

DOI: 10.19650/j.cnki.cjsi.J1905558

面向伴随型机器人同步运动的递进式步态时相检测算法*

张金艺¹, 秦政¹, 林羽晨¹, 姜玉稀²

(1. 上海大学 特种光纤与光接入网重点实验室 上海 200444; 2. 上海三思系统集成研究所 上海 201100)

摘要:在面向伴随型机器人的研究中,步态时相检测是保持人机同步运动的关键。然而,提高检测精度需要收集和分析更多步态时相信息,这导致检测延时冗长,无法满足实时性需求。针对此问题提出一种面向伴随型机器人同步运动的递进式步态时相检测算法,主要依托惯性测量单元和贝叶斯信息准则构建概率生成模型的物理层和决策层,对步态时相进行初步的快速检测;当检测达不到判决阈值时,在决策层中引入记忆网络,预测下一段时间的步态时相参数,从而为概率生成模型提供更多的决策信息,并依据多次判决结果递进地完成步态时相精准的增量检测。实验结果表明:算法的步态时相检测准确率达97.8%;决策时间为28.3 ms,相较于自适应贝叶斯算法降低了约30%。

关键词:伴随型机器人;同步运动;步态时相检测;贝叶斯信息准则;概率生成模型

中图分类号: TP212.6 TH39 **文献标识码:** A **国家标准学科分类代码:** 460.40

Progressive gait phase detection algorithm targeting to synchronous motion of companion robots

Zhang Jinyi¹, Qin Zheng¹, Lin Yuchen¹, Jiang Yuxi²

(1. Key laboratory of Specialty Fiber Optics and Optical Access Networks, Shanghai University, Shanghai 200444, China;

2. Shanghai Sansi Institute for System Integration, Shanghai 201100, China)

Abstract: In the research of companion robots, gait phase detection is the key to maintaining man-machine synchronous motion. However, improving detection accuracy requires collecting and analyzing more gait phase information, which results in a long detection delay and is unable to meet the real-time requirements. In this paper, a progressive gait phase detection algorithm targeting to synchronous motion of companion robots is proposed. The algorithm mainly constructs the physical layer and decision layer of the probabilistic generative model based on the inertial measurement unit and Bayesian information criterion, and performs preliminary rapid gait phase detection; when the detection fails to reach the decision threshold, a memory network is introduced in the decision layer to predict the gait phase parameters for next period of time, thereby provide more decision information for the probabilistic generative model, and progressively complete the accurate incremental detection of the gait phase based on multiple decision results. The experiment results show that the proposed gait phase detection algorithm achieves an accuracy of 97.8%; the decision time is 28.3 ms, which is about 30% reduction compared with the adaptive Bayesian algorithm.

Keywords: companion robot; synchronous motion; gait phase detection; Bayesian information criterion; probabilistic generative model

0 引言

智能化和拟人化的伴随型机器人已被逐渐应用于老年人生活服务中^[1-3]。为有效满足老年人与伴随型机器人同步而行的需求,必须提升机器人的运动精确度并降

低人机交互延时。为此,从人体步态特征角度出发,对伴随型机器人的同步运动展开深入研究^[4-6]。步态时相检测是一种研究步态特征的有效算法,通过人体步态周期的划分和参数分析对运动时下肢位姿变化进行表征,进而创建和改进伴随型机器人控制策略,让其构建稳定的交互和运动体系结构^[7-8]。其中步态时相参数一般来源

收稿日期:2019-08-31 Received Date:2019-08-31

* 基金项目:十三五国家重点研发计划(2017YFB0403500)、上海市教委重点学科(J50104)项目资助

于力敏电阻 (force sensing resistor, FSR)、肌电 (electromyographic, EMG) 传感器、惯性测量单元 (inertial measurement unit, IMU) 等可穿戴传感器^[9-10]。

