

# 控制与决策

Control and Decision

## 基于多模态数据融合的康复机器人关节角度预测方法

陈博, 王斌, 周袁, 周京, 王浙明, 叶祥明

引用本文:

陈博, 王斌, 周袁, 等. 基于多模态数据融合的康复机器人关节角度预测方法[J]. *控制与决策*, 2026, 41(3): 604-612.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2025.0504>

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### [基于图卷积网络的行为识别方法综述](#)

A survey of action recognition methods based on graph convolutional network

*控制与决策*. 2021, 36(7): 1537-1546 <https://doi.org/10.13195/j.kzyjc.2020.0514>

#### [移动机器人运动规划中的深度强化学习方法](#)

Deep reinforcement learning for motion planning of mobile robots

*控制与决策*. 2021, 36(6): 1281-1292 <https://doi.org/10.13195/j.kzyjc.2020.0470>

#### [基于 \$\pm 3\sigma\$ 正态概率区间分族遗传蚁群算法的移动机器人路径规划](#)

Path planning of mobile robot based on  $\pm 3\sigma$  normal probability interval population division using genetic ant-colony algorithm

*控制与决策*. 2021, 36(12): 2861-2870 <https://doi.org/10.13195/j.kzyjc.2020.0745>

#### [基于深度学习的行人轨迹预测方法综述](#)

Survey of pedestrian trajectory prediction methods based on deep learning

*控制与决策*. 2021, 36(12): 2841-2850 <https://doi.org/10.13195/j.kzyjc.2020.1841>

#### [基于生物启发神经网络和DMPC的多机器人协同搜索算法](#)

Multi-robot cooperative search algorithm based on bio-inspired neural network and DMPC

*控制与决策*. 2021, 36(11): 2699-2706 <https://doi.org/10.13195/j.kzyjc.2020.0959>

# 基于多模态数据融合的康复机器人关节角度预测方法

陈博<sup>1</sup>, 王斌<sup>1</sup>, 周袁<sup>1</sup>, 周京<sup>1†</sup>, 王浙明<sup>1</sup>, 叶祥明<sup>2</sup>

(1. 浙江工业大学信息工程学院, 杭州 310000; 2. 浙江省人民医院康复科, 杭州 310000)

**摘要:** 在人体关节角度预测中, 单传感器获取信息太过局限且易受环境干扰影响, 而基于多传感器的关节角度的预测研究, 由于输入数据维度升高、传统的融合方式存在特征利用率不足的缺陷, 导致预测精度下降. 为准确获取运动功能障碍患者佩戴外骨骼康复过程中的运动状态, 提出基于多模态数据融合的康复机器人关节角度预测方法. 首先, 设计多通道高分辨率网络结构使其适用于人体 3 维姿态特征提取任务, 同时利用卷积神经网络提取足底压力特征; 其次, 基于长短期记忆网络获取特征在时域上的关联性; 然后, 构建带注意力机制的多模态特征融合网络用于人体关节角度预测; 最后, 通过在低、中、高 3 组速度下的实验结果表明: 所提出算法在自建数据集上的评价指标 RMSE 为 0.039, 较传统关节角度预测方法提升 38% 以上; 评价指标  $R^2$  为 0.948, 较传统关节角度预测方法提升 17% 以上.

**关键词:** 康复机器人; 关节角度预测; 人体姿态估计; 多通道高分辨率网络; 长短期记忆网络; 多模态特征融合网络

中图分类号: TP18 文献标志码: A

DOI: 10.13195/j.kzyjc.2025.0504

引用格式: 陈博, 王斌, 周袁, 等. 基于多模态数据融合的康复机器人关节角度预测方法 [J]. 控制与决策, 2026, 41(3): 604-612.

## Prediction of rehabilitation robot's joint angle based on multi-modal data fusion method

CHEN Bo<sup>1</sup>, WANG Bin<sup>1</sup>, ZHOU Yuan<sup>1</sup>, ZHOU Jing<sup>1†</sup>, WANG Zhe-ming<sup>1</sup>, YE Xiang-ming<sup>2</sup>

(1. College of Information Engineering, Zhejiang University of Technology, Hangzhou 310000, China;  
2. Department of Rehabilitation, Zhejiang Provincial People's Hospital, Hangzhou 310000, China)

**Abstract:** In human joint angle prediction, the information acquired from a single sensor is extremely limited and highly prone to environmental disturbances. Meanwhile, in the existing joint angle prediction studies based on multi-sensors, the increase in the dimensionality of input data leads to a defect of insufficient feature utilization in traditional fusion methods, which will result in a decline in prediction accuracy. Aiming at accurately obtaining the motion state of lower-limb rehabilitation exoskeleton robots, we have proposed a multi-modal data fusion method to predict the rehabilitation robot joint angle. The algorithm adopts a multi channel fusion high-resolution network structure designed specifically to handle the human 3D pose feature extraction tasks and convolutional neural networks to extract plantar pressure features. Then, based on long short-term memory networks, the temporal correlations of features are obtained. Moreover, in order to accurately predict the joint angles of patients, a fusion network based on the attention mechanism is proposed. The results show that, under three groups of speeds, the root mean square error of the proposed algorithm is 0.039, representing an improvement of more than 38% compared with the single-modal joint angle prediction method; the coefficient of determination is 0.948, representing an improvement of more than 17% compared with the single-modal joint angle prediction method.

**Keywords:** rehabilitation robot; joint angle prediction; human pose estimation; multi channel fusion high-resolution network; long short-term memory networks; multi-modal feature fusion network

## 0 引言

由神经系统疾病引发的运动功能障碍人群康复

问题是目前全世界所有国家共同面临的严峻挑战.

截止 2019 年, 我国仅脑卒中引起的运动功能障碍人

收稿日期: 2025-05-15; 录用日期: 2025-10-31.

基金项目: 浙江省重点研发计划项目 (2024C03040).

责任编辑: 王琦.

<sup>†</sup>通信作者. E-mail: jzhou@zjut.edu.cn.

