能力域的位置及匹配程度, 进而生成具备物理可解释性的专家激活权重。该机制

使 EGN 能够根据实时地形特征变化, 智能地感知场景差异, 实现基于特征匹配准则的动态路由决策, 显著增强了模型在跨场景步态控制中的自适应能力与决策鲁棒性。

如图 3 所示, 经特征提取后的输入向量 $\mathbf{v} = [v_1, v_2, \dots, v_m]$, 结合基元模型的建立方法, 构建输入特征的相关一维基元 $B_j = (O_j, c_j, v_j)$ 。定义第 i 个时间卷积专家关于基元 B_j 的特征量值区间为 $V_{ij} = [v_{ij}^{\max}, v_{ij}^{\min}]$, 其中 $v_{ij}^{\max}$ 、 $v_{ij}^{\min}$ 分别为该专家在特征空间的上界与下界参数。同时, 为消除多源传感器差异影响, 引入可训练特征缩放系数矩阵 $\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_m)$ 进行特征缩放 $\tilde{\mathbf{v}} = \Sigma \odot \mathbf{v}$, 参数 σ_j 用于求解传感器特征的最优加权组合, 以平衡各特征对场景分类的贡献权重。




图 3 EGN 模型结构

Fig. 3 EGN model structure

可拓距函数用于计算专家模型与当前场景特征之间的匹配度, 以确定专家的路由权重, 其具体计算方法如式 (1) 所示。当可拓距 $\rho \leq 0$ 时, 表示输入特征位于专家特征量值区间 V_{ij} 内, 且 $|\rho|$ 值越小表示匹配度越高; $\rho > 0$ 时则处于区间外。

专家 i 的匹配度路由权重可表示为

$$\tilde{g}_i = \exp \left((-1) \times \frac{1}{m} \sum_{j=1}^m e(\tilde{v}_j, v_{0ij}, V_{ij}) \right)$$

式中: e 为专家 i 对第 j 维输入特征的可拓距, $\tilde{v}_j$ 表示第 j 维传感器数据经过特征提取与缩放后的输入, V_{ij} 为专家 i 关于基元 B_j 的特征量值区间, v_{0ij} 为最优点, m 表示传感器全部输入维度。

最终根据匹配度结果, 在 n 个时间卷积专家中, 选取 k 个匹配度最高的专家, 并通过 Softmax 函数生成专家激活权重向量 $\mathbf{g} = [g_1, g_2, \dots, g_k]$ 。

2.3 时间卷积专家模型

TCE 作为混合专家架构的核心执行单元, 通过改进的时序卷积架构实现对原始生物力学信号的高效处理, 其采用因果膨胀卷积实现运动学时序建模, 融合了残差连接, 通过层级化特征抽象

捕获步态运动的长期依赖特性。为适应下肢外骨骼多场景自适应控制需求, TCE 在传统时间卷积网络基础上引入步态周期感知机制与生物力学约束模块, 以增强对复杂地形的泛化能力与控制稳定性。

改进后的 TCE 接收经可拓门控网络筛选的 D 维特征向量 $\mathbf{X} \in \mathbb{R}^{T \times D}$ 为输入, 其中 T 为时间步长, D 为特征维度, 最终输出符合生物力学约束的髋关节辅助力矩序列 $\tau \in \mathbb{R}^{T \times 1}$ 。其整体架构如图 4 所示。




图 4 TCE 模型结构

Fig. 4 TCE model structure

TCE 的网络结构由多层时间卷积块堆叠构成, 时间卷积块的结构如图 2 所示。TCE 通过指数级增长的扩张系数 $d^{(l)} = 2^l$, 在保持恒定参数量的前提下, 使感受野呈指数级扩展, 有效建模步态周期的长期依赖关系。为避免模型在训练过程中的梯度消失与爆炸问题, TCE 对每个权重向量进行了归一化, 并引入 Dropout 与残差连接。

最终, TCE 通过生物力学约束模块对输出力矩进行物理边界限制与平滑处理, 确保控制信号的安全性与连续性。该模块通过幅值约束限制力矩输出范围, 并采用指数加权平滑算法抑制力矩突变。其公式为: $\tau_t = (1 - \alpha) \cdot \tau_t + \alpha \cdot \tau_{t-1} \in [\tau_{\min}, \tau_{\max}]$, 其中 α 为平滑因子。

2.4 EGN-TCE-MoE 方法实施过程

本文所提出的 EGN-TCE-MoE 方法流程如图 5 所示。模型的实施过程采用端到端训练框架, 其核心流程可分为数据处理、路由决策、专家执行与输出生成 4 个阶段。具体实施步骤如下:

步骤 1 数据采集与划分。系统接收多源传感器数据作为输入, 将采集到的原始信号按受试者进行划分。随机选取 4 名受试者的全部数据为测试数据集, 其余受试者数据选取为训练集。

