

DOI: 10.13382/j.jemi.B2407613

基于 IMU 的 PSR-MPC 人机速度协调防跌倒方法*

常洪彬 谷影冬 孙平 张迪

(沈阳工业大学人工智能学院 沈阳 110870)

摘要:针对老年人使用步行训练机器人康复过程中,因步行速度与机器人指定速度不协调而引发的跌倒事故问题,本文提出了一种人机速度协调防跌倒方法,该方法由跌倒预测模型和防跌倒控制方法两部分组成。首先,由惯性传感单元(IMU)采集受试者步行姿态信号,利用长短期记忆网络(LSTM)和注意力机制构建老年人跌倒预测模型;其次,在跌倒预测的基础上,设计多元相空间重构(PSR)速度预测模型,用于防跌倒控制器的设计;最后,将受试者的速度预测结果作为目标速度,利用PSR理论和模型预测控制技术(MPC),设计步行康复训练机器人的防跌倒控制器,实现对受试者步行速度的精确跟踪,避免在康复训练过程中因人机速度不协调引发的跌倒事故。仿真对比分析和实验研究结果表明,跌倒预测模型的预测准确率可达到95.2%,且跌倒预测的前置时间可达1.82 s,人机速度协调防跌倒方法可有效防止受试者步行速度与机器人指定速度不协调而发生跌倒事故,使受试者安全地完成步行康复训练。

关键词: 步行康复训练机器人; 人机速度协调; 防跌倒控制; 跌倒预测; 速度预测

中图分类号: TP242; TN06 **文献标识码:** A **国家标准学科分类代码:** 510.99

PSR-MPC human-robot speed coordination fall prevention method based on IMU

Chang Hongbin Gu Yingdong Sun Ping Zhang Di

(School of Artificial Intelligence, Shenyang University of Technology, Shenyang 110870, China)

Abstract: In response to the problem of falls caused by incoordination between the walking speed of the elderly and the designated speed of the walking rehabilitation training robot during rehabilitation, this paper proposes a human-robot speed coordination anti-falling method, consisting of two parts: a falling prediction model and an anti-falling control method. First, the walking posture signals of the subject are collected by an inertial measurement unit (IMU), and a falling prediction model for the elderly is constructed using long short-term memory (LSTM) network and attention mechanism. Second, based on the falling prediction, a multi-dimensional phase space reconstruction (PSR) speed prediction model is designed for the anti-falling controller. Finally, the predicted speed of the subject is used as the target speed, and the PSR theory and model predictive control (MPC) technology are used to design an anti-falling controller for the walking rehabilitation training robot, achieving precise tracking of the subject's walking speed and preventing falls caused by incoordination between the subject's walking speed and the robot's designated speed during rehabilitation training. Simulation and experimental results show that the prediction accuracy of the falling prediction model can reach 95.2%, and the lead time for falling prediction can reach 1.82 s. The human-robot speed coordination anti-falling method can effectively prevent falls caused by incoordination between the subject's walking speed and the robot's designated speed, enabling the subject to complete walking rehabilitation training safely.

Keywords: walking rehabilitation training robot; human-robot speed incoordination; anti-fall control; fall prediction; speed prediction

0 引言

下肢康复机器人广泛应用于步行功能障碍患者的康复训练过程中,能够为行走功能障碍患者提供安全、高效的步行训练平台^[1-2],常用的下肢康复训练机器人包括悬吊式的康复训练机器人^[3]、坐卧式的下肢康复机器人^[4]、外骨骼式机器人^[5-6]和智能移动步行康复训练机器人^[7-8]。在康复机器人的研究中,跟踪控制是目前研究的热点。为提高康复训练机器人的康复训练效果,研究人员已经提出了很多有效的控制方法,如改进的 PID 控制方法^[9]、自适应控制算法^[10]、滑模控制方法^[11-12]和柔顺控制方法^[13]等。但在进行康复训练的过程中,存在老年人由于环境因素或自身原因无法跟随机器人完成训练的情况。例如,老年人下肢力量不足以支撑康复机器人抵消后的剩余使用者质量,不能继续跟随机器人完成预定的训练;老年人腿部肌肉疲劳无法继续跟随机器人的目标速度;老年人步行速度与机器人目标速度不协调发生跌倒事故等,都给老年人的康复训练过程带来诸多安全隐患。然而,以往成果多研究如何提高康复机器人的轨迹跟踪精度和理疗效果,很少考虑到因人机速度不协调引发的跌倒问题。

实际上,在康复训练过程中发生的跌倒事故不仅会造成老年人身体上的二次伤害,还会造成巨大的心理压力,使康复训练更加难以进行^[14]。目前关于跌倒检测的研究,已产生很多优秀的成果^[15-16]。相较于跌倒检测,跌倒预测可提前预知跌倒,给机器预留时间采取安全保护措施,并可有效降低跌倒对老年人身体造成的损伤,但相关研究成果较少^[17]。跌倒预测的重点在于跌倒前对人体姿态的分析,根据姿态信号的变化情况提前判断是否有跌倒发生^[18-19]。惯性测量单元(inertial measurement unit, IMU)可采集运动物体的加速度、角速度、速度等姿态信息,具有成本较低、易于携带、隐私性较好等诸多优点,常被用于获取人体姿态信息或步态信息,以便做进一步的跌倒预测分析^[20-21]。文献[22]将惯性传感器固定到受试者的胸骨上采集行走的步态信息,利用随机森林模型计算人跌倒风险,实验取得了 80% 以上的跌倒预测准确率。文献[23]要求受试者在腰部佩戴加速度计用于测量运动加速度,先利用阈值法分类绝对跌倒和绝对日常活动,再利用机器学习法做进一步姿态识别,实验可以得到 90% 以上的跌倒预测准确率。然而以往的研究无法兼顾跌倒预测准确率和前置时间,且未同时考虑跌倒预测与防跌倒控制问题。

本文从步行康复训练机器人辅助老年人进行康复训练的应用需求出发,并考虑到高性能视觉传感器、肌电传感器、脑电传感器等的高成本问题,仅利用惯性传感单元

采集人体姿态信息,提出基于双层长短期记忆网络(long short-term memory, LSTM)和注意力机制的跌倒预测模型,对因人机速度不协调引发的跌倒事故进行预测。并在跌倒预测的基础上,提出相空间重构-模型预测控制(phase space reconstruction and model predictive control, PSR-MPC)人机速度协调防跌倒控制方法,避免在康复训练过程中发生因人机速度不协调引起的跌倒事故。实验结果表明,跌倒预测模型的预测准确率可达到 95.2%,且跌倒预测的前置时间可达 1.82 s。基于 IMU 的 PSR-MPC 人机速度协调防跌倒方法的优点是:当使用者正常步行康复训练时,可精确跟踪理疗师开具的运动处方;当使用者康复训练过程中发生跌倒时,可提前预测到跌倒并预测使用者的步行速度,并使机器人能精确跟踪使用者的步行速度,避免因人机速度不协调引发的跌倒事故。

