

文章编号: 1006-3080(2025)01-0110-09

DOI: 10.14135/j.cnki.1006-3080.20240229001

基于通道注意力机制增强 DGNN 的外骨骼机器人 步态相位预测

颜建军¹, 许赢家¹, 林越¹, 金理², 江金林²

(1. 华东理工大学机械与动力工程学院, 上海 200237; 2. 上海航天控制技术研究所, 上海 200235)

摘要:利用一种基于通道注意力机制增强的有向图神经网络(Channel Attention Enhanced Directed Graph Neural Network, CA-DGNN)的外骨骼机器人步态相位预测方法,提高了步态相位预测的准确性和可靠性。首先,研制了人体下肢姿态信息采集装置,采集人体下肢的行走步态数据并构建人体下肢的骨架模型;之后,建立了基于CA-DGNN步态相位的预测模型,提取人体步态相位的运动特征,并基于当前时刻数据预测未来时刻的步态相位;最后,探讨了滑动窗口大小对算法性能的影响。本文提高了外骨骼机器人步态相位预测的准确性和鲁棒性,为此方向研究提供了一种新的思路和方法。

关键词:步态相位预测;惯性传感器;骨架;时空图卷积网络;通道注意力机制

中图分类号:TP391.4

文献标志码:A

外骨骼机器人是一种可以穿戴行走式的机械设备,它可以减轻人类的负重,起到支撑、保护、运动等作用,广泛应用于医疗、农业、工业、军事等领域,已经成为未来科技发展的趋势。按用途不同,外骨骼机器人可以分为助力型^[1-2]、负重型^[3-4]和康复型^[5-6]机器人3类。本文主要探讨了基于下肢助力型的外骨骼机器人,其能够通过人体下肢关节处提供适当的外部辅助力矩来提高人体的运动能力^[7],识别并预测穿戴者的运动意图是外骨骼机器人辅助人类运动的前提和基本要求,根据感知到的人类意图从而有效控制外骨骼的运动^[8]。因此,必须首先估计人类的行走意图,以确保外骨骼机器人不会阻碍人类的运动^[9-10]。

人体行走过程是一个持续且规律的周期性运动。目前最常用的步态周期研究方法依赖于四相识别技术,由脚跟着地(HS)、脚尖着地(TS)、脚跟离地(TO)和摆动相中点(SM)表示。基于当前步态研究阶段,使用一系列可穿戴传感器,包括脚踏开关、

压力鞋垫和惯性传感器,在步态阶段检测方面进行了广泛的研究^[11-13]。

常用的步态相位检测分类算法可分为三大类:阈值方法(Threshold-Based Methods, TBM)、机器学习方法(Machine Learning Methods, MLM)和深度学习(Deep Learning, DP)。阈值方法通过手动设置阈值,观察原始数据的特征,并根据这些特征将步态阶段进行分类^[14]。Kim等^[15]提出了一种基于惯性测量单元(Inertial Measurement Unit, IMU)的脚-地接触检测(Foot-Ground Contact Detection, FGCD)算法。Bejarano等^[11]提出了一种基于惯性和磁性传感器的自适应算法,用于检测步态事件,这种算法在健康人和步态病理患者身上都表现出色。Seel等^[16]使用加速度计和陀螺仪传感器,提出了一种实时的步态事件检测方法。与TBM算法相比,数据驱动的机器学习算法性能得到了显著提高,它利用大量的数据来进行分类任务,从而减少了手动创建有意义特征的需求。在步态相位预测应用中,各种机器学习方法

收稿日期: 2024-02-29

基金项目: 国家自然科学基金重大研究计划(91748110)

作者简介: 颜建军(1975—),男,四川营山人,博士,副教授,主要研究方向为外骨骼机器人、智能传感测控、医学信号处理。E-mail: jnyan@ecust.edu.cn

引用本文: 颜建军,许赢家,林越,等.基于通道注意力机制增强 DGNN 的外骨骼机器人步态相位预测[J].华东理工大学学报(自然科学版),2025,51(1): 110-118.

Citation: YAN Jianjun, XU Yingjia, LIN Yue, et al. Gait Phase Prediction of Exoskeleton Robot Enhanced by DGNN Based on Channel Attention Mechanism[J]. Journal of East China University of Science and Technology, 2025, 51(1): 110-118.