数就高达1200万<sup>[1]</sup>。这类疾病常引起人体下肢运动能力损伤,且会对患者日常行为造成严重影响<sup>[2]</sup>。临床研究表明,准确、及时的康复训练能促使神经系统功能恢复,改善身体运动能力<sup>[3]</sup>。而传统一对一或多对一的康复模式,无法满足巨大的康复需求。因此,引入新的康复医疗设备用于辅助运动功能障碍人群进行康复训练有着重要的实际意义<sup>[4]</sup>。

下肢外骨骼机器人作为一种新型康复设备,可为运动功能障碍人群提供助力,帮助患者受损肌群恢复<sup>[5]</sup>。与传统治疗方式相比,外骨骼机器人能够根据患者身体状况提供对应训练模式,为康复医师提供极大的帮助<sup>[6]</sup>。关节角度预测是下肢外骨骼机器人控制的关键一环,能够辅助异常步态检测、康复效果评估等方面的研究,其目的是根据各类传感器信号预测人体佩戴外骨骼运动过程中关节角度变化轨迹。

现阶段,大多围绕生理信号与物理信号开展关节角度预测研究。Ardi等<sup>[7]</sup>提出基于傅里叶与小波分析的关节角度预测方法,利用傅里叶分析与小波分析提取脑电特征,通过多层感知机神经网络实现了人体步态的分类。Zhang等<sup>[8]</sup>将神经网络模型应用到康复医疗领域,其基于肌电信号提出由健侧肢体控制患侧肢体的协同控制策略,实现了运动功能障碍患者腿部关节角度的有效估计。Duan等<sup>[9]</sup>基于惯性传感器信号(IMU)提出小波自回归滑动平均模型,解决了IMU信号位置偏移引起的漂移误差现象。较传统机器学习方法,长短期记忆网络处理时序数据具有天然的优势。Hollinger等<sup>[10]</sup>验证了与随机森林等传统机器学习模型相比,应用长短期记忆网络后,关节角度预测精度有了明显改善。而Tan等<sup>[11]</sup>的研究则验证了长短期记忆网络在平地、楼梯等多场景中预测关节角度的可行性。为缓解控制器系统延迟现象,Su等<sup>[12]</sup>设计了基于平均权重因子的损失函数。Yang等<sup>[13]</sup>利用卷积自动编码器提取足底压力数据中的隐藏时空特征,基于长短期记忆网络学习足底压力特征与关节轨迹间的非线性关系,有效提升了轨迹预测精度。为减少特征维度升高对模型复杂度与预测精度的影响,Ren等<sup>[14]</sup>基于足底压力信号提出一种基于注意力机制的轨迹预测模型,通过编码器获取不同维度特征,利用多通道注意力机制层对变分模态分解后的数据进行解码,提升特征利用率,并缓解了传感器延迟现象。

在关节角度预测任务中,单一传感器信号易受环境噪声影响,基于多传感器信号往往能显著提升预测精度<sup>[15]</sup>。Bijalwan等<sup>[16]</sup>提出一种轻量化的关节轨迹预测方法,借助Microsoft Kinect v2传感器获取

人体3维姿态,结合IMU信号,通过逆运动学求解方式获取人体腿部关节角度运动轨迹。Sharma等<sup>[17]</sup>提出了基于惯性传感器信号与视觉信号融合的神经网络架构,通过光流法提取图像中光流特征,利用长短期记忆网络获取其时域特征,并基于多层感知机的融合网络实现光流特征与运动学特征的融合。

传统关节角度预测方法已经能够实现关节角度的预测,但仍存在以下问题亟需解决:1)传统关节角度预测方法多基于生理信号或物理信号开展,其获取信息过于局限且易受环境干扰影响,导致预测精度不高;2)传统人体3维姿态获取任务中,多采用HRNet等姿态提取网络获取人体2维姿态信息,通过点云转换得到3维姿态特征,图像中异常点在转换过程中会导致较大的误差而引起关节角度预测性能下降;3)基于多传感器的关节角度预测研究中,融合网络多为加权方式或多层感知机,而在多传感器人体关节角度预测任务中,随着传感器数目增加,输入网络特征维度升高,该类方法往往特征利用率不佳。

为充分利用人体运动过程中多模态数据,本文选取HRNet作为骨干网络,其具有多个并行多分辨率子网,可以实现多尺度信息的融合<sup>[18]</sup>。与传统方法采用低分辨率特征上采样获取高分辨率特征的方式相比<sup>[19]</sup>,HRNet在整个检测过程中始终保持高分辨率特征通道,丰富了提取特征的细节信息。这种机制使HRNet在许多对图像精度要求高的场景中都表现出色,在语义分割、人体姿态估计等领域都有广泛应用。关节角度预测任务依赖于精准的人体空间位置信息,相较Sadeghzadehyazdi等<sup>[20]</sup>通过卷积神经网络捕获人体视觉特征方法相比,HRNet利用RGB图像预测人体姿态信息,能有效提升模型性能。

综上所述,本文旨在集合RGB-D图像和足底压力信息互补优势,研究基于多模态特征融合的关节角度预测方法。主要优化以及改进表现在以下3个方面:1)设计多通道高分辨率网络以便提取人体运动过程中3维姿态特征,利用深度图像改善传统基于RGB图像的HRNet模型易受图像中异常点干扰问题;2)针对提取的多模态特征,设计基于注意力机制的融合模块实现多模态特征的选择与融合,可自适应调整多模态特征的权重分配,增强模型的鲁棒性和泛化能力,降低模型计算能力与复杂性;3)基于上述方法,搭建下肢康复外骨骼机器人平台,实现多模态数据采集、关节角度预测等功能,同时在低、中、高3组速度下对算法有效性进行验证。

### 1 基于多模态数据融合关节角度预测

图1展示了本文提出的双通道时空特征提取与自注意力机制网络 (DTSSANet). 其中:  $x_i^{RGB}$  表示

RGB 图像;  $x_i^{Depth}$  表示深度图像;  $x_i^{planter}$  表示足底压力数据;  $Q_i$  表示健康志愿者运动过程中的关节角度数据,  $Q_i$  包含髌关节角度  $q_i^h$  与膝关节角度  $q_i^k$ .