步骤 2 数据预处理。输入特征首先经过一维 CNN 进行时序特征抽取与归一化处理, 生成维度统一、时序结构清晰的特征向量, 为后续的路由决策提供标准化输入。




图 5 EGN-TCE-MoE 模型结构

Fig. 5 EGN-TCN-MoE model structure

步骤 3 可拓门控网络路由决策。将经过特征抽取后的数据转化为多个一维基元，送入 EGN 模块，用于动态选择最适配的专家子网络。首先，通过特征自适应缩放矩阵对输入特征进行归一化处理，消除不同传感器数据量纲差异；然后，采用可拓距函数计算输入特征与各专家的匹配度；最后，根据匹配度结果在拥有 n 个专家的专家网络中，激活 k 个匹配度最高的专家，并通过 Softmax 函数生成专家激活权重。该机制不仅实现了稀疏激活以提升计算效率，还赋予专家选择过程明确的物理可解释性。

步骤 4 专家执行与特征融合。根据 EGN 生成的路由权重，激活相应数量的 TCE 模块。被激活的 TCE 模块通过因果膨胀卷积与残差连接架构，对输入时序特征进行深度时序建模。TCE 模块内部集成生物力学约束机制，确保输出力矩符合人体运动特征。各专家输出通过加权求和进行特征融合，生成最终的髌关节辅助力矩预测。

步骤 5 端到端优化与输出。模型采用 RMSE 作为损失函数进行端到端训练，优化 EGN 路由权重与 TCE 专家参数。训练过程中，EGN 动态调整路由策略，使模型能够根据特征变化智能选择最优专家组合，实现跨场景控制策略的平滑迁移。最终输出为符合生物力学约束的髌关节辅助力矩，用于指导下肢外骨骼的实时控制。

3 下肢外骨骼自适应控制实验

本文围绕 EGN-TCE-MoE 模型在下肢外骨骼

多场景自适应控制中的有效性展开系统性验证，实验设计涵盖模型有效性验证、场景适应性评估与实时性能分析三大核心部分。第 1 部分通过消融实验验证混合专家架构与可拓门控网络路由机制的有效性；第 2 部分通过与主流时序建模方法在静态地形和动态场景转换中的对比实验，全面评估 EGN-TCE-MoE 在复杂地形下的性能优势；第 3 部分通过轻量化部署测试与推理延迟分析，验证模型在实际应用环境中的实时控制能力。

3.1 数据集与数据预处理

实验基于公开的步态数据集构建。数据集 1^[36] 由 34 名健康受试者 (24 名男性和 10 名女性，年龄 (25 ± 3) 岁，身高 (173 ± 8) cm，体重 (72 ± 10) kg) 在实验室环境下完成，涵盖平地、楼梯及斜坡 3 种典型地形下的髌关节运动学与动力学数据。数据采集任务设计为模拟真实场景，包含 35 种不同的速度坡度组合 (步速范围: $(0.6 \sim 1.9)$ m/s，坡度范围: $\pm 15^\circ$) 以及起步、转弯、台阶跨越等动态姿态转换任务，以覆盖下肢外骨骼在日常使用中可能面临的动态步态变化。数据集 2^[37] 包括 20 名健康受试者 (12 名男性和 8 名女性，年龄 (21 ± 3) 岁，身高 (170 ± 7) cm，体重 (68 ± 12) kg) 的实验数据，共包括跑步机行走、平地行走、坡道和楼梯上升下降 4 种运动模式。

为确保模型在真实应用场景中的泛化能力，实验采用留受试者交叉验证法。具体而言，每次将随机 4 名受试者的全部数据作为测试集，其余受试者的数据用于训练，共进行 10 轮独立验证。

该方法通过最大化测试集与训练集的分布差异,有效评估模型对跨个体步态特征的适应能力,避免过拟合风险。

实验数据中所有 IMU 信号均以 200 Hz 的采样频率进行采集,用于计算关节力矩的运动捕捉数据以 200 Hz 的采样频率采集,地面反作用力数据则以 1000 Hz 的采样频率采集,最终通过 Open-Sim 逆向动力学方法计算得出频率为 200 Hz 力矩标签。在计算关节力矩时,对动作捕捉数据和力矩数据均采用截止频率为 6 Hz 的 5 阶巴特沃斯低通滤波器进行滤波;对地面反作用力数据则采用截止频率为 20 Hz 的 5 阶巴特沃斯低通滤波器进行滤波。所有数据均进行了时间同步处理^[36-37]。原始传感器信号均通过归一化处理消除传感器间量纲差异,使各通道数据分布于统一尺度区间,为后续建模提供一致的输入基础。针对步态周期的非稳态特性,采用滑动窗口采样(窗口长度 1090 ms,步长 5 ms)提取时序特征,最终形成包含 12 维特征的输入张量 $\mathbf{X} \in \mathbb{R}^{218 \times 12}$ 。输入张量 $\mathbf{X}$ 的 12 维特征包括大腿 IMU 以及躯干 IMU 的三轴加速度与角速度。