如K近邻^[17]、决策树^[18]、贝叶斯网络分类器^[19]、线性判别分析^[20]等都被广泛应用,它们同样适用于区分步态阶段^[21]。深度学习是机器学习领域中一个新的研究方向,在搜索技术、数据挖掘、机器翻译、自然语言处理、多媒体学习、语音、推荐和个性化技术,以及其他相关领域都取得了很多成果。Su等^[22]提出了一种基于IMU和足底压力传感器的深度卷积神经网络(Deep Convolutional Neural Network, DCNN),用于识别步态周期的5个阶段。另外,Wu等^[23]提出了一种用于步态阶段分类的图卷积网络模型(Graph Convolutional Network Model, GCNM),并将其与长短时记忆网络(Long Short-Term Memory, LSTM)和DCNN进行了比较,结果表明GCNM在步态阶段分类方面具有较高的准确性,验证了该模型的有效性。

然而,这些步态相位预测方法没有充分考虑到关节之间的相互联系,也没有充分挖掘时间和空间之间的联系,无法充分表现人体步态相位特征。

在基于视频的动作识别领域,基于时空卷积网络的算法ST-GCN^[24]得到了广泛应用,它能够利用人体骨架信息。现有的基于图的方法通常将骨架表示为无向图,并使用两个独立的网络对骨骼和关节进行建模,但不能充分利用关节和骨骼之间的依赖关系。因此,本文引入基于通道注意力机制增强的有向图神经网络(CA-DGNN)^[25]的外骨骼机器人步态相位预测模型。该方法采用有向非循环图来表示骨架模型,其中关节作为图的顶点,骨骼作为边,可以捕捉关节之间的依赖关系;引入了通道注意力机制,通过对关节的不同通道信息赋予不同的权重来关注重要通道,使模型能在不同的特征空间中聚焦重要信息。同时,在已有下肢外骨骼机器人的基础上研制了一套基于IMU惯性传感器的人体步态运动数据采集设备,通过采集的数据计算得出骨架信息和运动信息,并将其输入到CA-DGNN中,以构建下肢骨架模型并进行下肢外骨骼机器人步态相位预测的研究,探讨了算法参数和部分超参数对步态相位预测性能的影响。

1 方法与数据

1.1 下肢助力外骨骼机器人

本文研究的下肢助力外骨骼机器人,其结构示意图如图1所示,该外骨骼采用刚性的机械支撑结构,在外骨骼机器人的大小腿和腰部安装传感器,采集人体的步态运动信息;在膝关节处布置电机驱动结构,作为外骨骼机器人的关节执行器,在人体运动

时提供相应的助力力矩;在外骨骼的背部安装控制器等组件,采用相应的控制策略,实现外骨骼机器人的实时控制。



图1 下肢助力外骨骼机器人

Fig. 1 Powered lower limb exoskeleton robot

1.2 人体步态信息采集设备

本文构建的人体步态信息采集设备如图2所示。该设备由大小腿和腰部的柔性绑缚结构组成,在大小腿和腰部均布置IMU惯性传感器,用于采集人体大小腿和腰部的运动数据,主要是大小腿和腰部的三轴角度、三轴加速度、三轴角速度,并且在腰部安装有协处理器,通过CAN(Controller area network)总线传输,将数据整合并通过蓝牙发送到手机等移动设备。



图2 人体步态信息采集设备

Fig. 2 Human gait information acquisition equipment

1.3 人体步态数据的获取

传感器的人体坐标系的规定如图3所示,即以人体侧面为基准,平行于人体矢状面运动方向为X轴,重力加速度方向为Y轴,垂直于人体矢状面为Z轴。

本文采用的数据是由本研究团队设计的一套人

体步态信息采集设备采集的运动数据,共邀请了 4 位志愿者进行步态行走的数据采集,采样频率为 100 Hz,单次采集时间为 20 s,每位实验者重复采集 5 次作为一组数据,共采集了 5 组数据,对其分别命名为数据集 1、数据集 2、数据集 3、数据集 4 和数据集 5,其中数据集 1、2、3、4 分别为 4 位不同志愿者的步态数据,数据集 5 与数据集 3 为同一个志愿者的 2 次运动数据(重新进行穿戴)。每个数据集内包括大小腿和腰部的三轴角度、三轴加速度和三轴角速度。




图 3 数据采集示意图:传感器的人体坐标系

Fig. 3 Data acquisition diagram: Human coordinate system of sensor

1.4 基于 CA-DGNN 的步态相位预测

因为骨架提供了关于人体运动的关键信息,通过分析骨架在不同步态相位中的姿态和加速度,可以获得有关步态周期的节奏、速度等重要特征。步态相位预测的主要流程如下:首先进行步态数据的采集,本文邀请 4 位志愿者穿戴人体步态信息采集设

备进行实验,得到行走步态运动数据;建立下肢骨架模型,建立时空图卷积网络;进行超参数实验,确定相应最优窗口大小;最后进行用户独立实验和用户依赖实验,与其他算法进行比较。图 4 显示了骨架及其相应的有向图,把腰部作为点 1,左大小腿分别为点 2 和点 5;右大小腿分别为点 3 和点 4,形成图结构。

为了进一步提高模型在步态预测任务上的准确率,本文在 DGNN 的基础上加以改进,引入了基于通道注意力机制增强的有向图神经网络(CA-DGNN)来进行步态相位的预测。