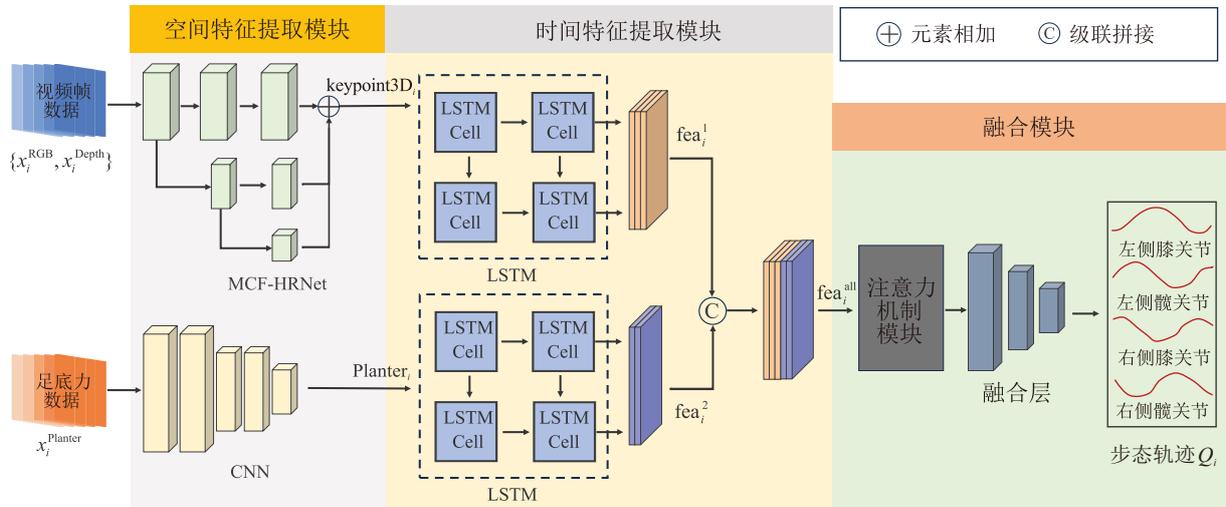


图1 双通道时空特征提取与自注意力机制网络

DTSSANet 网络包含 3 部分: 用于提取空间特征的多通道高分辨率网络 (MCF-HRNet) 与卷积神经网络 (CNN); 用于提取时间特征的长短期记忆网络 (LSTM); 用于多模态特征融合的带注意力机制的融合网络. MCF-HRNet 是本文为改善传统基于 RGB 图像的 HRNet 网络易受异常点干扰而导致轨迹预测精度不佳问题构建的网络模型.  $x_i^{RGB}$ 、 $x_i^{Depth}$  经 MCF-HRNet 网络得到人体 3 维姿态  $keypoint3D_i$ ,  $x_i^{planter}$  经 CNN 网络获取足底压力信号中的高维特征  $Planter_i$ . 在空间特征提取模块之后添加 LSTM 单元以捕获特征点间的时域信息  $fea_i^1$ 、 $fea_i^2$ . 将各分支时域特征级联拼接后的特征  $fea_i^{all}$  输入带注意力机制的融合网络, 预测得到人体关节运动轨迹  $Q_i$ , 与传统加权或多层感知机的融合方式相比, 能够显著提升特征利用率、改善预测精度.

#### 1.1 空间特征提取

图2是本文为有效获取人体 3 维姿态特征而设

计的网络模型 MCF-HRNet, 与传统 HRNet 网络相比, 通过搭建双通道的分支结构, 将深度图像与 RGB 图像分别经 Transition 模块与 Stage 模块处理后进行融合, 能有效捕获人体运动过程中各关节的 3 维空间关系, 其依托的骨干网络为 HRNet.

MCF-HRNet 网络的输入是宽度为 4 416、长度为 1 242 的 RGB 图像与深度图像, 其工作方式如下: RGB 图像与深度图像经 Stage 模块与 Transition 模块后输出人体 2 维姿态信息. 在 Transition 模块中, 采用卷积核大小为 3、步距为 2 的卷积操作向下两倍采样, 得到低分辨率子网络. 而在 Stage 模块中, 通过卷积核大小为 1 的卷积操作后, 通过归一化层, 上采样相应倍数, 使之与其他子网络分辨率一致, 进而将各分辨率子网络中信息进行融合<sup>[18]</sup>. Transition 模块与 Stage 模块如图 3 所示.

RGB 图像与深度图像经 Transition 模块与 Stage 模块后获取对应 2 维姿态信息, 通过下述公式对信

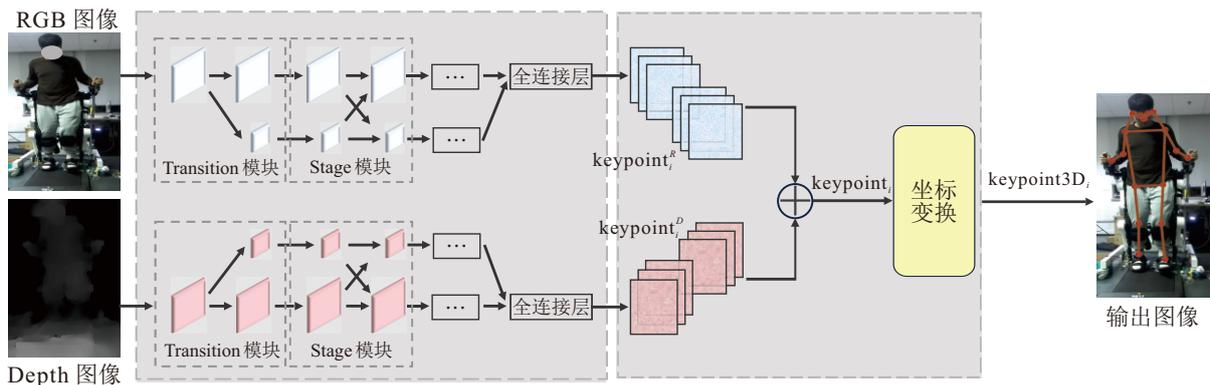


图2 多通道高分辨率网络

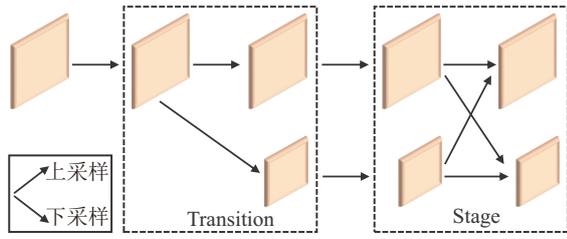


图3 Transition 模块与 Stage 模块定义

息融合后得到最终的人体 2 维姿态

$$\text{keypoint}_i = \omega_i^R \text{keypoint}_i^R + \omega_i^D \text{keypoint}_i^D. \quad (1)$$

其中:  $\text{keypoint}_i^R$  为由 RGB 图像预测得到的第  $i$  个关键点处坐标,  $\text{keypoint}_i^D$  为由深度图像预测得到的第  $i$  个关键点处坐标,  $\omega_i^R$  与  $\omega_i^D$  为可学习权重参数。

$\text{keypoint}_i$  与 3 维点云中的信息进行匹配, 获取对应位置  $i$  处包含  $X$ 、 $Y$ 、 $Z$  方向上的 3 维姿态坐标  $\text{keypoint}3D_i$ 。根据人体解剖学定义, 构建人体空间坐标系, 有关人体关键点以及坐标轴相关定义见图 4。