3.2 实验环境及参数设置

实验代码基于 Python 3.12 开发,深度学习框架选用 PyTorch 2.7.1,训练环境配置为 NVIDIA RTX 5070 GPU 与 Ubuntu 24.04 操作系统,优化器使用 Adam。模型部署平台为 Intel N305 处理器与 8 GB 内存的边缘计算设备。

本文使用 TCN 作为对比模型及专家模块,其所有候选超参数如表 1 所示,Molinaro 等^[20]通过网络搜索评估了不同超参数组合对 TCN 模型性能的影响。结果表明,当卷积核大小设为 5、时间卷积块数量为 5、每层卷积通道数为 80、膨胀因子为 2 时,模型在多尺度特征提取能力与信息冗余控制之间达到较优平衡,在多种传感器输入和应用场景下实现最佳的泛化性能。受此启发,本文在预设的超参数范围内开展了初步实验,并最终选取在验证集上测试准确率更高的配置作为最终模型参数。

表 1 TCN 参数
Table 1 TCN parameter

参数名称	参数值	设定值
Dropout 概率	0.1,0.15,0.2,0.3	0.15
起始学习率	5×10^{-5} , 1×10^{-4} , 5×10^{-4}	5×10^{-5}
批次大小	32,64,128	64
迭代次数	100,200	100

续表 1

参数名称	参数值	设定值
卷积核大小	4,5,6,7	5
膨胀因子	2,3,4	2
时间卷积块数	3,4,5	5
每层通道数	30,50,80,100	80

表 2 所示为 EGN-TCE-MoE 模型的参数设定。在专家规模配置中,模型性能会随着参数量的增加而略微提升模型的测试准确率,但同时也显著增加了模型的计算复杂度。为了在模型复杂度和泛化能力之间取得平衡,本文选择了 4 激活/5 专家的配置。

表 2 EGN-TCE-MoE 参数
Table 2 EGN-TCE-MoE parameter

参数名称	参数值	设定值
路由学习率	1×10^{-5} , 5×10^{-5} , 1×10^{-4}	1×10^{-5}
激活专家数	2,3,4,5,6	4
专家数	3,5,7,9	5
平滑因子	0.05,0.1,0.15	0.1

3.3 模型有效性验证

为验证混合专家架构与可拓门控网络的有效性,本研究采用渐进式对比验证方法:首先基于原始时序卷积网络建立性能基准,随后引入混合专家架构进行性能对比,进而测试可拓门控网络路由策略的优化效果,并系统分析不同专家总数与激活专家数对模型表现的影响。

模型训练阶段采用均方根误差 RMSE 作为损失函数。模型验证阶段的性能评价指标为 RMSE (Nm/kg) 与决定系数 (coefficient of determination, R^2),其数学定义为

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

本轮实验分别使用数据集 1 和数据集 2 对模型进行有效性验证,实验结果通过留试验者交叉验证后,最终数据取 10 轮独立验证的平均。结果如表 3 所示。表 3 模型有效性验证结果分析如下:在数据集 1 上,基准 TCN 模型在未引入专家机制的情况下,扭矩预测误差为 0.148 Nm/kg, R^2 为 0.818。引入混合专家架构 TCN-MoE 后,模型性能提升显著:在“2/3”专家配置(即 3 位专家中激活 2 位)下, RMSE 降低至 0.142 Nm/kg,降幅

4.05%, R^2 提高至 0.844, 增幅 3.18%; 将专家规模扩展至 5 位并激活 4 位时, RMSE 进一步降至 0.136 Nm/kg, R^2 提升至 0.875; 继续增加专家规模至“5/7”后, 模型性能趋于稳定, RMSE 和 R^2 分别为 0.135 Nm/kg 和 0.873。进一步引入可拓门控网络构建的 EGN-TCE-MoE 架构在相同专家配置下

表现更优: 在专家配置为“2/3”的情况下, RMSE 为 0.137 Nm/kg, R^2 为 0.867, 在“4/5”的配置时 RMSE 降至 0.132 Nm/kg, 较基准 TCN 模型降低 10.81%, R^2 提升至 0.896, 增幅达 9.53%。数据集 2 上的实验结果与数据集 1 呈现一致趋势, 验证了模型改进策略的有效性与稳健性。