CA-DGNN 将关节和骨骼信息结合起来并表示为一个有向非循环图(Directed acyclic graph),其中关节作为顶点,骨骼作为边,关节之间的依赖关系通过图的有向边建模,GTCN(Graph temporal convolution network)由 DGN 块(Directed graph network)、TCN 块(Temporal convolution network)和 ECA 块(Efficient channel attention)及若干功能层组成(图 4)。

模型从数据输入到多帧步态相位输出的流程图如图 5 所示。在骨架数据输入后,分别经过 3 个添加了 ECA 模块的 GTCN 操作后,输出张量被输入到全连接层,以获得每个步态的特征向量。在这之后,步态的特征向量通过 Softmax 函数传递到输出层,以获得步态相位类别的预测。最后,将模型预测的不同时间的步态进行组合,得到多帧步态相位输出。本文使用 100 帧数据预测未来 10 帧,即未来 100 ms 的数据。

在 CA-DGNN 中,每个图时间卷积模块后都添加了一个 ECA 模块。ECA 模块通过考虑每个通道及其 k 个邻居进行局部跨通道交互信息,自适应地调

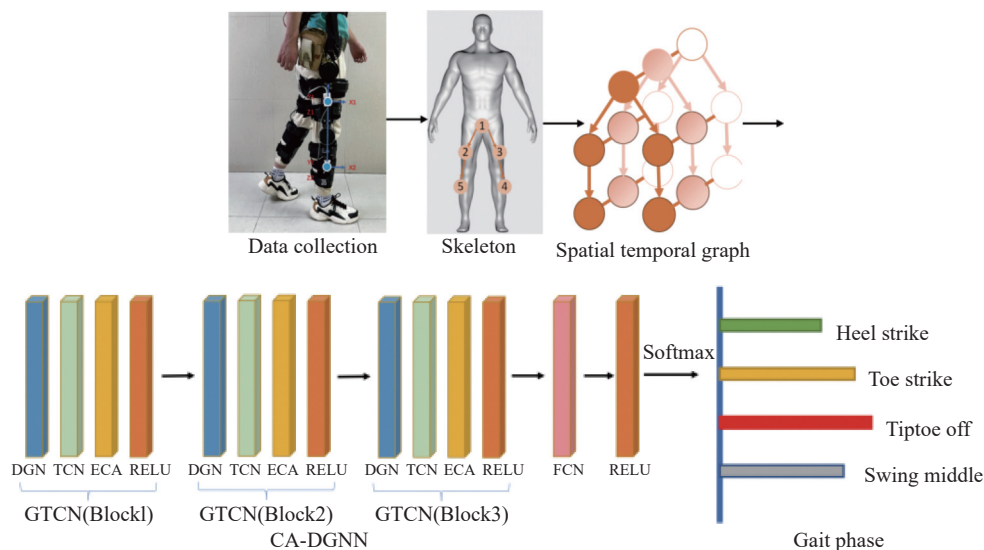


图 4 步态相位预测的流程

Fig. 4 Process of the gait phase prediction

整每个通道的权重,使得模型能够更加关注重要的通道,抑制噪声和无关信息。同时,本文改进了图学习的方法,增加了对有向非循环图进行稀疏化的操作,抑制了相关性较低的连接形成。

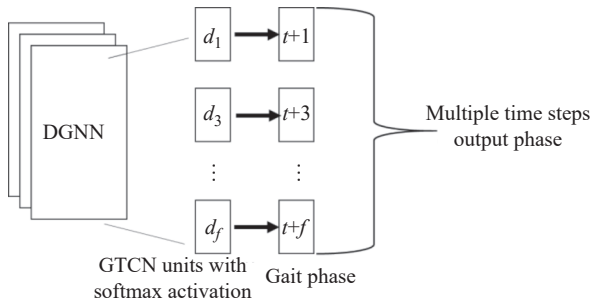


图5 CA-DGNN的多帧步态相位预测

Fig. 5 Multi-frame gait phase prediction of CA-DGNN

2 实验结果

本文将上述人体步行步态运动数据关节角度、加速度、角速度进行数据平滑处理,进行了窗口大小对算法性能影响的实验,分别运用CNN、RNN^[26]、TCN^[27]、LSTM^[28]这4种时间序列算法以及基于骨架的DGNN算法进行实验,最终与CA-DGNN进行比较,证明CA-DGNN算法在步态相位预测上的优越性。

训练参数设置为:学习率为0.001,批量大小为32,优化器选择Adam,迭代次数为150次,丢弃率为0.3,权重衰减系数为 10^{-4} ,学习率容忍次数为4。除了常规的超参数设置外,还设置了图学习冻结步数为5,用于保证训练开始的前5次迭代中初始图不进行更新。

2.1 窗口大小的实验

在数据加窗时,窗口的大小对结果的影响如表1所示。本实验所使用的传感器采样频率为100 Hz,正常人走路1 min大约在100~120步,一个步态周期为1 s左右,分别设置窗口大小为80、90、100、110、120、130、140、150、160、170和180,窗口间隔设置为1保持不变,使用数据集3作为训练集、数据集5作为测试集。实验将90%的数据用于训练、10%的数据用于验证,每次均进行100轮训练,设置学习率为0.001。