传统的步态时相检测研究着重于提高算法的精确度,而较少考虑硬件或软件的开销。亚利桑那州立大学的 Huang 等^[11]将 9 个 EMG 传感器置于膝关节肌肉上方,采用滑动窗口提取 4 种步态时相特征,并基于支持向量机实现 97% 的分类精度,然而传感器数量造成很大开销,导致应用场景受限;中国科学院的 Zhou 等^[12]运用小波变换策略,借助足底的压力传感器和小腿上的加速度计分析两种步态时相的时频信息,最终达到 97.8% 的检测精度,然而算法中用于平滑数据的滑动窗口过长,导致整体检测延时为 108.5 ms,实时性不高。为提升步态时相检测的整体性能,美国范德堡大学的 Ledoux^[13]指出步态时相检测不应当依赖于测力传感器,可采用绑定在小腿上的单个 IMU 降低系统开销,其基于阈值化方法对两种步态时相实现 92% 的检测精度,延时为 2% 个步幅周期。近两年的步态时相检测研究对步态周期的划分要求更加精细,英国利兹大学的 Martinez-herenandeza 等^[14]将 3 个惯性传感单元绑定在大腿、小腿和足部,提出一种自适应贝叶斯算法,在贝叶斯公式基础上加入时序因素,研究步态时相参数的转换关系,最终对 8 种步态时相实现 99.82% 的检测精度,并产生 40 ms 延时,此外 Martinez-herenandeza 等^[15]提出卷积神经网络也可以用于检测步态时相,通过卷积核提取步态特征参数进行分类,可达到 98.32% 的检测精度。虽然目前步态时相检测的精确度已足够,然而大量参数的提取和处理依然会带来较大的检测延迟,这对于伴随型机器人的同步运动而言是一个无法忽视的问题。

本文提出一种面向伴随型机器人同步运动的递进式步态时相检测算法,主要依托惯性测量单元和贝叶斯信息准则构建概率生成模型的物理层和决策层,对步态时相进行初步的快速检测;当检测达不到判决阈值时,在决策层中引入记忆网络,预测下一段时间的步态时相参数,从而为概率生成模型提供更多决策信息,并依据多次判决结果递进地完成步态时相精准的增量检测。

1 递进式步态时相检测算法中的概率生成模型

1.1 概率生成模型结构

概率生成模型的目的在于构建步态时相参数与步态时相类别间的概率分布关系,因此需要对实际的步态时相参数值进行收集和处理。本文提出的概率生成模型可以分为物理层和决策层两个部分,具体结构如图 1 所示。




图 1 递进式步态时相检测算法中的概率生成模型

Fig.1 The probabilistic generative model in progressive gait phase detection algorithm

物理层主要作用是获取步态时相参数和提取相应特征,为后续的检测作铺垫;决策层负责基于贝叶斯准则的条件概率计算、步态时相的快速检测和步态时相的增量检测。其中增量检测在初步的快速检测基础上补充完善,以实现整个算法体系的递进式检测。

1.2 概率生成模型中的物理层

概率生成模型中的物理层包含数据采集模块和数据处理模块,其中数据采集模块为数据处理模块提供完整的原始步态时相参数。数据采集模块主要基于惯性测量单元获取步态时相参数,其内容包含加速度计获取的三维加速度数据和陀螺仪得到的三维角速度数据;数据处理模块需要先对原始数据进行低通滤波处理,以减少噪声干扰^[16],而后计算已获得三维数据的均方根值,得到加速度矢量和 ACC 与角速度矢量和 GRY ,其计算方式如式(1)和(2)所示。

$$ACC = \sqrt{X_{acc}^2 + Y_{acc}^2 + Z_{acc}^2} \quad (1)$$

$$GRY = \sqrt{X_{gry}^2 + Y_{gry}^2 + Z_{gry}^2} \quad (2)$$

式中: X_{acc} 、 Y_{acc} 、 Z_{acc} 分别为加速度在 X 、 Y 、 Z 方向上的矢量分量; X_{gry} 、 Y_{gry} 、 Z_{gry} 分别为角速度在 X 、 Y 、 Z 方向上的矢量分量。此外,根据 Rancho Los Amigos 步态分析委员会^[17]引入的步态时相术语,一个运动周期中的步态时相可以分为 8 个类别,其具体划分如图 2 所示。首次触地期 (initial contact, IC) 表示右脚跟触地到右脚跟着地受力阶段;承重反应期 (loading response, LR) 表示右脚跟着地到右全脚着地;支撑相中期 (mid stance, MSt) 表示右全脚着地到右脚跟离地;支撑相末期 (terminal stance, TSt) 表示右脚跟离地到左脚跟着地;摆动前期 (pre swing, PSw)