表 3 模型有效性验证
Table 3 Model validity verification

模型	专家激活	数据集1		数据集2	
		RMSE/(Nm/kg)	R^2	RMSE/(Nm/kg)	R^2
TCN	—	0.148	0.818	0.133	0.880
TCN-MoE	2/3	0.142	0.844	0.129	0.901
	4/5	0.136	0.875	0.125	0.911
	5/7	0.135	0.873	0.125	0.915
	2/3	0.137	0.867	0.126	0.907
EGN-TCE-MoE	4/5	0.132	0.896	0.121	0.924
	5/7	0.132	0.899	0.122	0.922

图 6 为经滤波处理后的力矩预测, 在面对因环境变化而导致的关节力矩突变时, 混合专家架构通过智能路由与专家机制有效提升了模型表征能力, 可拓门控策略实现了专家资源动态优化, 使得模型更快响应动作变化, 具有更高的预测精度与鲁棒性。




图 6 模型力矩预测对比

Fig. 6 Comparison of moment estimation among different models

3.4 模型先进性对比

为进一步验证本文提出架构的技术优势, 选用全连接前馈网络 (fully connected feedforward neural networks, FCNN)、LSTM 模型、汤璐等^[17]设计的注意力机制 CNN-LSTM 模型与 Zhu 等^[23]改进的 Transformer 模型作为基准对照组。为确保模型的最佳性能, 所有对比模型均采用 Adam 优化器, 并通过贝叶斯优化进行超参数调优。

FCNN 采用 5 层全连接架构, 每层依次包含

全连接运算、批量归一化与 ReLU 激活函数, 前 3 层为含 64 个神经元的隐藏层, 输出层使用线性激活函数实现回归预测, 其学习率为 5×10^{-4} , 训练轮次为 200, 批次大小为 64; LSTM 模型通过遗忘门与输入门机制捕获时序长期依赖, 其包含 2 个双向 LSTM 层, 每层 64 个隐藏单元, 最终通过全连接层输出预测结果, 模型的学习率为 1×10^{-3} , 训练轮次为 200, 批次大小为 64; CNN-LSTM 模型由 3 个模块组成, 其中 CNN 由 2 个卷积层组成, 分别有 64 和 128 个卷积核, LSTM 包含 2 个隐藏层, 分别有 128 和 64 个神经元, 最终通过全连接层输出, 该模型学习率为 5×10^{-4} , 训练轮次为 150, 批次大小为 64; 改进的 Transformer 模型则凭借着注意力机制实现长期感知, 其通过时序嵌入层对输入进行编码, 3 个 Transformer 编码器实现特征感知, 每层注意力头数为 4, 前馈网络维度为 256, 最终通过线性层进行输出, 其学习率为 1×10^{-4} , 训练轮次为 150, 批次大小为 32。

性能指标对比如表 4 所示, 在数据集 1 上, FCNN 的 RMSE 最高, 达到 0.173 Nm/kg, LSTM、TCN、CNN-LSTM 和改进的 Transformer 依次降低, 分别为 0.154、0.148、0.137 和 0.128 Nm/kg, 而 EGN-TCE-MoE 的 RMSE 为 0.132 Nm/kg。在数据集 2 上保持着同样的趋势 Transformer 的 RMSE 最低为 0.119 Nm/kg, EGN-TCE-MoE 为 0.121 Nm/kg。实验结果表明, EGN-TCE-MoE 相较于 FCNN、LSTM、TCN 和 CNN-LSTM, 在数据集 1 上 RMSE 分别降低 23.70%、14.29%、10.81%

和 3.65%, 在数据集 2 上 RMSE 分别降低 20.91%、18.79%、9.02% 和 3.2%, 验证了其整体优越性。同时, EGN-TCE-MoE 相较于 Transformer 模型有略微劣势, 其在数据集 1 上 RMSE 相差 3.13%, R^2 低 0.88%; 在数据集 2 上 RMSE 仅相差 1.68%, R^2 高 0.1%。这是因为 Transformer 模型的参数量更大, 且采用了自注意力机制, 能够全局捕捉输入序列中任意两个位置间的依赖关系, 在处理长程复杂任务时有着一定优势。

表 4 模型性能指标对比

Table 4 Comparison of model performance metrics

模型	数据集1		数据集2	
	RMSE/ (Nm/kg)	R^2	RMSE/ (Nm/kg)	R^2
FCNN	0.173	0.783	0.153	0.845
LSTM	0.154	0.811	0.149	0.865
TCN	0.148	0.818	0.133	0.882
CNN-LSTM	0.137	0.855	0.125	0.911
Transformer	0.128	0.904	0.119	0.923
EGN-TCE-MoE	0.132	0.896	0.121	0.924

结合图 7 的误差折线图进一步分析, FCNN 误差波动剧烈, 峰值达 ± 0.5 Nm, 显露出其在时序建模能力上的缺陷; CNN-LSTM 的误差虽有所降低, 但在力矩突变时出现了较大峰值, 反映了其在时空融合上的瓶颈。本文的 EGN-TCE-MoE 模型误差曲线与 Transformer 相近, 其在整个时间序