1 跌倒预测模型设计

使用惯性传感器采集受试者前胸三轴加速度信号和角速度信号,并进一步计算笛卡尔坐标系下的速度信号,传感器佩戴方式如图 1 所示。

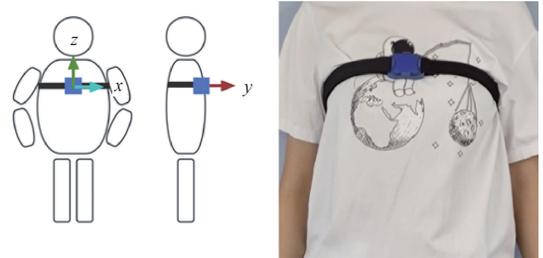


图 1 传感器佩戴位置示意图

Fig. 1 Diagram of the sensor position

针对人步行姿态信号设计了基于双层长短期记忆网络和注意力机制的跌倒预测模型。跌倒预测模型输入数据为 6 维特征的时间序列,分别为 x 轴方向的加速度和角速度, y 轴方向的加速度和角速度, z 轴方向的加速度和角速度。数据输入模型后,先经过第 1 层长短期记忆网络,第 2 层长短期记忆网络会再次处理前一层输出的特征数据,从中学到更多有效的信息。长短期记忆网络的输出作为注意力机制模块的输入,注意力机制将计算每个特征与其他特征的相关性大小,在训练阶段突出重要特征,为 6 种不同的特征按重要程度赋予不同的权值并计算最终输出。然后,接入到全连接(fully connected, FC)层,并由 Softmax 对人步行姿态进行分类并输出结果,跌倒预测模型结构如图 2 所示。

LSTM 是循环神经网络(recurrent neural network, RNN)的一种特殊类型,它可以通过特殊的门控机制解决循环神经网络的长期依赖问题,让信息在细胞单元上流

动,使其具有强大的时间序列处理能力^[24-25]。

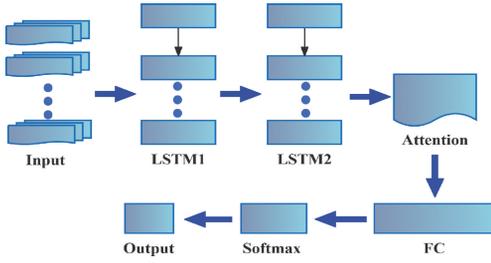


图 2 跌倒预测模型结构

Fig. 2 Model structure for fall prediction

LSTM 的核心结构可以分为 4 个部分:遗忘门、输入门、细胞状态和输出门^[26], LSTM 的工作过程可以由式(1)所示。

$$f_i(h_{i-1}, x_i) = \sigma(w_f \cdot [h_{i-1}, x_i] + b_f) \quad (1)$$

式中: $f_i(h_{i-1}, x_i)$ 表示遗忘门的输出, h_{i-1} 表示上一细胞单元的输出, x_i 表示当前细胞单元的输入, 激活函数取 sigmoid 函数 $\sigma(\square) = 1/(1 + e^{-\square})$, $\sigma(\square) \in [0, 1]$, w_f 表示遗忘门的权重矩阵, b_f 表示遗忘门的偏置项。

$$i_i(h_{i-1}, x_i) = \sigma(w_i \cdot [h_{i-1}, x_i] + b_i) \quad (2)$$

式中: $i_i(h_{i-1}, x_i)$ 表示输入门的输出, w_i 表示输入门的权重矩阵, b_i 表示输入门的偏置项。

$$c_i = c_{i-1} \odot f_i + \tilde{c}_i(h_{i-1}, x_i) \odot i_i \quad (3)$$

式中: c_{i-1} 为上一细胞状态, c_i 为当前细胞状态, $\tilde{c}_i(h_{i-1}, x_i)$ 为候选细胞状态。

$$\tilde{c}_i(h_{i-1}, x_i) = \tanh(w_c \cdot [h_{i-1}, x_i] + b_c) \quad (4)$$

式中: \tanh 为候选细胞状态的激活函数, $\tanh \in [-1, 1]$, w_c 表示候选细胞状态的权重矩阵, b_c 表示候选细胞状态的偏置项。

$$o_i(h_{i-1}, x_i) = \sigma(w_o \cdot [h_{i-1}, x_i] + b_o) \quad (5)$$

式中: $o_i(h_{i-1}, x_i)$ 表示输出门的输出, h_{i-1} 为上一细胞单元的输出, w_o 表示输出门权重矩阵, b_o 表示输出门偏置项。

$$h_i(o_i, c_i) = o_i \odot \tanh(c_i) \quad (6)$$

式中: $h_i(o_i, c_i)$ 为细胞单元的最终输出。

缩放点积注意力机制可有效降低跌倒预测模型的复杂度和计算量,并高效学习注意力的变化,从而产生更精确的权重分配,得到更好的预测结果,工作原理如式(7)~(10)所示。

$$q = \text{Query} \odot w_Q \quad (7)$$

$$k = \text{Key} \odot w_K \quad (8)$$

$$s = q \cdot k \quad (9)$$

$$\text{output} = \text{sum}(\text{softmax}(s/\sqrt{d_k}) \odot \text{Value} \odot w_V) \quad (10)$$

式中: s 、 q 和 k 皆为中间张量, Query 、 Key 、 Value 分别

表示查询向量、关键向量和值向量, w_Q 、 w_K 和 w_V 则表示它们对应的权重矩阵, d_k 为 Key 的维度。

2 基于 PSR-MPC 的防跌倒控制方法

2.1 步行康复训练机器人动力学模型

步行康复机器人如图 3 所示, 动力学模型描述为^[27]:

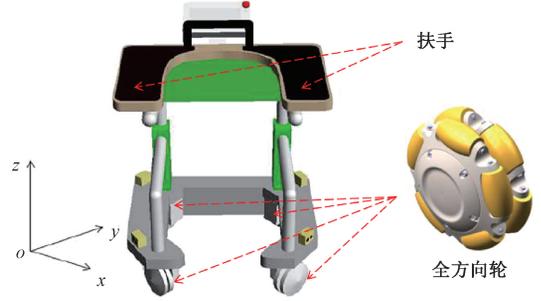


图 3 步行康复训练机器人结构

Fig. 3 Structure of the walking rehabilitation training robot

$$M_0 K(\theta) \ddot{X}(t) + M_0 \dot{K}(\theta) \dot{X}(t) = B(\theta) U(t) \quad (11)$$