由表1可以看出,不同的窗口大小也会影响CA-DGNN的性能,当窗口大小为100时表现最好,准确率为97.86%;当窗口大小为120时表现最差,准确率为95.25%。窗口大小为100的准确率比窗口大小为80、90、110、120、130、140、150、160、170

表1 不同窗口大小的实验结果

Window size	Accuracy/%	Precision/%	Recall/%	F1_score/%
80	97.02	95.69	95.60	95.57
90	97.26	96.39	96.14	96.18
100	97.86	97.59	96.66	97.08
110	95.74	95.49	93.17	94.09
120	95.25	95.41	90.30	92.06
130	96.29	95.86	93.19	94.21
140	96.59	96.32	94.56	95.27
150	96.81	95.97	94.64	95.17
160	95.41	94.16	92.38	92.95
170	96.08	96.36	93.23	94.40
180	96.30	96.15	93.21	94.32

和180时分别提高了0.84%、0.60%、2.12%、2.61%、1.57%、1.27%、1.05%、1.78%、1.56%和1.35%。

2.2 用户独立实验

由于CA-DGNN算法以骨架数据作为输入,而其他算法为数据驱动,因此在实验中,本节将原始三轴角度、三轴加速度和三轴角速度作为CNN、RNN、TCN和LSTM这4种算法的输入,将关节坐标作为CA-DGNN的输入,并进行比较,以证明CA-DGNN算法在步态相位预测上的优越性。使用数据集1、2、3作为训练集、数据集4作为测试集,Window size设置为100,用户独立实验结果如表2所示。由表2可知,在5种算法中,CA-DGNN算法的准确率比CNN、RNN、TCN、LSTM和DGNN分别提高了3.27%、5.29%、3.34%、2.69%、1.27%。

表2 用户独立实验结果

Algorithm	Accuracy/%
CNN	91.25
RNN	89.23
TCN	91.18
LSTM	91.83
CA-DGNN	94.52

2.3 用户依赖实验

使用数据集3作为训练集、数据集5作为测试集,进行用户依赖实验,将CA-DGNN算法与其他4种算法进行比较,结果如表3所示。

由表3可知,在5种算法中,CA-DGNN算法的

准确率比 CNN、RNN、TCN、LSTM 分别提高了 2.72%、8.21%、18.09%、3.51%。

表 3 用户依赖实验结果

Table 3 Results of user-dependent experiment

Algorithm	Accuracy/%	Precision/%	Recall/%	F1-Score/%
CNN	95.14	93.57	93.06	93.29
RNN	89.65	88.05	88.77	88.39
TCN	79.77	72.48	78.54	73.82
LSTM	94.35	90.24	95.25	92.06
CA-DGNN	97.86	97.33	97.13	97.15

2.4 消融实验

使用数据集 3 作为训练集、数据集 5 作为测试集,进行消融实验,使用 DGNN 算法与 CA-DGNN 算法进行比较,结果如表 4 所示。

表 4 消融实验结果

Table 4 Results of ablation experiment

Algorithm	Accuracy/%	Precision/%	Recall/%	F1-Score/%
DGNN	96.43	95.27	94.59	94.77
CA-DGNN	97.86	97.33	97.13	97.15

由表 4 可知,在消融实验中,CA-DGNN 算法相比 DGNN 算法在准确率、精确率、召回率和 F1 值上同时有显著提升,分别提高了 1.43%、2.06%、2.54%、2.38%。为了进一步验证提出算法的实用性,将穿戴人体步态信息采集设备采集的步态数据实时输入到训练的 CA-DGNN 模型,进一步进行实验验证,预测准确率达到 93.28%。

3 讨论

3.1 窗口大小的影响

不同的窗口大小会影响 CA-DGNN 算法的性能。为进一步分析窗口大小对步态相位预测平均准确率的影响,计算了不同窗口大小下各步态相位预测准确率,如图 6 所示。可以看出,在改变窗口大小的过程中,TO 相位一直保持着较高的准确率,一般在 99% 以上,其基本不受窗口大小改变的影响。而 HS、TS 这两个步态相位识别准确率低,分别为 95.72% 和 92.10%。SM 相位受窗口改变影响比较大,其最高准确率为 94.16%,最低准确率为 70.17%。但就准确率而言,CA-DGNN 算法的性能受窗口大小这一超参数的影响不是很大,步态模型具有较强的鲁棒性,在实际使用中可以减少为不同数据寻找合适窗口大小的计算量。