列上表现出了出色的稳定性, 峰值误差也低于 LSTM 和 CNN-LSTM。这表明了 EGN-TCE-MoE 模型通过智能路由决策有效提升了鲁棒性, 有效避免了传统模型在不同场景中的过拟合问题。




图 7 模型预测误差对比

Fig. 7 Model estimation error comparison

3.5 场景转换实验

为深入验证 EGN-TCE-MoE 模型在跨场景适应性的优势, 本文在数据集 2 上对模型开展了场景转换实验。实验通过分析模型在地形突变过渡段的表现, 评估控制策略的迁移能力与适应性。实验选取了包括平地斜坡转换与平地楼梯转换的 8 种典型场景转换类型, 覆盖了日常行走中常见的地形变化模式。在每种转换场景中, 提取了场景切换前后 1.5 s 的髋关节力矩预测数据作为基准, 计算 RMSE 以量化模型适应能力。实验结果如表 5 所示。

表 5 场景转换性能对比
Table 5 Performance comparison in scene transition

Nm/kg

场景	EGN-TCE-MoE	Transformer	CNN-LSTM	TCN	LSTM	FCNN
上坡至平地	0.137	0.140	0.145	0.151	0.168	0.170
平地至上坡	0.169	0.177	0.177	0.186	0.190	0.198
下坡至平地	0.149	0.148	0.156	0.163	0.179	0.181
平地至下坡	0.123	0.134	0.139	0.134	0.163	0.169
上楼梯至平地	0.118	0.118	0.121	0.123	0.150	0.151
平地至上楼梯	0.151	0.154	0.160	0.171	0.177	0.180
下楼梯至平地	0.133	0.135	0.143	0.147	0.162	0.164
平地至下楼梯	0.134	0.137	0.144	0.147	0.166	0.167
平均	0.139	0.143	0.148	0.153	0.169	0.173

结果表明, 本文提出的 EGN-TCE-MoE 模型在场景转换任务中展现出显著优势。在 8 种转换场景中, 该模型在 6 种场景下优于 Transformer 模型, 平均 RMSE 为 0.139 Nm/kg, 较 Transformer 模型降低 2.80%, 较 TCN 降低 9.15%。在最具挑战性平地至上坡的场景转换任务中, 相对 Transformer 模型, EGN-TCE-MoE 将 RMSE 降低了 4.52%, 这证明了可拓门控机制在应对地形突变时的优越适

应能力。此外, 在所有测试模型中, 除平地下坡转换外, 平地转换至其他场景的平均 RMSE 显著高于由其他场景转换至平地。这一现象与人体步态转换动力学特性密切相关, 即从平地进入变化地形时, 需要在短时间内完成步态模式切换、重心调整和肌肉激活策略重构, 而从变化地形返回平地时, 人体已提前建立了适应性控制策略, 转换过程更为平顺。EGN-TCE-MoE 通过可拓门控

机制对这种前向地形转换的复杂性进行了精准建模,在平地转换至其他场景的任务中较 Transformer 平均 RMSE 降低 4.22%,显著优于由其他场景转换至平地 0.74% 的性能提升。这表明可拓门控机制能够更敏锐地捕捉步态转换初期的关键生物力学特征,为外骨骼控制系统提供更及时精准的决策,有效缓解地形突变带来的适应性挑战。

3.6 模型部署测试

在外骨骼的实际部署环境中,控制系统延迟是影响用户体验与安全性的关键因素。根据文献 [37],合适的外骨骼辅助延迟有助于降低用户的代谢成本,当程序延迟控制在 100 ms 时,系统能有效降低用户能量消耗;而延迟低于 50 ms 或超过 150 ms 时,会增加用户的不适感。为验证 EGN-TCE-MoE 模型在实际应用中的潜力,本文对模型进行了轻量化部署测试。

分析表 6 数据可知,FCNN 因其结构简单,其平均推理时间最低,仅为 1.46 ms。TCN 通过膨胀卷积优化,平均推理时间为 9.61 ms,显著低于需顺序处理时序依赖的 LSTM 模型。值得注意的是,Transformer 模型与基于注意力机制的 CNN-LSTM 模型因其自注意力机制的 $O(n^2)$ 时间复杂度,其最大推理时间分别达到 315.02 和 271.79 ms,远超其他模型,这使其难以应用在对实时性要求苛刻的下肢外骨骼控制系统。本文提出的 EGN-TCE-MoE 模型在推理性能方面展现出显著优势,在专家配置为 4 激活/5 专家时,其平均推理时间为 37.09 ms,最大推理时间为 81.75 ms,均控制在 100 ms 最佳辅助时间内,可在适当延迟后为用户提供助力,满足了实际应用需求。虽然 EGN-TCE-MoE 的结构复杂度高于 LSTM 和 TCN,但其平均推理时间仅比 LSTM 高 7.5%,且最大推理时间不仅低于 LSTM,更远优于 Transformer 模型。这得益于其混合专家架构的参数稀疏激活特性,在推理时对于每个输入样本仅通过门控网络激活的部分专家,而非使用全部参数,从而有效控制了计算量。此外,可拓门控网络实现了对关键特征的高效路由,避免了不必要的计算。