式中: $X(t) = [x \ y \ \theta]^T$ 表示步行康复训练机器人的位置状态, $\dot{X}(t)$ 表示速度状态, $\ddot{X}(t)$ 表示加速度状态, $U(t) = [f_1 \ f_2 \ f_3 \ f_4]^T$, $f_i, i = 1, 2, 3, 4$ 表示 4 个轮子的控制力。其他变量表示为:

$$K(\theta) = \begin{bmatrix} 1 & 0 & p \\ 0 & 1 & q \\ 0 & 0 & 1 \end{bmatrix}$$

$$B(\theta) = \begin{bmatrix} -\sin\theta_1 & \sin\theta_2 & \sin\theta_3 & -\sin\theta_4 \\ \cos\theta_1 & -\cos\theta_2 & -\cos\theta_3 & \cos\theta_4 \\ \lambda_1 & -\lambda_2 & -\lambda_3 & \lambda_4 \end{bmatrix}$$

$$\lambda_i = l_i \cos(\theta_i - \phi_i), \theta_i = \theta + \frac{\pi}{2}(i-1)$$

$$p = \frac{1}{2} [\sin\theta(\lambda_1 - \lambda_3) + \cos\theta(\lambda_2 - \lambda_4)]$$

$$q = \frac{1}{2} [\sin\theta(\lambda_2 - \lambda_4) - \cos\theta(\lambda_1 - \lambda_3)]$$

$$M_0 = \text{Diag} [M + m \quad M + m \quad I_0 + mr_0^2]$$

式中: M 为机器人的质量, m 为训练者的质量; I_0 和 mr_0^2 分别表示步行康复训练机器人和训练者产生的转动惯量, r_0 表示机器人重心到中心的距离; l_i 表示步行康复训练机器人的重心到每个轮子中心的距离, θ_i 表示机器人重心与对应轮子的连线与坐标轴之间的夹角, ϕ_i 表示机器人中心与对应轮子的连线与坐标轴之间的夹角。

2.2 基于 PSR 的步行速度预测模型

将无线惯性姿态传感器采集的 xyz 三轴角速度信号

和加速度信号计算得到的 x_{yz} 三轴速度信号分为 3 组, 每组数据由每个轴方向上的速度信号和角速度信号组成, 记为多元时间序列为 $\{X_I, Y_I\}$, 其中 X_I 表示沿 x 轴的角速度, Y_I 表示沿 x 轴的速度, 需要预测的量为沿 x 轴方向的速度。两个离散系统分别为 $X_I = \{x_1, x_2, x_3, x_4, \dots, x_m\}$ 和 $Y_I = \{y_1, y_2, y_3, y_4, \dots, y_n\}$, 通过下式可以分别计算两个系统的信息熵 $H(\cdot)$ 和互信息 $I(X_I, Y_I)$:

$$H(X_I) = - \sum_{i=1}^m P_{X_I}(x_i) \log_2^{P_{X_I}(x_i)} \quad (12)$$

$$H(Y_I) = - \sum_{j=1}^n P_{Y_I}(y_j) \log_2^{P_{Y_I}(y_j)} \quad (13)$$

$$\begin{cases} I(X_I, Y_I) = H(X_I) + H(Y_I) - H(X_I, Y_I) \\ H(X_I, Y_I) = - \sum_{i=1}^m \sum_{j=1}^n P_{X_I, Y_I}(x_i, y_j) \log_2^{P_{X_I, Y_I}(x_i, y_j)} \end{cases} \quad (14)$$

式中: $P_{X_I}(x_i)$ 表示 X_I 中 x_i 概率, $P_{Y_I}(y_i)$ 表示 Y_I 中 y_i 概率, $H(X_I, Y_I)$ 表示两个系统的联合熵。

利用 $X_I = \{x_1, x_2, \dots, x_{m-\tau+1}\}$, $Y_I = \{y_\tau, y_{\tau+1}, \dots, y_n\}$, 那么式 (14) 可以用 $I_1(\tau)$ 表示, 求 $I_1(\tau)$ 的第一个极小值, 则得到时间延迟 τ 。增加嵌入维数 k , 计算预测变量 Y_I 在 $X_1^{(k)}$ 条件下的条件熵 $H(Y_I | X_1^{(k)})$, 当满足式 (15) 时嵌入维数 k 确定。

$$\begin{cases} H(Y_I | X_1^{(k)}) - H(Y_I | X_1^{(k+1)}) < \varepsilon \\ H(Y_I | X_1^{(k)}) = - \sum_{x_i \in X} P(x_i) \sum_{y_j \in Y} P(y_j | x_i) \log_2^{P(y_j | x_i)} \end{cases} \quad (15)$$

式中: ε 是一个极小量。

经过相空间重构之后的步行速度多元时间序列为:

$$H = \begin{bmatrix} x_1 & x_2 & \dots & x_{m_0} \\ x_{1+\tau} & x_{2+\tau} & \dots & x_{2+\tau} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1+(k-1)\tau} & x_{2+(k-1)\tau} & \dots & x_m \\ y_1 & y_2 & \dots & y_{n_0} \\ y_{1+\tau} & y_{2+\tau} & \dots & y_{n+\tau} \\ \vdots & \vdots & \ddots & \vdots \\ y_{1+(k-1)\tau} & y_{2+(k-1)\tau} & \dots & y_n \end{bmatrix} \quad (16)$$

使用局部线性嵌入法预测 x 轴上的下一组速度, 预测模型为:

$$\begin{cases} \hat{y}(n+1) = c_0 y(N) + c_1 y(N+\tau) + \dots + \\ c_{k-1} y(N+(k-1)\tau) + c_k \\ b = [c_0, c_1, c_2, \dots, c_k] \end{cases} \quad (17)$$

式中: $\hat{y}(n+1)$ 为 x 轴上的下一组速度的预测值, $y(N)$, $y(N+\tau), \dots, y(N+(k-1)\tau)$ 为 $\hat{y}(n+1)$ 的 $d+1$ 个

最近点, 利用欧几里得范数公式求系数 b :

$$b = (A^T A)^{-1} A^T Y \quad (18)$$

其中,

$$Y = \begin{bmatrix} y(t_1 + (k-1)\tau) \\ y(t_1 + 1 + (k-1)\tau) \\ y(t_1 + 2 + (k-1)\tau) \\ \vdots \\ y(t_1 + d + (k-1)\tau) \end{bmatrix}$$

$$A = \begin{bmatrix} y(t_j - d) & y(t_j - d + \tau) & \dots & y(t_j - d + (k-1)\tau) & 1 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ y(t_j - 1) & y(t_j - 1 + \tau) & \dots & y(t_j - 1 + (k-1)\tau) & 1 \\ y(t_j) & y(t_j + \tau) & \dots & y(t_j + (k-1)\tau) & 1 \end{bmatrix}$$

利用式 (17) 得到一次的预测值, 经过循环可得 x 轴速度预测值 $[\hat{y}_{x,n+1}, \hat{y}_{x,n+2}, \dots, \hat{y}_{x,n+n_0}]$, 用相同计算过程可得 y 轴速度预测值和旋转角速度预测值, 即为人步行时的姿态信息 $[\dot{x}_r, \dot{y}_r, \dot{\theta}_r]^T$ 。

2.3 基于速度预测信息的防跌倒控制方法

动力学模型式 (11) 可以化为以下形式:

$$\dot{X}(t) = K^{-1}(\theta) M_0^{-1} B(\theta) U(t) - K^{-1}(\theta) M_0^{-1} M_0 \dot{K}(\theta) X(t) \quad (19)$$

令 $\dot{X}(t) = \xi(t)$, 式 (19) 可以表示为:

$$\dot{\xi}(t) = K^{-1}(\theta) M_0^{-1} B(\theta) U(t) - K^{-1}(\theta) M_0^{-1} M_0 \dot{K}(\theta) \xi(t) \quad (20)$$