表示左脚跟着地到右脚尖离地;摆动相早期(initial swing, ISw)表示右脚尖离地到右脚处于身体中间;摆动相中期(mid swing, MSw)表示右脚处于身体中间到右脚处于身体前一段距离并开始减速;摆动相末期(terminal swing, TSw)表示右脚处于身体前一段距离并开始减速到右脚跟触地。




图2 一个步态周期内的步态时相划分

Fig.2 Gait phase division in a gait cycle

考虑各步态时相在整个周期占比情况,IC阶段可近似忽略,此外TSw步态时相会因为个体的运动习惯导致差异较大,因此本文进行除IC和TSw外的6种步态时相检测,并在收集参数时将数值与步态时相类别严格对应。

1.3 概率生成模型中的决策层

决策层包含监督训练模块、时相检测模块以及记忆网络下的投票判决模块。其中监督训练模块为时相检测模块提供贝叶斯表达式中的条件概率信息,记忆网络可为贝叶斯表达式提供更多参数,其机制在第2节详细阐述。监督训练模块以贝叶斯信息准则为基础,用于步态时相检测的时序贝叶斯表达式^[14]如式(3)所示。

$$P(C_n | A_t) = \frac{P(C_n | A_{t-1})P(A_t | C_n)}{P(A_t | A_{t-1})} \quad (3)$$

式中: C_n 表示步态时相类别; A 表示步态时相特征;下标 t 表示时间。

步态时相特征包括加速度矢量和、角速度矢量和,两个特征近似满足相互独立的条件,贝叶斯可进一步转化为朴素贝叶斯^[18]。此外,由于不同步态时相种类在惯性传感器时序参数上表现为分段式特征,为进行步态时相的快速检测,本文将时序贝叶斯离散化,消除步态时相转换因素,即将式(3)改进成式(4),其中 A_i 表示不同特征, m 表示特征的种类。

$$P(C_n | A) = \frac{P(C_n) \prod_{i=1}^m P(A_i | C_n)}{P(A)} \quad (4)$$

时相检测模块的检测标准如式(5)和(6)所示。

$$C = \max \{P(C_n | A)\} \quad (5)$$

$$C > T \quad (6)$$

式中: C 表示最大后验概率对应的步态时相; T 为检测阈值。当 C 达到阈值时,表明当前最大后验概率对应的步

态时相满足检测标准,即完成步态时相初步的快速检测,否则表明当前步态时相参数信息不够完整,极有可能处于步态时相转换的中间状态。为此考虑步态时相参数的时间关联性,引入记忆网络进行时序建模以预测下一段时间的步态时相参数,从而对更丰富的信息提取特征,多次计算后验概率后通过投票机制选出最切合实际的步态时相。

2 服务于步态时相增量检测的记忆网络

当概率生成模型下步态时相初步的快速检测无法满足阈值条件,即离散的步态时相特征不能精确划分步态时相类别时,必须考虑传感器参数的时间关联性,进行时序建模以获得额外的步态时相参数,用于步态时相的增量检测。深度学习领域的循环神经网络(recurrent neural network, RNN)已被证明在时间序列建模问题中的有效性^[19],其内部的处理机制包括内反馈连接和前馈连接,在计算过程中能够体现过程动态特性。

考虑到基本的RNN模型在迭代更新网络时存在梯度消失情况,因此采用RNN的变体,即长短期记忆网络(long short-term memory, LSTM)解决长期依赖问题^[20-22]。通过神经网络中神经元的迭代更替,建立步态时相参数间的关联特性^[23-25]。图3所示为一个由10个LSTM单元组成的深度RNN模型。其中每个LSTM模块包含1个单元格状态和3个门:输入门、遗忘门和输出门。输入门被定义为:

$$I_t = \beta(W_{PI}P_t + W_{HI}H_{t-1} + b_I) \quad (7)$$

式中: β 是数学上的sigmoid函数; W 是权重矩阵; P 是单模块输入参数; H 代表模块间输入参数; b 表示偏差向量。遗忘门 F 可以表示为:

$$F_t = \beta(W_{PF}P_t + W_{HF}H_{t-1} + b_F) \quad (8)$$

长短期记忆存储在记忆单元中,其状态以向量 S 表示如下:

$$S_t = F_t S_{t-1} + I_t \tanh(W_{PS}P_t + W_{HS}H_{t-1} + b_S) \quad (9)$$

输出门 O 决定了输出函数表达式如下:

$$O_t = \beta(W_{PO}P_t + W_{HO}H_{t-1} + b_O) \quad (10)$$

隐藏状态 H 可以表示为:

$$H_t = O_t \tanh(S_t) \quad (11)$$

最后输出 U 的表达式为:

$$U = \text{softmax}(W_U H_L + b_U) \quad (12)$$

式中: L 表示RNN的最后一个LSTM序号。

整个记忆网络的核心在于内部神经元比重和偏移的数值训练。通过预设的神经元参数将训练集前向传播得到一个预测值,与实际值对比后再反向传播更新神经元参数,反复迭代一定次数可将记忆网络训练完成。训练好的记忆网络可基于当前的步态时相参数预测未来一段




图 3 深度 RNN 结构
Fig.3 Structure of deep RNN

时间的参数,从而得到更多的步态时相分段内容,并作为额外信息输入至概率生成模型。

引入记忆网络后,概率生成模型可以获得下一段时间的步态时相参数,从而对更丰富的信息提取特征,作为输入多次计算式(4)中的后验概率,最终通过投票机制,选出基于式(5)得到的步态时相众数,完成步态时相精准的增量检测。其中投票机制基于图 4 所示的参数段 1~3。




图 4 投票机制中的参数段
Fig.4 The parameter segments in voting mechanism

当快速检测选取的参数段 1 得不到满足判决阈值的步态时相时,再通过记忆网络获得步态时相参数段 2 和 3,进而从 3 个步态时相中投票选出众数。若是 3 个步态时相均不相同,则选取最大后验概率对应的步态时相,以此可解决快速检测达不到判决阈值的问题,整体实现步态时相的递进式检测。

3 验证与结果分析

3.1 验证体系构建

本文共有 20 名志愿者参与步态时相参数的采集,其中人员性别和年龄段划分如表 1 所示。

表 1 数据采集人员划分
Table 1 Division of the data collection subjects

采集人员	性别	年龄段/岁	体重/kg
18 名老年人	9 男,9 女	45~55	55~78
2 名中年人	1 男,1 女	40~45	


所有志愿者在采集参数时被要求以正常速度在平地上按直线方向正常行走。采集方法基于运动绑带,将集成了 IMU 的智能手机固定在人体的右膝关节下方,以保证数据的可靠性,如图 5 所示。采集过程中志愿者正常步行以获取惯性传感器数据,采样频率为 50 Hz,并通过智能手机发送至上位机进行数据存储和分析。




图 5 集成 IMU 的智能手机
Fig.5 The smartphone integrating IMU

本文对 20 名志愿者各采集 20 组有效步态时相周期,共收集如图 6 所示的 400 组步态时相周期,选取 280 组用于训练,120 组用于测试。上位机端使用数学工具 MATLAB 进行概率生成模型的构建,而后基于深度学习

框架 Pytorch 对步态时相训练集进行 LSTM 训练,以提供额外的步态时相参数信息,引入概率生成模型中实现步态时相的进一步决策,完善整个算法体系。最终,通过测试数据对面向伴随型机器人同步运动的递进式步态时相检测算法进行验证。



(a) 加速度曲线
(a) Acceleration curve



(b) 角速度曲线
(b) Angular velocity curve

图 6 步态时相周期
Fig.6 Gait phase period

3.2 实验结果分析

本文首先对训练集中每组步态时相周期进行步态时相类别划分,再通过长度为 100 ms 的滑动窗口求解各步态时相对应加速度和角速度的均值,并保证当前步态时相参数至少占滑动窗口的 60%,最终可获得如图 7 所示的 6 种步态时相特征的散点图,进一步依据其分布情况作为贝叶斯信息准则的判决依据。

由图 7 可见,不同步态时相的特征分布于不同位置,此时可对分布图进行区间划分,统计贝叶斯表达式中各步态时相对应的条件概率,以实现后验概率的计算和对应步态时相初步的快速检测。