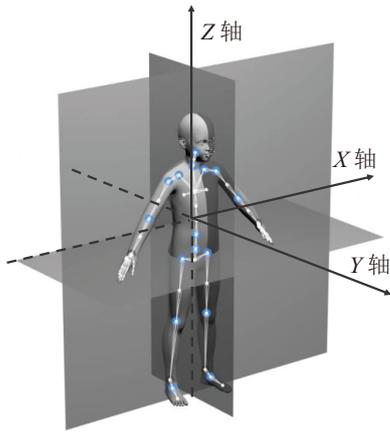


图4 人体空间坐标系定义

基于下肢康复外骨骼机器人平台采集到的 36 维足底压力信号通过 CNN 得到 2 维网格足底压力数据中的高维特征, 减少了人为筛选特征造成的主观性影响<sup>[21]</sup>。足底压力传感器以鞋垫的方式布置在外骨骼机器人左右两侧脚底处, 人体佩戴外骨骼机器人后能够保证与足底压力传感器充分接触, 实际放置位置见图 5。



图5 足底压力传感器分布

CNN 具体结构如下: 2 层卷积层, 2 层批量归一

化层, 2 层激活层和 1 层池化层。第 1 层卷积层的卷积核大小设置为 5, 步长为 2, 填充为 2, 扩张系数为 1。第 2 层卷积层的卷积核大小设置为 3, 步长为 1, 填充为 1, 扩张系数为 1。池化层选择最大值池化, 核大小为 2, 步长为 2。激活函数均为 ReLu 函数。

## 1.2 时域特征提取

通过空间特征提取网络后的特征在时序上存在关联性, 包含单个步态周期内的动作关联性, 以及不同步态周期之间的运动状态变化, 而 LSTM 独特的结构和信息传递方式使其可以捕捉上述时序依赖关系。

LSTM 工作过程<sup>[22]</sup>如下:

$$f_t = \sigma(W_f X_t + W_{hf} h_{t-1} + b_f), \quad (2)$$

$$i_t = \sigma(W_i X_t + W_{hi} h_{t-1} + b_i), \quad (3)$$

$$o_t = \sigma(W_o X_t + W_{ho} h_{t-1} + b_o), \quad (4)$$

$$c_t = c_{t-1} \otimes f_t + g_t, \quad (5)$$

$$g_t = i_t \otimes (\tanh(W_c X_t + W_{hc} h_{t-1} + b_c)), \quad (6)$$

$$h_t = o_t \otimes \tanh(c_{t-1}). \quad (7)$$

其中:  $W_i$ 、 $W_o$ 、 $W_f$ 、 $W_{hi}$ 、 $W_{ho}$ 、 $W_{hf}$ 、 $W_{fc}$  分别表示与输入门、输出门、遗忘门、记忆单元相连的权重变量,  $b_i$ 、 $b_o$ 、 $b_f$ 、 $b_c$  表示偏置变量,  $\otimes$  表示哈达玛积乘积 (Hadamard)。

LSTM 层结构如下: 足底压力特征、视觉特征均使用一个 3 层的 LSTM 网络用于其时间特征提取。其中, 第 1 层 LSTM 层神经元个数为 16, 第 2 层 LSTM 层神经元个数为 32, 第 3 层 LSTM 层神经元个数为 64, 各 LSTM 层神经元随机失活率均取 0.5, 全连接层神经元个数为 8, 输入窗口大小选择为 10。

## 1.3 多模态特征融合网络

足底压力数据与图像数据经时空特征提取后得到的特征维度高达 71 维, 而单一多层感知机融合网络在处理特征维度较高的复杂场景时, 对特征有效捕捉方面存在一定局限性。为弥补上述缺陷, 本文引入带注意力机制的融合网络, 通过点注意力机制层对上层网络得到的特征进行筛选, 实现不同尺度特征间的融合, 利用多层感知机实现特征融合, 从而得到步态轨迹。

自注意力机制计算过程<sup>[23]</sup>如下:

$$Q = XW^Q, \quad (8)$$

$$K = XW^K, \quad (9)$$

$$V = XW^V, \quad (10)$$

$$S(Q, K) = \frac{QK^T}{\sqrt{d}}, \quad (11)$$

$$\text{Attention} = \text{softmax}(S(Q, K))V. \quad (12)$$

其中:  $Q$ 、 $K$ 、 $V$ 分别为自注意力层的输入,  $W^Q$ 、 $W^K$ 、 $W^V$ 分别为预测特征的权重矩阵,  $d$ 为 $Q$ 、 $K$ 、 $V$ 的维数.

注意力机制中查询、键和值的向量维度均取 64. 多层感知机一共包含 4 层隐藏层, 第 1 层隐藏层神经元个数为 32, 第 2 层隐藏层神经元个数为 16, 第 3 层隐藏层神经元个数为 8, 第 4 层隐藏层神经元个

数为 4, 激活函数均为 ReLu 函数.

## 2 实验与分析

### 2.1 实验平台

图 6 为本文基于 Matlab/Simulink 环境搭建的数据感知平台. 数据感知平台包括各类传感器信号接收模块、控制器模块以及控制指令发送模块. 其中: 传感器信号接收模块负责实时采集足底压力信号、编码器位置信号、编码器速度信号, 控制器模块负责产生控制指令, 控制指令发送模块负责将控制指令发送给控制器.