康复训练机器人系统可以看作是一个输入为 $u =$

$[f_1, f_2, f_3, f_4]^T$ 和状态变量为 $\xi = [\dot{x}, \dot{y}, \dot{\theta}]^T$ 的控制系统, 其一般形式可以表示为:

$$\dot{\xi} = f[\xi, u] \quad (21)$$

式中: $f[\xi, u]$ 是关于向量 ξ 和 u 的未知非线性函数, 在给定参考轨迹上, 每一点都满足式 (21), 用下标 r 代表目标轨迹上的任意一点, 此时:

$$\dot{\xi}_r = f[\xi_r, u_r] \quad (22)$$

在参考点 (ξ_r, u_r) 上, 利用泰勒展开式展开, 保留一阶项, 忽略高阶项, 可以得到:

$$\dot{\xi} = f(\xi_r, u_r) + \frac{\partial f}{\partial \xi} \Big|_{\xi=\xi_r} (\xi - \xi_r) + \frac{\partial f}{\partial u} \Big|_{u=u_r} (u - u_r) \quad (23)$$

令 $\tilde{\xi} = \xi - \xi_r$, $\tilde{u} = u - u_r$, 那么可以得到系统的线性误差模型, \tilde{A} 、 \tilde{B} 为对应的雅可比矩阵求偏导得到:

$$\dot{\tilde{\xi}} = \tilde{A} \tilde{\xi} + \tilde{B} \tilde{u} \quad (24)$$

式中:

$$\bar{A} = \begin{bmatrix} 0 & 0 & -\dot{p} \\ 0 & 0 & -\dot{q} \\ 0 & 0 & 0 \end{bmatrix}, \tilde{\xi} = \begin{bmatrix} \dot{x} - x_r \\ \dot{y} - y_r \\ \dot{\theta} - \dot{\theta}_r \end{bmatrix}, \tilde{u} = \begin{bmatrix} f_1 - f_{1r} \\ f_2 - f_{2r} \\ f_3 - f_{3r} \\ f_4 - f_{4r} \end{bmatrix}$$

$$\bar{B} = \begin{bmatrix} -\frac{\sin\theta}{M+m} - \frac{p\lambda_1}{I_0+mr_0^2} & \frac{\cos\theta}{M+m} + \frac{p\lambda_2}{I_0+mr_0^2} \\ \frac{\cos\theta}{M+m} - \frac{q\lambda_1}{I_0+mr_0^2} & \frac{\sin\theta}{M+m} + \frac{q\lambda_2}{I_0+mr_0^2} \\ \frac{\lambda_1}{I_0+mr_0^2} & \frac{-\lambda_2}{I_0+mr_0^2} \\ -\frac{\sin\theta}{M+m} + \frac{p\lambda_3}{I_0+mr_0^2} & \frac{\cos\theta_r}{M+m} - \frac{p_r\lambda_4}{I_0+mr_0^2} \\ \frac{\cos\theta}{M+m} + \frac{q\lambda_3}{I_0+mr_0^2} & \frac{\sin\theta}{M+m} - \frac{q\lambda_4}{I_0+mr_0^2} \\ \frac{-\lambda_3}{I_0+mr_0^2} & \frac{\lambda_4}{I_0+mr_0^2} \end{bmatrix}$$

为了将该模型应用于模型预测控制器,利用前向欧拉法对式(24)进行离散化,推导 $k+1$ 时刻的离散系统状态空间方程:

$$\tilde{\xi}(k+1) = (\mathbf{I} + \mathbf{T}\bar{\mathbf{A}})\tilde{\xi}(k) + \mathbf{T}\bar{\mathbf{B}}\tilde{u}(k) \quad (25)$$

式中: \mathbf{I} 表示单位矩阵, \mathbf{T} 为采样时间。

式(25)可化为式(26)所示的线性预测模型:

$$\tilde{\xi}(k+1) = \tilde{\mathbf{A}}\tilde{\xi}(k) + \tilde{\mathbf{B}}\tilde{u}(k) \quad (26)$$

式中: $\tilde{\mathbf{A}} = \mathbf{I} + \mathbf{T}\bar{\mathbf{A}}, \tilde{\mathbf{B}} = \mathbf{T}\bar{\mathbf{B}}$ 。

为了防止控制器在求解的过程中出现无最优解的情形,引入松弛因子^[28],设计目标函数 J 为:

$$J(k) = \sum_{i=1}^{N_p} \|\varphi(k+i) - \varphi_r(k+i)\|_D^2 + \sum_{i=1}^{N_c-1} \|\Delta u(k+i)\|_R^2 + \rho\varepsilon^2 \quad (27)$$

式中: $\varphi(k+i)$ 为控制输出, $\varphi_r(k+i)$ 为目标控制输出, $\Delta u(k+i)$ 为控制增量, N_p 为预测时域, N_c 为控制时域,满足 $N_p > N_c$, D 为轨迹偏移惩罚矩阵, R 为控制增量的惩罚矩阵, ρ 为权重系数, ε 为松弛因子, $\|\mathbf{Z}\|_D^2$ 表示 $\mathbf{Z}^T \mathbf{D} \mathbf{Z}$ 运算, \mathbf{Z} 代表式(27)双竖线中间的部分。

$$\text{令 } \boldsymbol{\eta}(k) = \begin{bmatrix} \tilde{\xi}(k) \\ \tilde{u}(k-1) \end{bmatrix}, \text{ 其中, } \tilde{u}(k) =$$

$\tilde{u}(k-1) + \Delta u(k), \Delta u(k)$ 表示控制增量,将式(26)转换成如式(28)所示形式:

$$\begin{cases} \boldsymbol{\eta}(k+1) = \mathbf{P}\boldsymbol{\eta}(k) + \mathbf{Q}\Delta u(k) \\ \mathbf{Y}(k) = \mathbf{C}\boldsymbol{\eta}(k) \end{cases} \quad (28)$$

式中:

$$\mathbf{P} = \begin{bmatrix} \tilde{\mathbf{A}} & \tilde{\mathbf{B}} \\ \mathbf{0}_{m \times n} & \mathbf{I}_m \end{bmatrix}, \mathbf{Q} = \begin{bmatrix} \tilde{\mathbf{B}} \\ \mathbf{I}_m \end{bmatrix}, \mathbf{C} = \begin{bmatrix} \mathbf{1} & \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{1} & \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \mathbf{1} & \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{0} \end{bmatrix}$$

式(28)为新的状态空间表达式,其中 n 为状态变量的维度, m 为控制量的维度。由式(28)可以推导出系统的预测输出表达式,如式(29)所示。

$$\boldsymbol{\varphi}(k) = \boldsymbol{\psi}\boldsymbol{\eta}(k) + \boldsymbol{\Theta}\Delta \mathbf{U}(k) \quad (29)$$