窗口大小为 80 和 100 时 CA-DGNN 的混淆矩阵如图 7 所示。窗口大小为 80 时步态相位预测准确率稍低一些,比窗口大小为 100 的准确率低了 0.84%。根据图 6 所示,窗口大小改变时,SM 相位准确率受影响变化最大,故在考虑最佳窗口大小时,应该从准确率和 SM 相位准确率两个方面综合考虑。窗口大小分别为 80 和 100 时,前者在 HS、TO 相位上准确率和后者相近,但 TS、SM 相位准确率却低于后者,尤其是受窗口大小影响最大的 SM 相位,后者平均准确率比前者高了 4.67%。

总体来说,窗口大小为 100 时准确率达到最高,并且各个步态相位的识别准确率都位居前列,尤其是受窗口大小影响最大的 SM 相位。窗口大小改善了误识别情况,并且该模型拥有较强的鲁棒性,在实际使用中拥有更强的普适性。




图 6 不同窗口大小的步态相位预测准确率

Fig. 6 Gait phase prediction accuracy of different window size

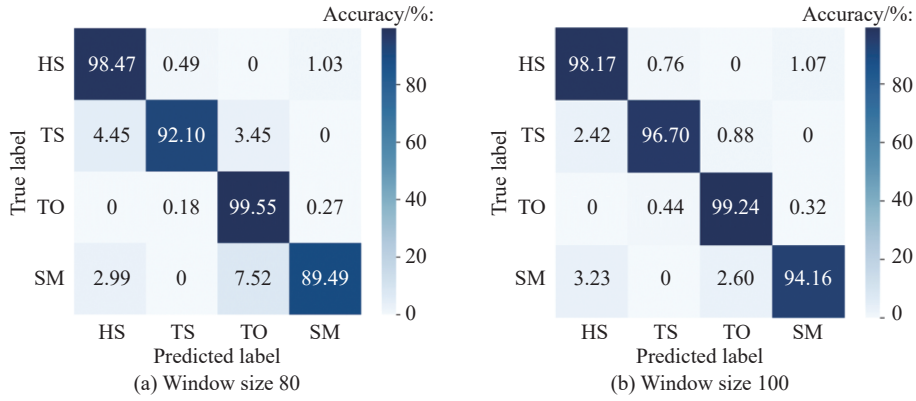


图 7 不同窗口大小的 CA-DGNN 混淆矩阵

Fig. 7 CA-DGNN confusion matrices of different window size

3.2 用户独立实验的结果分析

在用户独立实验中 CA-DGNN 在 6 种算法中表现最好, 识别准确率达到 94.52%。为了进一步分析各算法的性能, 计算了各步态相位预测准确率, 如图 8 所示。CA-DGNN 在大多数步态相位预测准确率上都比其他 5 个算法高, 最低准确率也在 85.66% 左右, 其他算法最低准确率甚至只有 61.68%。CA-DGNN 在 TS 和 SM 准确率分别为 98.34% 和 85.66%; HS 和 TO 准确率分别为 94.22% 和 95.21%, 虽然并非最佳, 但也达到了平均水准。在 SM 相位上, 其他 5 种算法准确率都不超过 70%, 而 CA-DGNN 算法准确率高达 85.66%; 在 TO 和 HS 相位上, CA-DGNN 准确率也在 94% 以上; 这说明 CA-DGNN 在步态相位分类上的表现优于其他算法, 其高准确率和稳定性更适于步态相位预测。

对 CA-DGNN 的实验结果进一步分析, 其混淆矩阵如图 9 所示。CA-DGNN 对 HS、TS 和 TO 3 种步态相位预测准确率较高, 但还是出现了 SM 步态相位的误识别率较高的情况, 如把 SM 识别为 TO 的误识别率为 8.05%, 把 SM 识别为 HS 的误识别率为 6.29%。

由于所使用数据为三轴加速度和三轴角速度的下肢矢状面运动角度, 在实际运动过程中, 腿部的运动特征相差不是很大, 差别较大的主要是踝关节数据, 而踝关节数据并没有采集, 因此出现了这几个步态相位之间的误识别, 导致准确率降低。但在使用同样数据的情况下, 各算法识别准确率也有差别, 说明模型本身的特性也是影响步态相位预测性能的重要因素。

3.3 用户依赖实验的结果分析

前述通过用户独立实验建立步态相位预测用户依赖实验, 并且获得了较好的结果。虽然通用模型可以减少训练过程中所需的时间, 但通用模型可能

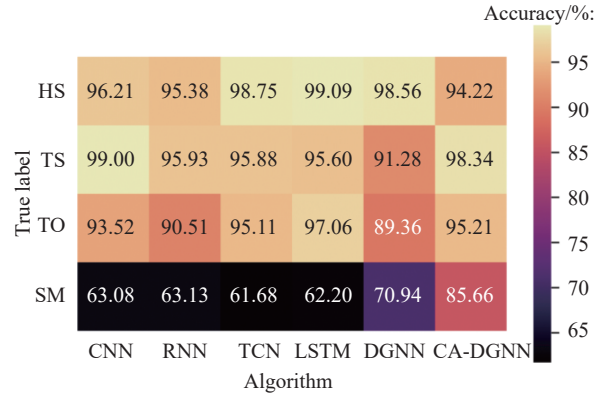


图 8 用户独立实验中不同算法的步态相位预测准确率

Fig. 8 Gait phase prediction accuracy of different algorithms in user-independent experiment