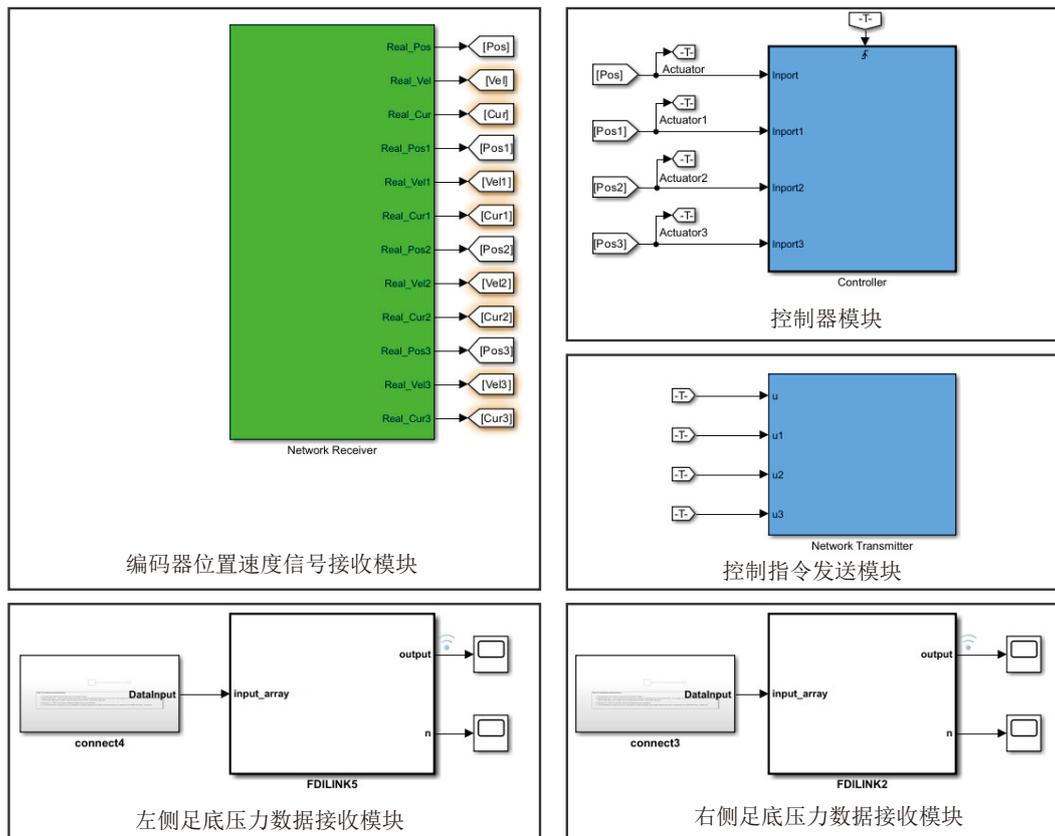


图6 数据感知平台

图 7 为本文搭建的下肢康复外骨骼机器人硬件平台. 该平台由服务器、PC 端、树莓派、多类传感器以及各类通讯接口组成. PC 端在 Matlab/Simulink 环境下实现控制信号的生成与数据采集, 服务器通过训练关节角度预测算法完成上层决策任务, 多类传感器实时采集人体佩戴下肢康复外骨骼机器人康复训练过程中产生的多模态数据. 各类通讯接口用于各模块间数据传输, PC 端与树莓派间通过 UDP 协议通信, 树莓派与伺服驱动系统间通过 CAN 总线模块进行通信. PC 端配置英特尔酷睿 i9-12900H 处理器和 GeForce RTX 4060 显卡, 其性能可满足控制算法与数据采集功能的实现. 服务器配有英特尔酷睿 i7-11700 处理器和 2 块 16 G 显存的 GeForce RTX 3090

显卡, 其性能可满足机器学习算法的训练与预测.

通过所搭建的基于足底压力、视觉的下肢康复外骨骼机器人平台对 15 名志愿者进行数据采集, 所有志愿者均为成年男性, 年龄在 22 ~ 30 之间, 无行走障碍, 且多次实验过程中保证了环境因素的一致性.

### 2.2 实验设计

在基于搭建的下肢康复外骨骼机器人平台所构建的 15 名健康志愿者下肢运动数据集上, 验证所提出关节角度预测方法的有效性, 实验步骤如下:

1) 采集 15 名年龄、身高、体重上存在差异性的健康志愿者步态数据作为实验样本, 步态数据包括志愿者 RGB 图像、深度图像、足底压力信号以及左侧髋关节角度、右侧髋关节角度、左侧膝关节角度、

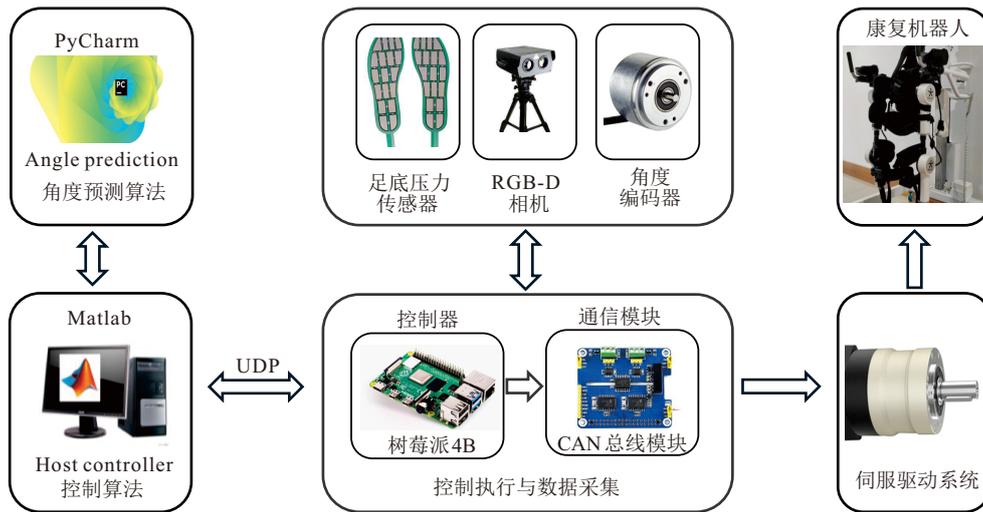


图7 下肢康复外骨骼机器人硬件平台

右侧膝关节角度。

2) 通过康复跑台设置不同的行走速度模拟康复患者不同康复阶段的康复训练,行走速度设置为低、中、高3组速度,低速情况下速度为0.5 km/h,中速情况下速度为1.0 km/h,高速情况下速度为1.5 km/h.在每组速度下,每名志愿者佩戴下肢康复外骨骼机器人均行走120 s.

3) 搭建双通道时空特征提取与自注意力机制网络,将处理后数据集按比例4:1分为训练集与测试集,完成网络设计以及超参数训练.选择基于LSTM的关节角度预测模型<sup>[12]</sup>以及基于CNN-LSTM的关节角度预测模型<sup>[13]</sup>作为基准模型,验证算法的有效性.

4) 对实验结果进行分析,计算各方法在低、中、高速下的预测误差,同时分析误差产生原因.上述实验过程保证不受电磁干扰、设备故障等因素影响.