式中:

$$\boldsymbol{\Theta} = \begin{bmatrix} \mathbf{C}\mathbf{Q} & \mathbf{0} & \mathbf{L} & \mathbf{0} \\ \mathbf{C}\mathbf{P}\mathbf{Q} & \mathbf{C}\mathbf{Q} & \mathbf{L} & \mathbf{0} \\ \mathbf{M} & \mathbf{M} & \mathbf{O} & \mathbf{M} \\ \mathbf{C}\mathbf{P}^{N_c-1}\mathbf{Q} & \mathbf{C}\mathbf{P}^{N_c-2}\mathbf{Q} & \mathbf{L} & \mathbf{0} \\ \mathbf{C}\mathbf{P}^{N_c}\mathbf{Q} & \mathbf{C}\mathbf{P}^{N_c-1}\mathbf{Q} & \mathbf{L} & \mathbf{C}\mathbf{Q} \\ \mathbf{M} & \mathbf{M} & \mathbf{O} & \mathbf{M} \\ \mathbf{C}\mathbf{P}^{N_p-1}\mathbf{Q} & \mathbf{C}\mathbf{P}^{N_p-2}\mathbf{Q} & \mathbf{L} & \mathbf{C}\mathbf{P}^{N_p-N_c-1}\mathbf{Q} \end{bmatrix}$$

$$\boldsymbol{\varphi}(k) = \begin{bmatrix} \mathbf{Y}(k+1) \\ \mathbf{Y}(k+2) \\ \mathbf{M} \\ \mathbf{Y}(k+N_c) \\ \mathbf{M} \\ \mathbf{Y}(k+N_p) \end{bmatrix}, \boldsymbol{\psi} = \begin{bmatrix} \mathbf{C}\mathbf{P} \\ \mathbf{C}\mathbf{P}^2 \\ \mathbf{M} \\ \mathbf{C}\mathbf{P}^{N_c} \\ \mathbf{M} \\ \mathbf{C}\mathbf{P}^{N_p} \end{bmatrix}, \Delta \mathbf{U}(k) =$$

$$\begin{bmatrix} \Delta u(k) \\ \Delta u(k+1) \\ \vdots \\ \Delta u(k+N_c) \end{bmatrix}$$

将式(29)代入式(27)中,并将结果转化为标准二次型形式。

$$J(k) = \frac{1}{2} [\Delta \mathbf{U}^T(k) \quad \boldsymbol{\varepsilon}] \mathbf{H} \begin{bmatrix} \Delta \mathbf{U}(k) \\ \boldsymbol{\varepsilon} \end{bmatrix} + \mathbf{G} \begin{bmatrix} \Delta \mathbf{U}(k) \\ \boldsymbol{\varepsilon} \end{bmatrix} \quad (30)$$

为了避免系统控制增量过大而引起步行康复训练机器人的运动路径和速度发生突变,建立步行康复训练机器人的控制增量和控制输入约束条件。并将目标函数转化为标准二次型形式,此时模型预测控制的求解即可以转化成求解二次规划问题,并结合约束条件,将控制增量的求解转变为解决以下优化问题:

$$\begin{cases} J[\boldsymbol{\eta}(k), \mathbf{u}(k-1), \Delta\mathbf{U}(k)] = \frac{1}{2}\boldsymbol{\zeta}^T \mathbf{H}\boldsymbol{\zeta} + \mathbf{G}\boldsymbol{\zeta} \\ s. t. \Delta\mathbf{U}(k)_{\min} \leq \Delta\mathbf{U}(k) \leq \Delta\mathbf{U}(k)_{\max} \\ \mathbf{U}_{\min}(k) \leq \mathbf{u}(k) \leq \mathbf{U}_{\max}(k) \end{cases} \quad (31)$$

其中, $\boldsymbol{\zeta} = \begin{bmatrix} \Delta\mathbf{U}(k) \\ \boldsymbol{\varepsilon} \end{bmatrix}$, $\mathbf{H} = \begin{bmatrix} 2\boldsymbol{\Theta}^T \mathbf{D}\boldsymbol{\Theta} + 2\mathbf{R} & \mathbf{0} \\ \mathbf{0} & \boldsymbol{\rho} \end{bmatrix}$, $\mathbf{G} = [2\mathbf{E}^T \mathbf{D}\boldsymbol{\Theta} \ \mathbf{0}]$ 。

\mathbf{H} 为目标函数中求解 $\Delta\mathbf{U}(k)$ 的二次型矩阵, \mathbf{G} 为目标函数中求解 $\Delta\mathbf{U}(k)$ 的线性量。每经过一次采样都会完成一次对式 (31) 的求解, 得到的控制时域内的一系列控制增量如式 (32) 所示, 其中 $\Delta\mathbf{u}^*(k)$ 表示 k 时刻的最优控制增量。

$$\Delta\mathbf{U}^*(k) = \begin{bmatrix} \Delta\mathbf{u}^*(k) \\ \Delta\mathbf{u}^*(k+1) \\ \vdots \\ \Delta\mathbf{u}^*(k+N_c-1) \end{bmatrix} \quad (32)$$

每次循环都选取控制增量序列式 (32) 的第 1 个元素作为实际的控制增量作用于系统, 那么控制器输入 $\mathbf{u}(k)$ 的计算方法如式 (33) 所示。

$$\mathbf{u}(k) = \mathbf{u}(k-1) + \Delta\mathbf{u}^*(k) \quad (33)$$

进入下一个周期后, 此时重复上述过程, 依次循环即可实现步行康复训练机器人对人步行速度预测值的轨迹跟踪控制。

防跌倒控制策略的仿真程序流程图如图 4 所示。

3 步行康复训练机器人防跌倒控制仿真实验

3.1 跌倒预测实验

运动姿态数据采集时, 无线惯性姿态传感器被固定在受试者的胸前。进行传感器的初始水平校准后, 受试者可以自由行走活动。数据的采集频率为 400 Hz, 利用航向角转换矩阵将基于惯性传感器的局部坐标系的姿态数据转换为全局坐标系下的姿态信号。当跌倒预测模型预测出受试者即将发生跌倒, 则将 0.3 s 作为一个预测窗口, 向后预测一组速度信息, 将此速度信息作为步行康复训练机器人的目标速度, 即可实现机器人跟踪受试者速度, 防止因人机速度不协调发生的跌倒事故。

受试者共采集 1 000 组前胸姿态信息, 分为人机速度协调时正常行走的前胸姿态信息和人机速度不协调时发生跌倒的前胸姿态信息两类。取全部数据的 80% 作为训练集, 剩下 20% 的数据作为测试集, 即 800 组数据作为训练集, 200 组数据作为测试集。完成模型搭建之后, 训练集用于训练模型和各项参数调整, 最后使用测试集对