表 6 模型推理延迟对比
Table 6 Comparison of model inference latency

模型	离线训练 时间/min	平均推理 时间/ms	最大推理 时间/ms
FCNN	3	1.46	4.17
LSTM	20	34.50	84.43
CNN-LSTM	80	112.85	271.79
TCN	30	9.61	24.41

续表 6

模型	离线训练 时间/min	平均推理 时间/ms	最大推理 时间/ms
Transformer	180	146.79	315.02
EGN-TCE-MoE (4激活/5专家)	165	37.09	81.75
EGN-TCE-MoE (2激活/3专家)	100	23.82	52.90

虽然在静态场景中,Transformer 模型展现出略优的性能,但在动态场景转换这一外骨骼机器人的核心应用场景中,EGN-TCE-MoE 凭借其可拓门控机制,实现了更加精准的控制策略迁移。同时,相较于 Transformer 模型,EGN-TCE-MoE 推理速度提升了 3.96 倍,在精度、实时性与适应性 3 方面取得了最佳平衡。这一结果充分证明,针对下肢外骨骼机器人的实际应用需求,EGN-TCE-MoE 的综合性能显著优于现有方法,验证了其在工程部署中的可行性与实际应用价值。

4 结束语

针对下肢外骨骼机器人跨场景适应性不足的难题,本文提出 EGN-TCE-MoE 模型,通过可拓函数动态量化多源步态特征与专家模块的匹配度,实现了复杂地形下控制策略的自适应迁移与专家资源的智能调度;同时,时间卷积专家模块凭借其强大的时序建模能力与内置的生物力学约束机制,确保了关节辅助力矩的精准生成与物理可行性。消融实验与跨模型对比验证了该架构在提升力矩预测精度与控制稳定性方面的显著优势,有效解决了传统方法在场景切换时的性能瓶颈。然而,当前研究主要聚焦于步态模式相对稳定的健康受试者,个体步态差异及病理性步态的极端变异可能影响模型的泛化能力。未来研究将深入探索面向个体差异的自适应学习策略,进一步优化模型的轻量化设计与实时计算效率,推动该智能控制框架在临床康复与日常辅助等更广泛场景中的实际应用,并探索该架构在多模态机器人决策系统、神经网络路由优化等多领域的应用潜力。

参考文献:

- [1] KAPSALYAMOV A, JAMWAL P K, HUSSAIN S, et al. State of the art lower limb robotic exoskeletons for elderly assistance[J]. *IEEE access*, 2019, 7: 95075–95086.
 - [2] 胡湛, 彭希哲. 应对中国人口老龄化的治理选择[J]. *中国社会科学*, 2018(12): 134–155, 202.
- HU Zhan, PENG Xizhe. Governance choices in dealing