考虑到图 7 中不同步态时相特征有一定重叠,当初步判决不满足阈值条件时,为步态时相参数的时间关联性引入记忆网络。本文基于深度学习框架 Pytorch 对步态时相周期进行 LSTM 训练,为对比训练和测试效果,取 280 组训练集的前 80% 进行训练,每组周期约 50 个参数




图 7 步态时相特征散点分布
Fig.7 Scatter distribution plot of gait phase feature

特征点,共训练 5 000 次,最终收敛的最小损失函数值为 0.0011,得到的损失函数曲线如图 8 所示,对训练集的后 20% 进行 50 次测试验证,其中一次测试结果如图 9 所示。




图 8 损失函数收敛曲线
Fig.8 Convergence curve of the loss function




图 9 测试结果
Fig.9 The test results

从图 9 中可以看出,训练结果与原步态时相周期参数基本一致,测试结果与原步态时相周期参数接近。在通过记忆网络获得步态时相参数的预测值后,可以进一步作为额外信息输入至概率生成模型提取特征,多次计算后验概率后通过投票机制选出最切合实际的步态时相。

完成概率生成模型的搭建和记忆网络训练后,本节课对于用于测试的 120 组步态时相进行检测,得到如图 10 所示的检测曲线,其中纵坐标为 7 的点代表 TSw,仅作步态周期示意使用。可以看出,整体步态时相检测的类别与实际类别基本一致。




图 10 步态时相检测的类别曲线对比

Fig.10 Comparison of the category curves of gait phase detection

本文的步态时相延迟主要来自于记忆网络的数据预测,对 120 组步态时相检测的延迟平均为 28.3 ms。此外,本文对各种步态时相检测混淆矩阵如图 11 所示。




图 11 步态时相检测混淆矩阵

Fig.11 Confusion matrix of gait phase detection

参照图 7 中各步态时相的特征分布散点图,从图 11 中可以看出,MSt 和 MSw 这两个步态时相误检率较低,原因是其特征分布较为集中,且同其余步态时相特征差异较大;TSt 和 ISw 这两个步态时相检测准确率最低,原因是其特征分布受数据采集者不同、运动速度有快慢等因素影响较大,且与其余步态时相特征分布产生多个交集。此外,误检情况不仅仅产生在相邻步态时相中,这也体现出概率生成模型对特征进行离散分析的特点。本文步态时相检测的整体准确率保持在 97.0% 以上,平均达到 97.8% 的检测准确率,算法整体检测情况与其余步态时相检测相关文献对比如表 2 所示。

表 2 步态时相检测方法对比
Table 2 Comparison of gait phase detection methods

步态时相检测方法	IMU 数量	步态时相种类	检测准确率/%	检测延时
时频分析与峰值启发式算法 ^[12]	2	2(HS/TO)	97.8	108.5 ms
阈值法 ^[13]	1	2(HS/TO)	92	2% 步幅
自适应贝叶斯算法 ^[14]	3	8(IC/LR/MD/TS/PS/IS/MS/TS)	99.82	40 ms
卷积神经网络与一阶马尔可夫策略 ^[15]	3	8(IC/LR/MD/TS/PS/IS/MS/TS)	98.32	-
递进式步态时相检测算法	1	6(LR/MSt/TSt/PSw/ISw/MSw)	97.8	28.3 ms

从表 2 中可以看出,本文递进式步态时相检测算法仅借助单个传感器,硬件开销较小,算法整体对步态时相进行了 6 种划分,最终在实现较高检测准确率的情况下保持相对较低的延时,降低了步态时相检测的软件开销。

4 结 论

本文提出的递进式步态时相检测算法,依托惯性测

量单元和贝叶斯信息准则构建概率生成模型的物理层和决策层,完成步态时相初步的快速检测,另外引入记忆网络,基于预测的步态时相参数,多次判决后实现步态时相精准的增量检测,以解决快速检测达不到判决阈值的问题,整体实现步态时相的递进式检测。算法在实现较高检测准确率的同时能够保持较低的延时,提升了检测性能,能够较好地服务于伴随型机器人的同步运动。