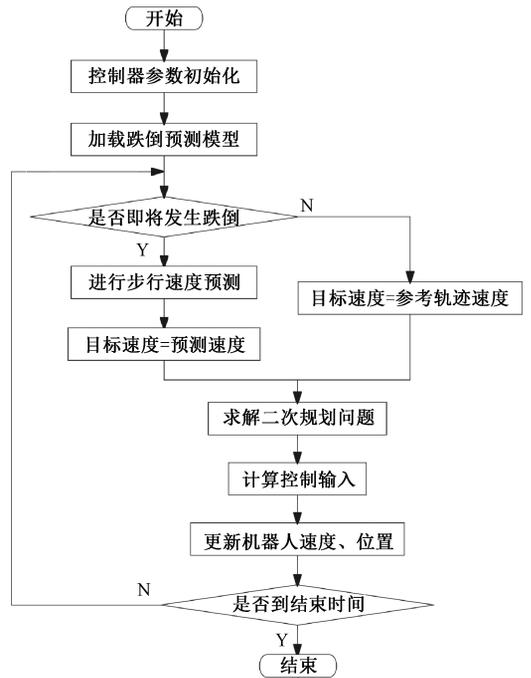


图 4 程序流程图

Fig. 4 Program flowchart

模型的分类预测效果进行验证, 得到最终的跌倒预测结果。图 5 和 6 是训练时的损失曲线和精确度曲线。

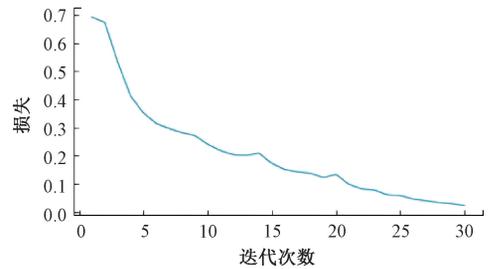


图 5 训练损失曲线

Fig. 5 Training loss curves

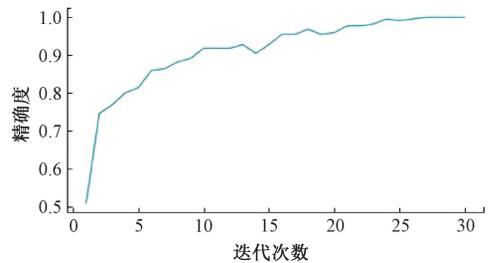


图 6 训练精确度曲线

Fig. 6 Training accuracy curves

由图 5 和 6 可知, 在训练开始阶段损失值大幅下降, 说明学习率合适且进行梯度下降, 学习到一定阶段后, 损

失曲线趋于平稳,在迭代次数接近 30 次时,损失逐渐接近 0。训练的精确度曲线稳步上升,直至趋于平稳并接近 1,表示模型的训练效果比较好,模型能够正确地预测出输入数据的类别,此时各项参数已经为最优,其中:步长 $batch_size$ 为 5,迭代次数 $epoch$ 为 30,初始学习率设置为 0.005,权重衰减系数设置为 0.000 1,然后使用该参数进行测试并计算各个评价标准。

使用准确率和跌倒预测前置时间作为跌倒预测模型的评价指标。跌倒预测的前置时间是指从预测出跌倒发生到人体躯干触地阶段的时间间隔,准确率 (precision, P) 的计算公式如式 (34) 所示。

$$P = \frac{TP}{TP + FP} \times 100\% \quad (34)$$

其中, TP 表示实际情况中跌倒且预测结果也是跌倒, FP 代表实际情况中正常步行但预测结果是跌倒,跌倒预测模型在测试集上的预测准确率为 95.2%。跌倒测试数据的跌倒预测前置时间如图 7 所示。

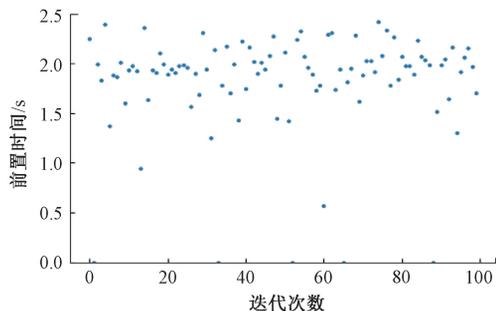


图 7 测试集跌倒预测前置时间

Fig. 7 Fall prediction lead time of test set

由以上各组跌倒预测前置时间可得到模型跌倒预测的平均前置时间为 1.82 s。通过以上实验结果证明基于双层 LSTM 和注意力机制的跌倒预测模型可有效预测跌倒发生的状况,且具有较高的预测准确率,同时也可延长跌倒预测的前置时间。

3.2 基于速度预测的轨迹跟踪仿真实验

为验证基于速度预测的防跌倒控制方法的有效性和稳定性,进行了速度预测实验和基于受试者步行速度预测值的机器人速度跟踪仿真实验。步行康复训练机器人的初始状态和初始速度设为 $X(0) = [0 \ 0 \ 0]^T$, $\dot{X}(0) = [0 \ 0 \ 0]^T$,此时步行速度预测情况和步行康复训练机器人的速度跟踪情况如图 8~10 所示。

由图 8~10 中的受试者行走速度与速度预测值实时重合,可以看出本文提出的速度预测模型可准确地预测受试者行走速度。在将受试者步行速度作为步行康复训练机器人的目标速度时,即使机器人的初始速度与目标速度存在较大偏差,仍可快速跟踪目标速度,且在目标速

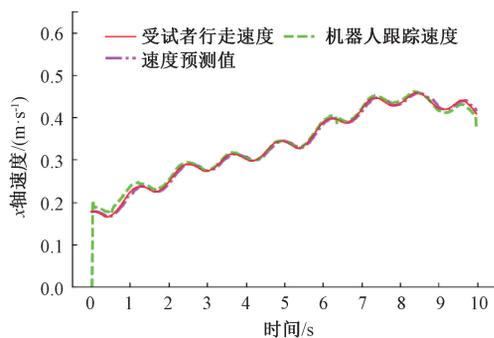


图 8 x 轴速度跟踪

Fig. 8 Velocity tracking of x-axis

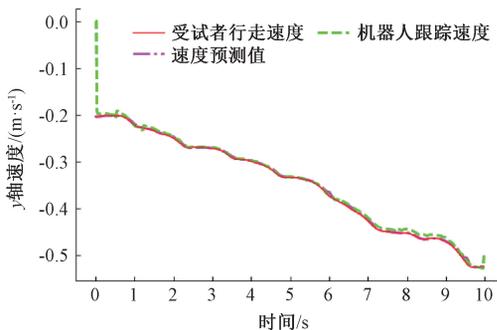


图 9 y 轴速度跟踪

Fig. 9 Velocity tracking of y-axis

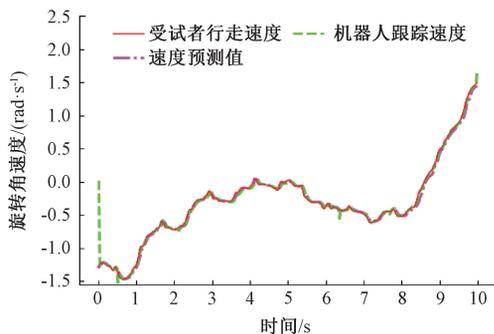


图 10 旋转角速度跟踪

Fig. 10 Velocity tracking of angle

度发生变化时步行康复训练机器人可以快速且精确地对目标速度进行跟踪。此外,步行康复训练机器人在 x 轴、 y 轴和旋转角 3 个方向上的跟踪速度都非常贴近受试者的行走速度。

3.3 防跌倒控制仿真实验

为验证本课题提出的基于跌倒预测和速度预测的防跌倒控制方法的有效性,与文献 [29] 提出的步行康复训练机器人的控制方法进行对比。对比仿真中,选取式 (35) 所示轨迹进行步行康复训练。

$$\begin{cases} x_r(t) = 20\cos(t/10) \\ y_r(t) = 10\sin(t/10) \\ \theta_r(t) = \pi/4 \end{cases} \quad (35)$$