- with China's aging population[J]. *Social sciences in China*, 2018(12): 134–155, 202.
- [3] KIM M S, SHIN I, PARK D G, et al. Post-stroke movement disorders disappearance: a report of disappearance of tardive dyskinesia after stroke and a literature review[J]. *Acta neurologica belgica*, 2023, 123(5): 2005–2007.
- [4] 郭毅锋, 邓凯, 黄丽敏, 等. 主动助力下肢康复外骨骼机器人研究现状[J]. *机械传动*, 2025, 49(5): 161–176.
- GUO Yifeng, DENG Kai, HUANG Limin, et al. Current research status of active-assist lower limb rehabilitation exoskeleton robots[J]. *Journal of mechanical transmission*, 2025, 49(5): 161–176.
- [5] 杨洁, 王旭鹏, 唐欣尧, 等. 无动力髋关节助力外骨骼设计与分析[J]. *机械传动*, 2024, 48(8): 70–81.
- YANG Jie, WANG Xupeng, TANG Xinyao, et al. Design and analysis of non-dynamic hip joint assisted exoskeletons[J]. *Journal of mechanical transmission*, 2024, 48(8): 70–81.
- [6] JEZERNIK S, COLOMBO G, KELLER T, et al. Robotic orthosis lokomat: a rehabilitation and research tool[J]. *Neuromodulation: technology at the neural interface*, 2003, 6(2): 108–115.
- [7] FRANKS P W, BRYAN G M, REYES R, et al. The effects of incline level on optimized lower-limb exoskeleton assistance: a case series[J]. *IEEE transactions on neural systems and rehabilitation engineering*, 2022, 30: 2494–2505.
- [8] FRANKS P W, BRYAN G M, MARTIN R M, et al. Comparing optimized exoskeleton assistance of the hip, knee, and ankle in single and multi-joint configurations [J]. *Wearable technologies*, 2021, 2: e16.
- [9] ZHANG Juanjuan, FIERS P, WITTE K A, et al. Human-in-the-loop optimization of exoskeleton assistance during walking[J]. *Science*, 2017, 356(6344): 1280–1284.
- [10] 牛苗赫, 雷飞. 面向下肢外骨骼的运动意图识别算法研究[J]. *智能系统学报*, 2025, 20(2): 407–415.
- NIU Miaohe, LEI Fei. Motion intention recognition algorithms for lower limb exoskeleton[J]. *CAAI transactions on intelligent systems*, 2025, 20(2): 407–415.
- [11] 孙国安, 赵明, 张廷丰, 等. 基于肌电预测模型的下肢外骨骼自适应控制方法[J]. *郑州大学学报(工学版)*, 2025, 46(3): 34–41.
- SUN Guoan, ZHAO Ming, ZHANG Tingfeng, et al. Adaptive control method of lower limb exoskeleton based on myoelectric prediction model[J]. *Journal of Zhengzhou University (engineering science)*, 2025, 46(3): 34–41.
- [12] 衣淳植, 贾翊丞, 姜峰, 等. 基于惯性测量单元的人体运动意图识别方法: 现状与挑战[J]. *智能系统学报*, 2025, 20(4): 763–775.
- YI Chunzhi, JIA Yicheng, JIANG Feng, et al. Human motion intention recognition method based on inertial measurement unit: current situation, and challenges[J]. *CAAI transactions on intelligent systems*, 2025, 20(4): 763–775.
- [13] 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 ordnance equipment engineering*, 2025, 46(5): 177–184.
- [14] 刘洋, 彭世国, 马宏志, 等. 下肢外骨骼机器人动力学参数辨识与步态跟踪[J]. *广东工业大学学报*, 2022, 39(6): 44–52.
- LIU Yang, PENG Shiguo, MA Hongzhi, et al. Dynamic parameter identification and gait tracking of lower limb exoskeleton robot[J]. *Journal of Guangdong University of Technology*, 2022, 39(6): 44–52.
- [15] 崔占贺, 艾莉莎, 马欣雨, 等. 基于1D-CNN-SVM的下肢外骨骼步态信息识别研究[J]. *电子测量技术*, 2025, 48(12): 71–78.
- CUI Zhanhe, AI Lisha, MA Xinyu, et al. Gait information recognition study of lower limb exoskeleton based on 1D-CNN-SVM[J]. *Electronic measurement technology*, 2025, 48(12): 71–78.
- [16] 李鑫, 徐赵洁, 柳金康, 等. 基于双源传感与LSTM的运动步态相位识别研究[J]. *传感器与微系统*, 2025, 44(4): 13–16, 20.
- LI Xin, XU Zhaojie, LIU Jinkang, et al. Research on phase recognition of motion gait based on dual source sensing and LSTM[J]. *Transducer and microsystem technologies*, 2025, 44(4): 13–16, 20.
- [17] 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 & processing*, 2024, 39(4): 996–1008.
- [18] REN Jiale, WANG Aihui, LI Hengyi, et al. A transformer-based neural network for gait prediction in lower limb exoskeleton robots using plantar force[J]. *Sensors*, 2023, 23(14): 6547.
- [19] ZHANG Yuanwen, XIONG Jingfeng, XIAN Haolan, et al. Joint moment estimation for hip exoskeleton control: a generalized moment feature generation method[J]. *Bioinformatic intelligence and robotics*, 2025, 5(4): 100246.
- [20] MOLINARO D D, SCHERPEREEL K L, SCHONHAUT E B, et al. Task-agnostic exoskeleton control via biological joint moment estimation[J]. *Nature*, 2024, 635(8038): 337–344.
- [21] MOLINARO D D, KANG I, CAMARGO J, et al. Sub-