需要注意的是,本文尚未将复杂运动纳入同步运动的范畴,如紧急转弯、突变跑跳等情况,这需要借助更多

传感器收集丰富有效的数据,用以检测更完整精确的步态时相,从而增强整个算法在不同运动情况下的鲁棒性。未来的研究还可以对人体运动进行突变运动的建模,进一步为人机同步运动提供决策依据。

参考文献

- [1] 王亚宾,张小栋,穆小奇,等. 用于助老伴行机器人的老年人摔倒预测方法研究[J]. 电子测量与仪器学报, 2018, 32(7): 1-7.
WANG Y B, ZHANG X D, MU X Q, et al. Research on the prediction method of elderly fall-down for elderly-assistant and walking-assistant robot [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(7): 1-7.
- [2] 刘策,刘小峰. 助老服务机器人多模式友好交互系统设计与实现[J]. 电子测量与仪器学报, 2019, 33(1): 177-182.
LIU C, LIU X F. Design and implementation of multi-mode friendly interactive system for elderly assistance robot [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(1): 177-182.
- [3] 颜云辉,徐靖,陆志国,等. 仿人服务机器人发展与研究现状[J]. 机器人, 2017, 39(4): 551-564.
YAN Y H, XU J, LU ZH G, et al. Development and research status of humanoid service robots [J]. Robot, 2017, 39(4): 551-564.
- [4] WANG L, YI J G, LIU T. Gait adaptable human-robot interaction system and its application to a robotic walker[C]. IEEE 8th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER), 2018: 707-712.
- [5] IHN-SIK W, SOON-GEUL L. Intelligent robotic walker with actively controlled human interaction [J]. ETRI Journal, 2018, 40(4): 522-530.
- [6] 戴廷飞,刘邈,叶阳阳,等. 人机共享控制机器人系统的应用与发展[J]. 仪器仪表学报, 2019, 40(3): 62-73.
DAI T F, LIU M, YE Y Y, et al. Application and development of human-machine shared control robot system [J]. Chinese Journal of Scientific Instrument, 2019, 40(3): 62-73.
- [7] MARTINEZ-HERNANDEZ U, DODD T J, PRESCOTT T J. Feeling the shape: Active exploration behaviors for object recognition with a robotic hand [J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2018, 48(12): 2339-2348.
- [8] 刘作军,高新智,赵晓东,等. 下肢假肢穿戴者跑动步态识别与膝关节控制策略研究[J]. 仪器仪表学报, 2018, 39(7): 74-82.
LIU Z J, GAO X ZH, ZHAO X D, et al. Research on running gait recognition and motion control strategy for lower limb prosthesis wearer [J]. Chinese Journal of Scientific Instrument, 2018, 39(7): 74-82.
- [9] 郑悦,景晓蓓,李光林. 人机智能协同在医疗康复机器人领域的应用[J]. 仪器仪表学报, 2017, 38(10): 2373-2380.
ZHENG Y, JING X B, LI G L. Application of human-machine intelligence synergy in the field of medical and rehabilitation robot [J]. Chinese Journal of Scientific Instrument, 2017, 38(10): 2373-2380.
- [10] 江晋剑,胡桂姬,苏亮亮,等. 基于步态触觉压力极值点的身份识别方法[J]. 电子测量与仪器学报, 2018, 32(8): 83-88.
JIANG J J, HU G J, SU L L, et al. Identification method based on gait haptic pressure extreme points [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(8): 83-88.
- [11] HUANG H, ZHANG F, HARGROVE L J, et al. Continuous locomotion-mode identification for prosthetic legs based on neuromuscular-mechanical fusion [J]. IEEE Transactions on Biomedical Engineering, 2011, 58(10): 2867-2875.
- [12] ZHOU H, JI N, OLUWAROTIMI W, et al. Towards real-time detection of gait events on different terrains using time-frequency analysis and peak heuristics algorithm [J]. Sensors, 2016, 16(10): 1634.
- [13] LEDOUX E D. Inertial sensing for gait event detection and transfemoral prosthesis control strategy [J]. IEEE Transactions on Biomedical Engineering, 2018, 65(12): 2704-2712.
- [14] MARTINEZ-HERNANDEZA U, DEGHANI-SANIJ A A. Adaptive Bayesian inference system for recognition of walking activities and prediction of gait events using wearable sensors [J]. Neural Networks, 2018, 102(2): 107-119.
- [15] MARTINEZ-HERNANDEZA U, RUBIO-SOLIS A, DEGHANI-SANIJ A A. Recognition of walking activity and prediction of gait periods with a CNN and first-order MC strategy [C]. 7th IEEE International Conference on Biomedical Robotics and Biomechanics, 2018: 897-902.
- [16] 郭英,刘清华,姬现磊,等. 基于手机加速度计的行人步态分析[J]. 中国惯性技术学报, 2017, 25(6): 708-712.
GUO Y, LIU Q H, JI X L, et al. Pedestrian gait analysis based on mobile phone accelerometer [J]. Journal of Chinese Inertial Technology, 2017, 25(6): 708-712.
- [17] PERRY J, THOROFARE K S, DAVIDS J R. Gait