此时步行康复训练机器人的初始状态和初始速度设为 $\mathbf{X}(0) = [20 \ 0 \ 0]^T$, $\dot{\mathbf{X}}(0) = [0 \ 1 \ 0]^T$, 此时步行康复训练机器人的轨迹跟踪情况如图 11 所示。

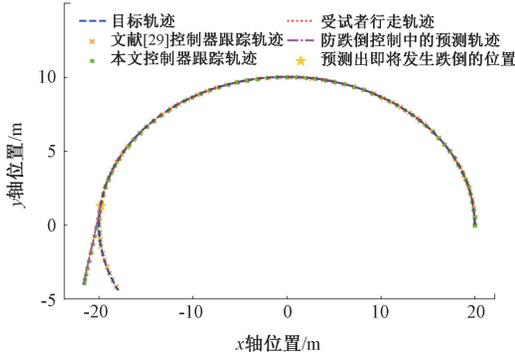


图 11 轨迹跟踪

Fig. 11 Path tracking

在图 11 中,机器人使用文献[29]中控制器生成的移动轨迹(“×”线)与式(35)描述的目标轨迹(“- -”线)重合,表明使用文献[29]中的控制器可实现轨迹跟踪。但使用跌倒预测模型,在“★”符号处,可预测出受试者即将发生跌倒;之后机器人继续使用文献[29]中的控制器,则受试者会发生跌倒(“×”线)。

图 11 中,在“★”符号之前,机器人使用本文提出控制器的跟踪轨迹(“...”线)与目标轨迹(“- -”线)重合,表明本文提出的控制策略,在预测到跌倒发生前可实现精确的轨迹跟踪。在“★”符号处,使用本文提出的跌倒预测模型,可预测出受试者即将发生跌倒。

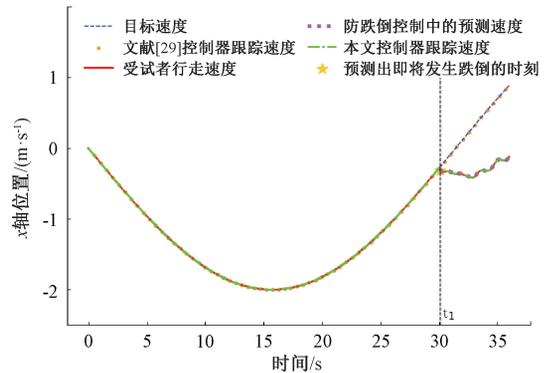
在“★”符号后,即使用跌倒预测模型预测到跌倒后,将采用速度预测模型对受试者的运动速度和轨迹进行预测。其中,防跌倒控制的预测轨迹(“-·-”线)与受试者行走轨迹(“...”线)重合,表明本文提出的方法对受试者行走轨迹预测的准确性。在“★”符号后,机器人使用本文控制器的跟踪轨迹(“●”线)与受试者行走轨迹(“...”线)重合,说明本文提出的防跌倒控制器可在机器人预测到受试者即将发生跌倒时,调整控制策略,机器人开始跟踪受试者的运动轨迹,进而防止受试者发生跌倒。在“★”符号后,跌倒预测模型仍然实时预测受试者是否发生跌倒,机器人的运动轨迹是“●”线,而不是“×”线,表明使用本文提出的防跌倒控制方法的有效性。

该仿真结果表明,本文提出防跌倒控制方法可保证受试者在不发生跌倒的情况下,精确跟踪指定的参考轨迹进行康复训练。当受试者步行速度与机器人目标速度无法匹配导致受试者可能发生跌倒时,跌倒预测模型可

预测出受试者的跌倒行为,机器人采用基于速度预测的防跌倒控制器跟踪受试者步行轨迹,达到避免受试者发生跌倒的效果。

本文提出的控制方法的目的是,当受试者不发生跌倒时,机器人跟踪康复训练轨迹,进而带动受试者进行步行康复训练,恢复受试者的腿部肌肉和行走能力;当预测到受试者发生跌倒时,保证受试者安全是第一位的,因此本文设计的控制方法使机器人不再跟踪设计好的康复训练轨迹,而是使机器人跟踪受试者的运动状态和速度,保证受试者平稳地停止康复训练或不发生跌倒。

机器人使用文献[29]提出的控制器,可以实现目标轨迹的稳定跟踪,但在人机速度不协调发生跌倒的情况下,仍然会继续跟踪原始目标轨迹,导致受试者发生跌倒。为得到机器人的实时运动信息,图 12 给出了本组仿真在 x 轴上的速度分量。

图 12 x 轴速度跟踪情况Fig. 12 Velocity tracking of x -axis

由图 12 可以看出本文提出的基于跌倒预测和速度预测的防跌倒控制方法,在 $(0, t_1)$ 时间段可以精确地跟踪目标轨迹的 x 轴速度。在 t_1 时刻预测到受试者即将发生跌倒后,速度预测模型能准确预测出受试者步行速度,且防跌倒控制器可以使步行康复机器人较精确地跟踪受试者的步行速度,使机器人与受试者“步调”一致,有效支撑受试者的身体,避免因人机速度不协调发生的跌倒事故。之后,受试者无需继续跟随目标轨迹继续进行康复训练,机器人会跟随受试者的运动速度缓慢移动防止二次跌倒的发生。而机器人使用文献[29]提出的控制器时,机器人只能跟踪指定目标速度,当受试者发生跌倒时,无法根据受试者的步行速度调整自身速度避免受试者发生跌倒。

4 结论

针对老年人参与步行康复训练过程中人步行速度与机器人目标速度不协调引发的跌倒问题,提出了基于

LSTM 和注意力机制的跌倒预测方法和基于 PSR-MPC 的人机速度协调防跌倒控制方法。实验结果表明,跌倒预测模型可有效预测受试者的跌倒行为,且跌倒预测的准确率可达到 95.2%,跌倒预测的前置时间可达 1.82 s。在跌倒预测的基础上,仿真实验结果表明基于 PSR-MPC 的防跌倒控制方法,可准确预测受试者步行速度,并精准跟踪受试者步行速度和行走轨迹,实现人机速度不协调情况下的防跌倒控制。实验结果验证了基于 LSTM 和注意力机制的跌倒预测模型和 PSR-MPC 人机速度协调防跌倒控制器的有效性。未来可将该技术拓展到步行康复训练机器人的主动康复训练研究。