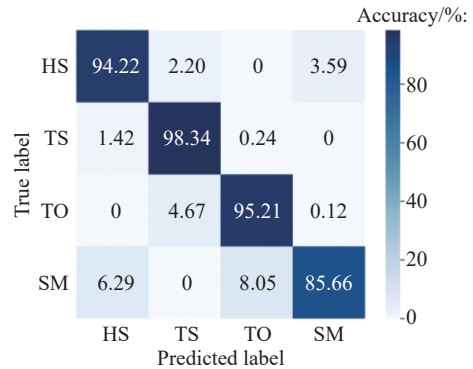


图 9 用户独立实验中的步态相位预测混淆矩阵

Fig. 9 Confusion matrix of gait phase prediction in user-independent experiment

不适用于特定个体。因此进行用户依赖实验, 将使用者数据加入模型进行训练, 以进一步提高步态识别的准确率。各算法的不同步态相位预测准确率如图 10 所示。由图可得, CA-DGNN 在 HS、TO、SM 这 3 个步态相位上准确率分别为 98.17%、99.24%、94.16%; 在 TS 步态相位上准确率为 96.70%, 对比最好的 97.73% 仅相差 1.03%。CA-DGNN 方法中各步态的识别准确率都不小于 94.16%, 而其他算法最低

识别准确率甚至只有 71.99%。这说明 CA-DGNN 在步态相位预测上表现良好, 优于其他几种算法。

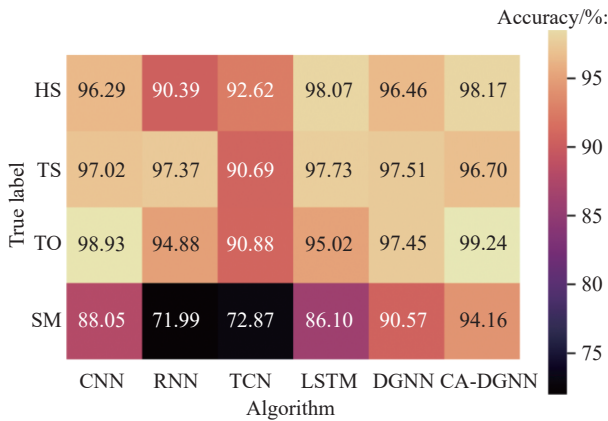


图 10 用户依赖实验中不同算法的步态相位预测准确率
Fig. 10 Gait phase prediction accuracy of different algorithms in user-dependent experiment

CA-DGNN 的混淆矩阵如图 11 所示, 用户依赖实验中 CA-DGNN 对 4 种步态相位预测准确率均很高, 最低也在 94.16%, 比前述用户独立实验效果要好, 并且更加稳定, 鲁棒性更强。但也同样面临前述的问题, 出现了步态相位的误识别情况, 但基本不超过 3%。结果说明 CA-DGNN 相比其他 4 种算法在步态相位预测上都具有更高的准确性和稳定性。




图 11 用户依赖实验中的步态相位预测混淆矩阵
Fig. 11 Confusion matrix of gait phase prediction in user-dependent experiment

大多数分析时间序列的 DL 算法(如 RNN、LSTM、TCN)主要关注时间特征, 它们学习空间特征的能力相对较弱。这些深度学习算法鲜有明确考虑骨架和相邻关节之间的空间连通性、依赖关系和图形结构。因此, 它们在理解人体行走所表达的步态相位方面能力相对有限, 这导致其在步态相位预测的整体表现不如 CA-DGNN。

3.4 穿戴实验的结果分析

在处理人体步态这种具有多维和复杂的时间依赖性数据时, CA-DGNN 相比于 DGNN, 通过关注通

道间的空间依赖关系, 自动地学习通道的重要性, 能够更好地理解不同的步态相位模式, 有助于提高模型的分类准确率。实际穿戴实验的结果也能进一步验证 CA-DGNN 在步态相位预测上的实用性。为测试 CA-DGNN 算法的实用性, 测试人员穿戴运动数据采集装备进行行走, 同时使用 CA-DGNN 进行实时步态相位预测。同时记录每个时刻的步态相位和模型预测结果, 在测试结束后进行结果分析。实际穿戴运动数据采集设备后行走的实时步态相位预测结果的混淆矩阵如图 12 所示。根据实验结果和混淆矩阵, 在处理实时步态数据方面, CA-DGNN 虽然受到噪声干扰, 但仍保持 93.28% 的准确率。4 种步态相位中 HS、TS、SM 都保持 91% 以上的准确率, 只有 TO 相位识别准确率有较大下降。穿戴设备的实时相位预测准确率仍保持较高的水平, 证明 CA-DGNN 有较强的准确率和鲁棒性, 对后续外骨骼助力的研究有实用意义。