- analysis: Normal and pathological function[J]. Journal of Pediatric Orthopaedics, 1992, 12(6):815.
- [18] 刘宇,向高军,路永乐,等. 基于可穿戴式 MIMU 的个人导航修正算法[J]. 中国惯性技术学报, 2018, 26(6): 732-736,746.
LIU Y, XIANG G J, LU Y L, et al. Personal navigation correction algorithm based on wearable MIMU[J]. JAMA The Journal of the American Medical Association, 2018, 26(6): 732-736,746.
- [19] XU P Y, SARIKAYA R. Contextual domain classification in spoken language understanding systems using recurrent neural network [C]. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2014: 136-140.
- [20] 黄忠,任福继,胡敏,等. 基于双 LSTM 融合的人类机器人实时表情再现方法[J]. 机器人, 2019, 41(2): 137-146.
HUANG ZH, REN F J, HU M, et al. A real-time expression mimicking method for humanoid robot based on dual LSTM fusion [J]. Robot, 2019, 41(2): 137-146.
- [21] 惠文珊,李会军,陈萌,等. 基于 CNN-LSTM 的机器人触觉识别与自适应抓取控制[J]. 仪器仪表学报, 2019, 40(1): 211-218.
HUI W SH, LI H J, CHEN M, et al. Robotic tactile recognition and adaptive grasping control based on CNN-LSTM [J]. Chinese Journal of Scientific Instrument, 2019, 40(1): 211-218.
- [22] XUE W D, CHAI Y, LI Q G, et al. Short-term relay quality prediction algorithm based on long and short-term memory[J]. Instrumentation, 2018, 5(4): 46-54.
- [23] 陈怀宇,尹达一,张泉. LSTM 网络提高 MEMS 惯导定位精度的分析及验证[J]. 中国惯性技术学报, 2018, 26(5): 610-615.
CHEN H Y, YIN D Y, ZHANG Q. Analysis and verification on improving MEMS navigation accuracy based on LSTM network[J]. Journal of Chinese Inertial Technology, 2018, 26(5): 610-615.
- [24] 魏昱洲,许西宁. 基于 LSTM 长短期记忆网络的超短期风速预测[J]. 电子测量与仪器学报, 2019, 33(2): 64-71.
WEI Y ZH, XU X N. Ultra-short-term wind speed prediction model using LSTM networks [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(2): 64-71.
- [25] UDDIN M Z. A wearable sensor-based activity prediction system to facilitate edge computing in smart healthcare system [J]. Journal of Parallel and Distributed Computing, 2019, 123: 46-53.

作者简介



张金艺

E-mail: zhangjinyi@shu.edu.cn

Zhang Jinyi (Corresponding author) received his B. Sc. degree from Shanghai Tech University in 1987, received his M. Sc. and Ph. D. degrees both from Shanghai University in 2003 and 2009, respectively. Now, he is a research fellow in Shanghai University. His main research interests include researches on the key technologies targeting to companion robots and communication SoC design.



秦政

秦政, 2017 年于上海大学获得学士学位, 现为上海大学硕士研究生, 主要研究方向为面向伴随型机器人的步态时相检测、人类活动识别、步态识别。
E-mail: 18721018720@163.com

Qin Zheng received his B. Sc. degree from Shanghai University in 2017. Now, he is a M. Sc. candidate in Shanghai University. His main research interests include gait phase detection targeting to companion robots, human activity recognition and gait recognition.