- ject-independent, biological hip moment estimation during multimodal overground ambulation using deep learning[J]. *IEEE transactions on medical robotics and bionics*, 2022, 4(1): 219–229.
- [22] DARYAKENARI F H, FARIZEH T. A novel Transformer-based method for full lower-limb joint angles and moments prediction in gait using sEMG and IMU data [EB/OL]. (2025–06–05)[2025–10–22]. <https://arxiv.org/abs/2506.04577>.
- [23] ZHU Yeqing, XIA Di, ZHANG Heng. Using wearable sensors to estimate vertical ground reaction force based on a transformer[J]. *Applied sciences*, 2023, 13(4): 2136.
- [24] BAUD R, MANZOORI A R, IJSPEERT A, et al. Review of control strategies for lower-limb exoskeletons to assist gait[J]. *Journal of NeuroEngineering and rehabilitation*, 2021, 18(1): 119.
- [25] 杨春燕, 蔡文, 汤龙. 可拓学[M]. 2 版. 北京: 科学出版社, 2024.
- [26] 杨春燕, 李兴森. 可拓学 40 年发展历程及研究进展[J]. 广东工业大学学报, 2023, 40(6): 1–11.
YANG Chunyan, LI Xingsen. Development and research progress of extenics over the past 40 years[J]. *Journal of Guangdong University of Technology*, 2023, 40(6): 1–11.
- [27] 赵燕伟, 朱芬, 桂方志, 等. 基于可拓距的改进 k-means 聚类算法[J]. *智能系统学报*, 2020, 15(2): 344–351.
ZHAO Yanwei, ZHU Fen, GUI Fangzhi, et al. Improved k-means algorithm based on extension distance[J]. *CAAI transactions on intelligent systems*, 2020, 15(2): 344–351.
- [28] 陈晓华, 刘大莲, 田英杰, 等. 可拓支持向量分类机[J]. *智能系统学报*, 2018, 13(1): 147–151.
CHEN Xiaohua, LIU Dalian, TIAN Yingjie, et al. Extension support vector classification machine[J]. *CAAI transactions on intelligent systems*, 2018, 13(1): 147–151.
- [29] 张丽芳, 李兴森. 基元潜部特征元挖掘的智能方法研究[J]. *智能系统学报*, 2025, 20(2): 457–464.
ZHANG Lifang, LI Xingsen. Research on intelligent methods for latent features mining of basic element[J]. *CAAI transactions on intelligent systems*, 2025, 20(2): 457–464.
- [30] 田英杰, 刘大莲, 李兴森. 面向标签可变性的可拓分类方法[J]. 广东工业大学学报, 2025, 42(4): 1–7.
TIAN Yingjie, LIU Dalian, LI Xingsen. Extension classification method for label variability[J]. *Journal of Guangdong University of Technology*, 2025, 42(4): 1–7.
- [31] 周玉, 钱旭, 张俊彩, 等. 可拓神经网络研究综述[J]. *计算机应用研究*, 2010, 27(1): 1–5.
ZHOU Yu, QIAN Xu, ZHANG Juncai, et al. Survey and research of extension neural network[J]. *Application research of computers*, 2010, 27(1): 1–5.
- [32] 王体春, 夏天, 费叶琦. 融合卷积深度置信网络与可拓神经网络的齿轮故障诊断方法[J]. *计算机集成制造系统*, 2025, 31(6): 2178–2193.
WANG Tichun, XIA Tian, FEI Yeqi. Gear fault diagnosis method integrating convolutional deep belief network and extensible neural network[J]. *Computer integrated manufacturing systems*, 2025, 31(6): 2178–2193.
- [33] 陈鑫. 可拓神经网络及其在汽车智能驾驶路径规划中的应用[D]. 广州: 广东工业大学, 2024.
CHEN Xin. Extension neural network and its applications in path planning method for smart driving cars[D]. Guangzhou: Guangdong University of Technology, 2024.
- [34] 夏崇坤, 苏成利, 曹江涛, 等. 基于 MDP-ISAP 的 ENN 分类算法及其应用[J]. *控制工程*, 2017, 24(9): 1958–1964.
XIA Chongkun, SU Chengli, CAO Jiangtao, et al. MDP-ISAP with ENN-based classification algorithm and its application[J]. *Control engineering of China*, 2017, 24(9): 1958–1964.
- [35] JACOBS R A, JORDAN M I, NOWLAN S J, et al. Adaptive mixtures of local experts[J]. *Neural computation*, 1991, 3(1): 79–87.
- [36] MOLINARO D D, KANG I, YOUNG A J. Estimating human joint moments unifies exoskeleton control, reducing user effort[J]. *Science robotics*, 2024, 9(88): eadi8852.
- [37] 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.

作者简介:



余昊阳, 硕士研究生, 主要研究方向为可拓智能、深度学习。E-mail: yuhaoyang7@qq.com。



李兴森, 教授, 可拓学与创新方法研究所所长, 中国人工智能学会理事。主要研究方向为可拓学与人工智能, 获得国家发明专利授权 3 项, 发表学术论文 80 篇, 出版专著 3 部。E-mail: lixingsen@126.com。



颜伊庆, 副教授, 博士, 主要研究方向为可拓智能、数据库系统。E-mail: yanlolo2012@gmail.com。