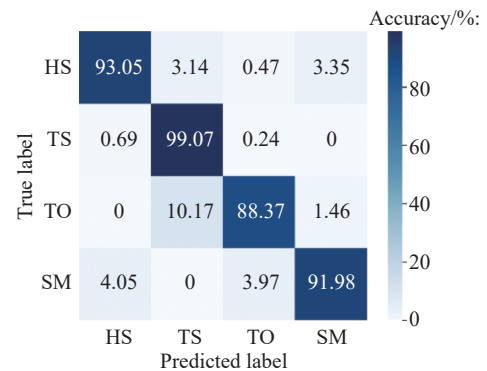


图 12 实时相位预测混淆矩阵
Fig. 12 Real-time phase prediction confusion matrix

4 结束语

在本研究中, 引入了一种使用 CA-DGNN 的基于多惯性传感器的骨架步态相位检测方法。首先, 提取人体 5 个关节上 IMU 的运动数据, 并对其进行了加窗; 其次, 根据人体关节之间的自然连接关系, 建立了步态相位预测的骨架模型; 然后, 使用空间图卷积层和时间卷积层分别在空间和时间尺度上提取人体步态相位的动态特征, 从而更全面地挖掘人类行走步态的空间和时间模式; 最后, 建立了基于 CA-DGNN 和骨架的步态相位预测模型, 讨论了参数对模型性能的影响, 并将实验结果与其他 5 种算法的结果进行了比较。实验结果表明, CA-DGNN 模型具有更好的准确性和鲁棒性, 优于其他 5 种算法。本研究旨在为基于 IMU 的步态相位预测提供了一种新方法。

参考文献:

- [1] WALSH C, PALUSKA D, PASCH K, *et al.* Development of a lightweight, underactuated exoskeleton for load-carrying augmentation[C]// Proceedings 2006 IEEE International Conference on Robotics and Automation. Orlando, FL, USA: IEEE, 2006: 3485-3491.
- [2] WALSH C, ENDO K, HERR H. A quasi-passive leg exoskeleton for load-carrying augmentation[J]. *International Journal of Humanoid Robotics*, 2007, 4(3): 487-506.
- [3] LG to usher in new era of AI robotics with wearable robot [EB/OL]. (2018-08-29) [2024-02-29]. <http://www.lgnewsroom.com/2018/08/lg-to-usher-in-new-era-of-ai-robotics-with-wearable-robot/>.
- [4] LOCKHEED M. Lockheed Martin partners with Deakin University to further develop industrial exoskeleton [EB/OL]. (2018-09-05) [2024-02-29]. <https://news.lockheedmartin.com/2018-09-05-Lockheed-Martin-Partners-with-Deakin-University-to-Further-Develop-Industrial-Exoskeleton?linkId=100000003411667>.
- [5] STRAUSSER K A, KAZEROONI H. The development and testing of a human machine interface for a mobile medical exoskeleton[C]//2011 IEEE/RSJ International Conference on Intelligent Robots and Systems. San Francisco, CA, USA: IEEE, 2011: 4911-4916.
- [6] WANG S, WANG L, MEIJNEKE C, *et al.* Design and control of the MINDWALKER exoskeleton[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2014, 23(2): 277-286.
- [7] DOLLAR A M, HERR H. Lower extremity exoskeletons and active orthoses: Challenges and state-of-the-art[J]. *IEEE Transactions on Robotics*, 2008, 24(1): 144-158.
- [8] KYEONG S, SHIN W, YANG M, *et al.* Recognition of walking environments and gait period by surface electromyography[J]. *Frontiers of Information Technology & Electronic Engineering*, 2019, 20(3): 342-352.
- [9] QIU S, GUO W, CALDWELL D, *et al.* Exoskeleton online learning and estimation of human walking intention based on dynamical movement primitives[J]. *IEEE Transactions on Cognitive and Developmental Systems*, 2020, 13(1): 67-79.
- [10] LEE T, KIM I, LEE S H. Estimation of the continuous walking angle of knee and ankle (talocrural joint, subtalar joint) of a lower-limb exoskeleton robot using a neural network[J]. *Sensors*, 2021, 21(8): 2807.
- [11] BEJARANO N C, AMBROSINI E, PEDROCCHI A, *et al.* A novel adaptive, real-time algorithm to detect gait events from wearable sensors[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2014, 23(3): 413-422.
- [12] QI Y, SOH C B, GUNAWAN E, *et al.* Assessment of foot trajectory for human gait phase detection using wireless ultrasonic sensor network[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2015, 24(1): 88-97.
- [13] SEEL T, RAISCH J, SCHAUER T. IMU-based joint angle measurement for gait analysis[J]. *Sensors*, 2014, 14(4): 6891-6909.
- [14] DING Z, YANG C, XING K, *et al.* The real time gait phase detection based on long short-term memory[C]//2018 IEEE Third International Conference on Data Science in Cyber-space (DSC). Guangzhou, China: IEEE, 2018: 33-38.
- [15] KIM M, LEE D. Development of an IMU-based foot-ground contact detection (FGCD) algorithm[J]. *Ergonomics*, 2017, 60(3): 384-403.
- [16] SEEL T, LANDGRAF L, SCHAUER T. Online gait phase detection with automatic adaption to gait velocity changes using accelerometers and gyroscopes[J]. *Biomedical Technology*, 2014, 59(s1): S795-S798.
- [17] DERLATKA M, BOGDAN M. Ensemble kNN classifiers for human gait recognition based on ground reaction forces[C]//2015 8th International Conference on Human System Interaction (HSI). Warsaw, Poland: IEEE, 2015: 88-93.
- [18] DERLATKA M, IHNATOUSKI M. Decision tree approach to rules extraction for human gait analysis[C]// Artificial Intelligence and Soft Computing: 10th International Conference, ICAISC. Zakopane, Poland: Artificial Intelligence and Soft Computing, 2010: 597-604.
- [19] MARTINEZ-HERNANDEZ U, MAHMOOD I, DEGHANI-SANIJ A A. Simultaneous Bayesian recognition of locomotion and gait phases with wearable sensors[J]. *IEEE Sensors Journal*, 2017, 18(3): 1282-1290.
- [20] LEE M, ROAN M, SMITH B, *et al.* Gait analysis to classify external load conditions using linear discriminant analysis[J]. *Human Movement Science*, 2009, 28(2): 226-235.
- [21] RUETERBORIES J, SPAICH E G, LARSEN B, *et al.* Methods for gait event detection and analysis in ambulatory systems[J]. *Medical Engineering & Physics*, 2010, 32(6): 545-552.
- [22] SU B, SMITH C, GUTIERREZ FAREWIK E. Gait phase recognition using deep convolutional neural network with inertial measurement units[J]. *Biosensors*, 2020, 10(9): 109.
- [23] WU X, YUAN Y, ZHANG X, *et al.* Gait phase classification for a lower limb exoskeleton system based on a graph convolutional network model[J]. *IEEE Transactions on Industrial Electronics*, 2021, 69(5): 4999-5008.
- [24] YAN S, XIONG Y, LIN D. Spatial temporal graph convolutional networks for skeleton-based action recognition [C]//Proceedings of the AAAI conference on artificial intel-