图8展示了其中一名志愿者佩戴外骨骼机器人进行数据采集的过程,RGB-D相机位于志愿者前方1.5 m处用于采集训练过程中RGB图像、深度图像.足底压力传感器通过鞋垫的方式布置在志愿者脚底,角度编码器内置于电机中,通过数据感知平台实时

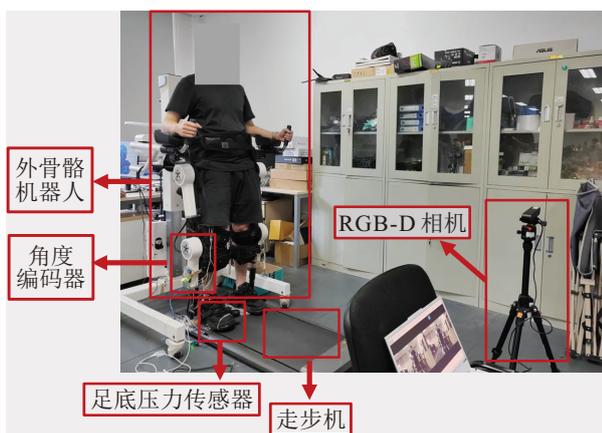


图8 数据采集过程

对上述信号进行采集.RGB-D相机采集图像的分辨率为2 K,其深度量程为0.3 ~ 20 m,足底压力传感器精度达0.1 N/cm<sup>2</sup>,角度编码器能够检测的最小角度增量可达0.000057°.

### 2.3 特征提取结果分析

MCF-HRNet网络所提取的图像特征见图9.特征中包含了人体行走过程中关键点3维姿态信息,与传统方法相比所含特征信息量更丰富、物理意义更强.志愿者下肢各个关节的运动相较上肢而言变化更大,而膝关节与踝关节的运动在整个下肢的运动中变化尤为明显.

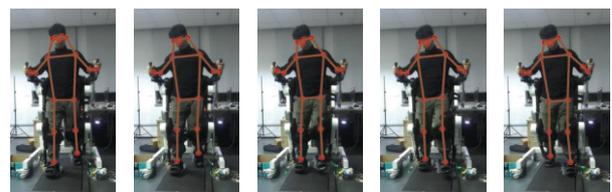


图9 人体姿态特征

预测得到的左侧膝关节关键点在X轴和Y轴方向上的变化曲线如图10和图11所示.关键点在X轴与Y轴方向运动偏移较小,且关键点的运动无明显规律.

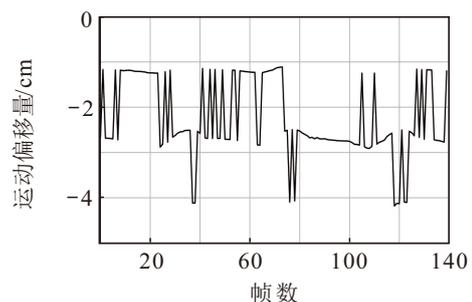


图10 X轴方向人体姿态特征

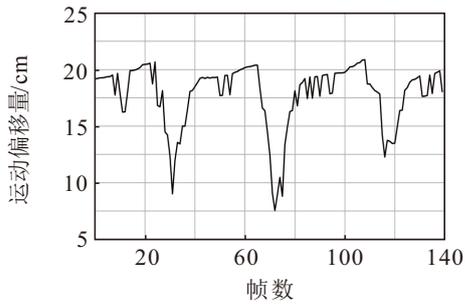


图11 Y轴方向人体姿态特征

图12展示了左侧膝关节关键点在Z轴方向变化曲线.与关键点在X轴和Y轴方向的运动相比,关键点Z轴方向上的运动范围更大,呈现出明显周期变化规律,与实际训练过程中的步态规律相符.通过分析关键点姿态特征在各个方向的变化规律可知,所提出的MCF-HRNet网络获取特征中空间信息更丰富,对人体步态运动的理解更准确.

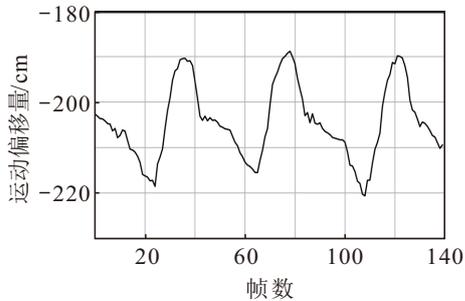


图12 Z轴方向人体姿态特征

## 2.4 消融实验结果与分析

为验证本文所提出关节角度预测网络的有效性,选取均方根误差(RMSE)和决定系数( $R^2$ )作为衡量关节角度预测效果的指标对模型精度进行评估.评价指标RMSE的值越小表示模型预测效果越好,而评价指标 $R^2$ 的值越大表示模型预测效果越好<sup>[24]</sup>.

RMSE和 $R^2$ 的计算公式如下:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - z_i)^2}, \quad (13)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - z_i)^2}{\sum_{i=1}^N (\mu_i - z_i)^2}. \quad (14)$$

其中: $N$ 为样本数量, $y_i$ 为第*i*个时刻通过关节角度预测网络输出得到的预测值, $z_i$ 为第*i*个时刻通过编码器测量得到的真实数据, $\mu_i$ 为通过编码器测量得到真实数据的平均值.

为了进一步分析本文所提出的MCF-HRNet与融合模块对关节角度预测效果的影响,分别将各个

模块去除进行消融实验.实验中Model 1表示使用HRNet网络对视频帧数据进行特征提取;Model 2表示使用MCF-HRNet对视频帧数据进行特征提取.Model 1与Model 2均采用多层感知机网络实现特征间的融合,其余模块设计与图1中DTSSANet网络保持一致.表1展示了Model 1、Model 2与DTSSANet网络在低、中、高3组速度下的评价指标RMSE与 $R^2$ .

表1 消融实验结果对比 单位: km/h

方法	speed = 0.5		speed = 1.0		speed = 1.5	
	RMSE	$R^2$	RMSE	$R^2$	RMSE	$R^2$
Model 1	0.063	0.817	0.036	0.911	0.057	0.897
Model 2	0.039	0.897	0.033	0.943	0.048	0.963
本文方法	0.042	0.901	0.023	0.983	0.052	0.961

由实验结果可知,本文所提出的MCF-HRNet与融合模块均能提升关节角度预测精度,且两种模块组合可以取得更好的关节角度预测效果,验证了各个模块的有效性和互补性.Model 2与Model 1相比,所设计的MCF-HRNet利用深度信息改善了HRNet预测效果,相较仅利用RGB图像进行人体2维姿态信息提取的HRNet网络,评价指标RMSE与 $R^2$ 分别提升了23.1%与6.7%.DTSSANet网络与Model 2之间比较,所设计的融合模块相较传统利用多层感知机网络进行融合的方法,评价指标RMSE与 $R^2$ 分别提升了2.5%与1.5%.