参考文献

- [1] JEHU D A, DAVIS J C, FALCK R S, et al. Risk factors for recurrent falls in older adults: A systematic review with meta-analysis [J]. *Maturitas*, 2021, 144 (1): 23-28.
- [2] SUN Y, XIAO C, CHEN L P, et al. A review of intelligent walking support robots: Aiding sit-to-stand transition and walking [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2024, 32(1): 1355-1369.
- [3] ZHANG X, YUE Z, WANG J. Robotics in lower-limb rehabilitation after stroke [J]. *Behavioural Neurology*, 2017(1): 3731802-3731815.
- [4] WANG D, LI J, JIAN Z, et al. Modeling and control of a bedside cable-driven lower-limb rehabilitation robot for bedridden individuals [J]. *Frontiers in Bioengineering and Biotechnology*, 2023, 11(1): 1905-1916.
- [5] DONG M, YUAN J, LI J. A lower limb rehabilitation robot with rigid-flexible characteristics and multi-mode exercises [J]. *Machines*, 2022, 10(10): 918-929.
- [6] GAO M Y, WANG ZH L, PANG Z X, et al. Electrically driven lower limb exoskeleton rehabilitation robot based on anthropomorphic design [J]. *Machines*, 2022, 10(4): 266-272.
- [7] CHANG H, SUN P, WANG S. Output tracking control for an omnidirectional rehabilitative training walker with incomplete measurements and random parameters [J]. *International Journal of Systems Science*, 2017, 48(12): 2509-2521.
- [8] SUN P, SHAN R, WANG S. Safety-triggered stochastic tracking control for a cushion robot by constraining velocity considering the estimated internal disturbance [J]. *Applied Mathematics and Computation*, 2022, 416(1): 126761.
- [9] SABAH N, HAMEED E. Design of modified adaptive pid controller for lower limb rehabilitation robot based on grey wolf optimization algorithm [J]. *Webology*, 2022, 19(1): 295-310.
- [10] YANG R, ZHOU J, SONG R. Adaptive admittance control based on linear quadratic regulation optimization technique for a lower limb rehabilitation robot [C]. 2021 6th IEEE International Conference on Advanced Robotics and Mechatronics, 2021: 396-399.
- [11] LI X G, HOU C, HE J. Saturated sliding mode control scheme for a new wearable back-support exoskeleton [J]. *IEEE Transactions on Automation Science and Engineering*, 2023, 21(2): 1392-1404.
- [12] PÉREZ-SAN LÁZARO R, SALGADO I, CHAIREZ I. Adaptive sliding-mode controller of a lower limb mobile exoskeleton for active rehabilitation [J]. *ISA Transactions*, 2021, 109(1): 218-228.
- [13] 赵东辉, 王威, 张紫涵, 等. 基于多模态步行意图识别的助行机器人柔顺控制 [J]. *仪器仪表学报*, 2022, 43(2): 205-215.
- [14] ZHAO D H, WANG W, ZHANG Z H, et al. Compliance control of walking aid robots based on multimodal walking intention recognition [J]. *Chinese Journal of Scientific Instrument*, 2022, 43(2): 205-215.
- [15] WANG P, LI Q, YIN P, et al. A convolution neural network approach for fall detection based on adaptive channel selection of UWB radar signals [J]. *Neural Computing and Applications*, 2023, 35(22): 15967-15980.
- [16] YHDEGO H, LI J, PAOLINI C, et al. Wearable sensor gait analysis of fall detection using attention network [C]. 2021 IEEE International Conference on Bioinformatics and Biomedicine, 2021: 3137-3141.
- [17] 刘鹏飞, 李伟彤. 基于时空自适应图卷积网络的跌倒检测算法 [J]. *电子测量技术*, 2023, 46(3): 150-156.
- [18] LIU P F, LI W T. Fall detection algorithm based on spatial-temporal adaptive graph convolution network [J]. *Electronic Measurement Technology*, 2023, 46(3): 150-156.
- [19] PARSONS R, BLYTHE R D, CRAMB S M, et al. Inpatient fall prediction models: A scoping review [J]. *Gerontology*, 2023, 69(1): 14-29.
- [20] LIU J W, LI X H, HUANG SH SH, et al. A review of wearable sensors based fall-related recognition systems [J]. *Engineering Applications of Artificial Intelligence*, 2023, 121(1): 105993-106008.
- [21] NOH B, YOUM C, GOH E, et al. XGBoost based machine learning approach to predict the risk of fall in older adults using gait outcomes [J]. *Scientific Reports*, 2021, 11(1): 12183-12188.
- [22] SAADEH W, BUTT S A, ALTAF M A B. A patient-

- specific single sensor IoT-based wearable fall prediction and detection system [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2019, 27(5): 995-1003.
- [21] SIWADAMRONGPONG W, CHINRUNGRUENG J, HASEGAWA S, et al. Fall detection and prediction based on IMU and EMG sensors for elders [C]. 2022 19th International Joint Conference on Computer Science and Software Engineering (JCSSE), 2022: 1-6.
- [22] LOCKHART T E, SOANGRA R, YOON H, et al. Prediction of fall risk among community-dwelling older adults using a wearable system [J]. *Scientific Reports*, 2021, 11(1): 20976-20981.
- [23] SAMPATH D M A, KARTHIKEYAN T, VINOTH K R. Gait-based person fall prediction using deep learning approach [J]. *Soft Computing*, 2022, 26(23): 12933-12941.
- [24] 王江, 史元浩, 郭正玉, 等. 融合小波分解和 LSTM 的目标轨迹预测 [J]. *电子测量与仪器学报*, 2023, 37(1): 204-211.
WANG J, SHI Y H, GUO ZH Y, et al. Target trajectory prediction by fusing wavelet decomposition and LSTM [J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(1): 204-211.
- [25] 张怀洲, 行鸿彦, 李浩琪, 等. 融合 LSTM 和改进 A* 算法的火灾逃生路径规划方法 [J]. *电子测量与仪器学报*, 2023, 37(4): 69-79.
ZHANG H ZH, XING H Y, LI H Q, et al. Fire escape path planning method based on LSTM and improved A* algorithm [J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(4): 69-79.
- [26] 杨生鹏, 文中, 丁剑, 等. 二次分解组合 LSTM 的短期风电功率预测模型 [J]. *国外电子测量技术*, 2024, 43(1): 87-93.
YANG SH P, WEN ZH, DING J, et al. Short-term wind power prediction model for quadratic decomposition combined LSTM [J]. *Foreign Electronic Measurement Technology*, 2024, 43(1): 87-93.
- [27] SU X J, QING F D, CHANG H B, et al. Trajectory tracking control of human support robots via adaptive sliding-mode approach [J]. *IEEE Transactions on Cybernetics*, 2023, 54(3): 1747-1754.
- [28] 严浙平, 杨皓宇, 张伟, 等. 基于模型预测—中枢模式发生器的六足机器人轨迹跟踪控制 [J]. *机器人*, 2023, 45(1): 58-69.
YAN ZH P, YANG H Y, ZHANG W, et al. Trajectory tracking control of hexapod robot based on model prediction and central pattern generator [J]. *Robot*, 2023, 45(1): 58-69.
- [29] CHANG H, WANG S, SUN P. Stochastic adaptive tracking for a rehabilitative training walker with control constraints considering the omniwheel touchdown characteristic [J]. *International Journal of Control*, 2020, 93(5): 1159-1171.

作者简介



常洪彬(通信作者), 2011 年于沈阳师范大学获得学士学位, 2016 年于沈阳工业大学获得硕士学位, 2019 年于日本高知工科大学获得博士学位, 现为沈阳工业大学副教授, 主要研究方向为康复机器人、智能控制等。

E-mail: Chang.hongbin@sut.edu.cn

Chang Hongbin (Corresponding author) received his B. Sc. degree from Shenyang Normal University in 2011, M. Sc. degree from Shenyang University of Technology in 2016, and Ph. D. degree from Kochi University of Technology in 2019, respectively. Now he is an associate professor in Shenyang University of Technology. His main research interests include rehabilitation robots, intelligent control, etc.