- ligence. New Orleans, Louisiana, USA: AAAI, 2018, 32(1): 7444-7452.
- [25] SHI L, ZHANG Y, CHENG J, *et al.* Skeleton-based action recognition with directed graph neural networks[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Long Beach, CA, USA: IEEE, 2019: 7904-7913.
- [26] ELMAN J L. Finding structure in time[J]. *Cognitive Science*, 1990, 14(2): 179-211.
- [27] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[J]. (2018-08-13) [2019-06-22]. [https://arXiv preprint arXiv: 1803.01271](https://arxiv.org/abs/1803.01271), 2018.
- [28] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.

Gait Phase Prediction of Exoskeleton Robot Enhanced by DGNN Based on Channel Attention Mechanism

YAN Jianjun¹, XU Yingjia¹, LIN Yue¹, JIN Li², JIANG Jinlin²

(1. School of Mechanical and Power Engineering, East China University of Science and Technology, Shanghai 200237, China; 2. Shanghai Aerospace Control Technology Institute, Shanghai 200235, China)

Abstract: Gait phase prediction holds significant importance in the control of assistive robotic devices, such as exoskeletons. The control unit is required to discern the gait phase to supply the necessary power during operation. Given that current gait phase prediction methods based on the Inertial Measurement Unit (IMU) do not fully leverage the relationship between joints and bones, this study presents a gait phase prediction approach for an exoskeleton robot using a Channel Attention-enhanced Directed Graph Neural Network (CA-DGNN) to enhance prediction accuracy and reliability. Initially, a device for collecting human lower limb posture information is developed to gather walking gait data and construct a skeleton model of the lower limbs. Subsequently, a gait phase prediction model based on CA-DGNN is established to extract motion characteristics of human gait phases and predict the gait phase at a future moment based on current data. Lastly, the impact of the sliding window size on the algorithm's performance is analyzed. The experimental results show that compared to other algorithms, the prediction accuracy of CA-DGNN is 97.88%, which is better than other four algorithms such as CNN, RNN, TCN and LSTM. This work aims to present an innovative idea and method for gait phase prediction in exoskeleton robots, thereby advancing the accuracy and robustness in such robotic systems.

Key words: gait phase prediction; IMU; skeleton; spatial temporal graph convolutional networks; channel attention mechanism

(责任编辑: 王晓丽)