## 2.5 对比实验结果与分析

在低、中、高3组速度下各算法指标对比结果如表2所示.计算3组速度下的平均RMSE与 $R^2$ ,所提出方法在自建数据集上测试的RMSE为0.039,较基于LSTM的轨迹预测模型和基于CNN-LSTM的轨迹预测模型分别提升45.1%和38.1%;测试的 $R^2$ 为0.948,较基于LSTM的轨迹预测模型和CNN-LSTM的轨迹预测模型分别提升22%和17.3%.与传统单模态轨迹预测方法相比,所提出方法体现出更强的预测能力和更高的拟合精度,表明该方法能适应不同康复阶段下的步态轨迹预测.

表2 本文模型与经典模型效果对比 单位: km/h

方法	speed = 0.5		speed = 1.0		speed = 1.5	
	RMSE	$R^2$	RMSE	$R^2$	RMSE	$R^2$
LSTM模型 <sup>[21]</sup>	0.086	0.612	0.047	0.847	0.078	0.871
CNN-LSTM模型 <sup>[23]</sup>	0.073	0.732	0.041	0.835	0.075	0.857
本文方法	0.042	0.901	0.023	0.983	0.052	0.961

随机选取一名志愿者的数据用于展示所提出方法、基于LSTM的关节角度预测模型与基于CNN-LSTM的关节角度预测模型在1.0 km/h速度下的关节角度预测效果,步态轨迹对比如图13所示.基于

LSTM 模型与基于 CNN-LSTM 模型在峰值处预测效果较差, 而所提出方法在各个关节的轨迹预测中

均能较好地逼近轨迹真实值, 在整条曲线上始终保持较高的准确性。

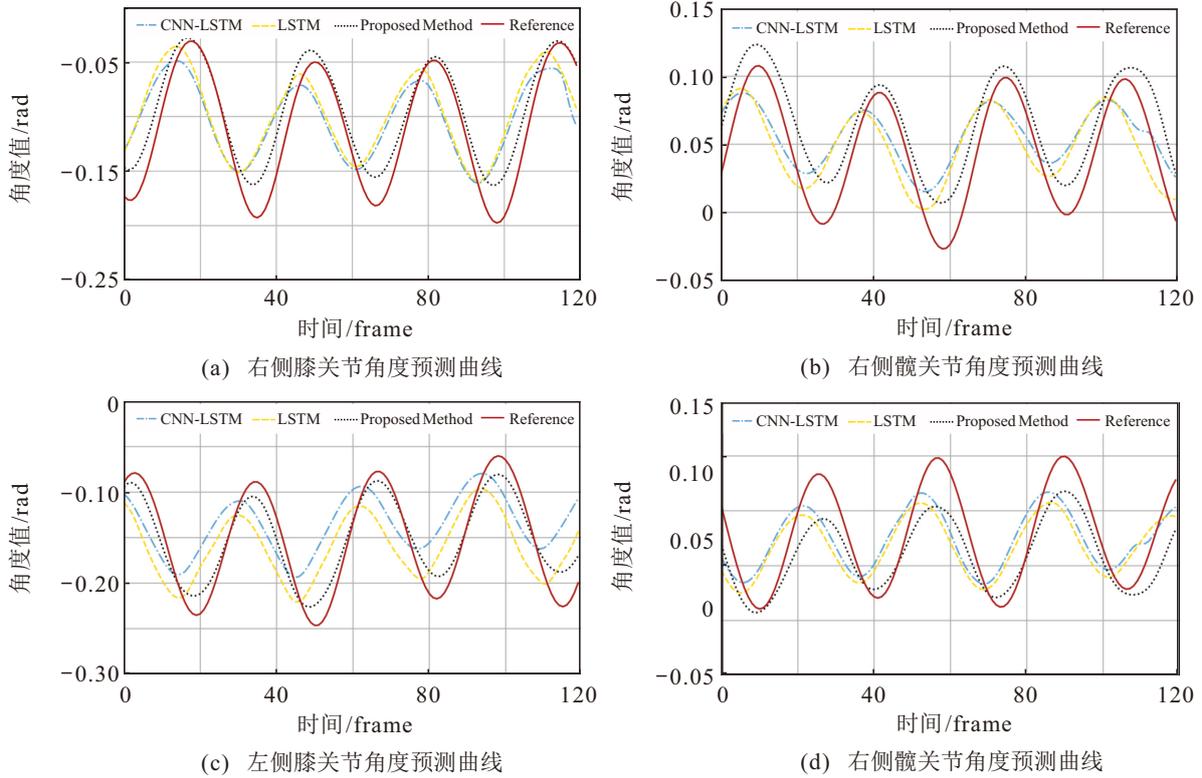


图13 多种轨迹步态算法结果对比

### 3 结论

本文为提升运动功能障碍患者穿戴外骨骼康复训练过程中关节角度预测的准确性开展了研究, 提出双通道时空特征提取与自注意力机制网络. 针对足底压力数据、视觉数据各自的特性, 分别设计了特征提取网络, 并利用长短期记忆网络捕获其时域特征, 最终基于注意力机制的融合网络实现人体关节角度的精准预测. 基于搭建的下肢康复外骨骼机器人平台, 构建包含 15 名健康志愿者的下肢运动数据集. 在低、中、高 3 组速度下对算法有效性进行验证, 实验结果表明: 所提出算法在自建数据集上测试的评价指标 RMSE 为 0.039, 较传统轨迹预测方法提升 38% 以上; 评价指标  $R^2$  为 0.948, 较传统轨迹预测方法提升 17% 以上. 实验中志愿者均为无步行障碍的成年人, 下一步研究工作将进一步提升人体佩戴下肢康复外骨骼训练过程的安全性, 设计临床实验, 并邀请从事康复方向的医生进行相关实验的安全性评估, 最终为患有运动功能障碍患者提供康复帮助.

#### 参考文献 (References)

[1] 王陇德, 刘建民, 杨弋, 等. 我国脑卒中防治仍面临巨大挑战 —— 《中国脑卒中防治报告 2018》概要[J]. 中国循环杂志, 2019, 34(2): 105-119. (Wang L D, Liu J M, Yang Y, et al. The prevention and

treatment of stroke still face huge challenges — Brief report on stroke prevention and treatment in china, 2018[J]. Chinese Circulation Journal, 2019, 34(2): 105-119.)

[2] Xiang X N, Ding M F, Zong H Y, et al. The safety and feasibility of a new rehabilitation robotic exoskeleton for assisting individuals with lower extremity motor complete lesions following spinal cord injury (SCI): An observational study[J]. Spinal Cord, 2020, 58(7): 787-794.

[3] 池奎龙, 温静, 张霞, 等. 电针治疗脑卒中后遗症文献的可视化数据挖掘与分析[J]. 针刺研究, 2023, 48(5): 508-514. (Chi K L, Wen J, Zhang X, et al. Network visual data mining and analysis of literature on electroacupuncture treatment of post-stroke sequelae[J]. Acupuncture Research, 2023, 48(5): 508-514.)

[4] 刘前进, 李思佳, 胡晓诗, 等. 上肢康复机器人治疗对脑瘫痉挛型偏瘫患儿上肢运动功能恢复的影响[J]. 中国康复, 2024, 39(5): 269-273. (Liu Q J, Li S J, Hu X S, et al. Effects of upper limb rehabilitation intelligent robot on upper limb motor function in children with cerebral palsy spastic hemiplegia[J]. Chinese Journal of Rehabilitation, 2024, 39(5): 269-273.)

[5] Zhang S S, 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.
- [6] Ma Y, Wu X Y, Yang S X, et al. Online gait planning of lower-limb exoskeleton robot for paraplegic rehabilitation considering weight transfer process[J]. *IEEE Transactions on Automation Science and Engineering*, 2021, 18(2): 414-425.
- [7] Ardi Handojoseno A M, Shine J M, Nguyen T N, et al. Analysis and prediction of the freezing of gait using EEG brain dynamics[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2015, 23(5): 887-896.
- [8] Zhang F, Li P F, Hou Z G, et al. sEMG-based continuous estimation of joint angles of human legs by using BP neural network[J]. *Neurocomputing*, 2012, 78(1): 139-148.
- [9] Duan M R, Hu Q, Zang T, et al. Wavelet-ARMA-based short-term drift calibration of IMU position on human lower limbs[J]. *IEEE Sensors Journal*, 2023, 23(14): 15773-15785.
- [10] Hollinger D, Schall M, Chen H, et al. The influence of gait phase on predicting lower-limb joint angles[J]. *IEEE Transactions on Medical Robotics and Bionics*, 2023, 5(2): 343-352.
- [11] Tan J S, Tippaya S, Binnie T, et al. Predicting knee joint kinematics from wearable sensor data in people with knee osteoarthritis and clinical considerations for future machine learning models[J]. *Sensors*, 2022, 22(2): 446.
- [12] Su B B, Gutierrez-Farewik E M. Gait trajectory and gait phase prediction based on an LSTM network[J]. *Sensors*, 2020, 20(24): 7127.
- [13] Yang J T, Yin Y H. Novel soft smart shoes for motion intent learning of lower limbs using LSTM with a convolutional autoencoder[J]. *IEEE Sensors Journal*, 2021, 21(2): 1906-1917.
- [14] Ren J L, Wang A H, Li H Y, et al. A transformer-based neural network for gait prediction in lower limb exoskeleton robots using plantar force[J]. *Sensors*, 2023, 23(14): 6547.
- [15] Katmah R, Al Shehhi A, Jelinek H F, et al. A systematic review of gait analysis in the context of multimodal sensing fusion and AI[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2023, 31: 4189-4202.
- [16] Bijalwan V, Semwal V B, Mandal T K. Fusion of multi-sensor-based biomechanical gait analysis using vision and wearable sensor[J]. *IEEE Sensors Journal*, 2021, 21(13): 14213-14220.
- [17] Sharma A, Rombokas E. Improving IMU-based prediction of lower limb kinematics in natural environments using egocentric optical flow[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2022, 30: 699-708.
- [18] Wang J D, Sun K, Cheng T H, et al. Deep high-resolution representation learning for visual recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 43(10): 3349-3364.
- [19] Yang X L, Ye Q Y, Cai G F, et al. PD-ResNet for classification of Parkinson's disease from gait[J]. *IEEE Journal of Translational Engineering in Health and Medicine*, 2022, 10: 1-11.
- [20] Sadeghzadehyazdi N, Batabyal T, Acton S T. Modeling spatiotemporal patterns of gait anomaly with a CNN-LSTM deep neural network[J]. *Expert Systems with Applications*, 2021, 185: 115582.
- [21] 李健伟, 曲长文, 彭书娟. 基于级联 CNN 的 SAR 图像舰船目标检测算法[J]. *控制与决策*, 2019, 34(10): 2191-2197.  
(Li J W, Qu C W, Peng S J. A ship detection method based on cascade CNN in SAR images[J]. *Control and Decision*, 2019, 34(10): 2191-2197.)
- [22] Challa S K, Kumar A, Semwal V B, et al. An optimized-LSTM and RGB-D sensor-based human gait trajectory generator for bipedal robot walking[J]. *IEEE Sensors Journal*, 2022, 22(24): 24352-24363.
- [23] 于明, 李学博, 郭迎春. 融合注意力机制的域泛化行人再识别[J]. *控制与决策*, 2022, 37(7): 1721-1728.  
(Yu M, Li X B, Guo Y C. Domain generalization person re-identification based on attention mechanism[J]. *Control and Decision*, 2022, 37(7): 1721-1728.)
- [24] 张云佐, 董旭. 基于双分支时空步态特征融合的深度学习步态识别[J]. *控制与决策*, 2024, 39(4): 1403-1408.  
(Zhang Y Z, Dong X. Deep learning gait recognition based on two branch spatiotemporal gait feature fusion[J]. *Control and Decision*, 2024, 39(4): 1403-1408.)

## 作者简介

陈博 (1984-), 男, 教授, 博士, 主要研究方向为康复机器人、信息融合理论及应用, E-mail: [bchen@zjut.edu.cn](mailto:bchen@zjut.edu.cn);

王斌 (2000-), 男, 硕士生, 主要研究方向为深度学习、步态预测, E-mail: [wbingll@163.com](mailto:wbingll@163.com);

周袁 (1998-), 男, 博士生, 主要研究方向为下肢外骨骼机器人运动规划与控制, E-mail: [111122030007@zjut.edu.cn](mailto:111122030007@zjut.edu.cn);

周京 (1993-), 男, 副研究员, 博士, 主要研究方向为多源信息融合、状态估计, E-mail: [jzhou@zjut.edu.cn](mailto:jzhou@zjut.edu.cn);

王浙明 (1989-), 男, 教授, 博士, 主要研究方向为预测控制、优化算法, E-mail: [wangzheming@zjut.edu.cn](mailto:wangzheming@zjut.edu.cn);

叶祥明 (1966-), 男, 主任医师, 主要研究方向为脊髓损伤康复、颅脑外伤康复, E-mail: [Yexmdr@126.com](mailto:Yexmdr@126.com).