

引文格式:向勉,易本顺,周丙涛,等.利用惯性传感器与多模态网络解析跑步参数[J].武汉大学学报(信息科学版),2024,49(7):1079-1087.DOI:10.13203/j.whugis20220229



Citation: XIANG Mian, YI Benshun, ZHOU Bingtao, et al. Analysis of Running Parameters Using IMU and Multi-modal Network[J]. Geomatics and Information Science of Wuhan University, 2024, 49(7):1079-1087.DOI:10.13203/j.whugis20220229

# 利用惯性传感器与多模态网络解析跑步参数

向勉<sup>1</sup> 易本顺<sup>2</sup> 周丙涛<sup>1</sup> 谭建军<sup>1</sup> 朱黎<sup>1</sup>

1 湖北民族大学智能科学与工程学院,湖北 恩施,445000

2 武汉大学电子信息学院,湖北 武汉,430072

**摘要:**实时检测跑步时的速度与步幅在避免运动者受伤、提升运动效率上有着重要意义。提出了一种利用惯性测量单元(inertial measurement unit, IMU)来检测这两个指标的方法。首先,招募了10名志愿者,并将3个IMU模块安置在足部、小腿、大腿处,采集了5137个步态周期的数据;然后,利用主成分分析法分析数据,结合皮尔逊相关系数探讨了速度步幅与传感器位置、物理参数之间的关系;提出了一种多模态架构的长短期记忆特征提取网络(multi-modal-attention-long short-term memory, M-Att-LSTM),利用两个引入注意力机制的长短期记忆网络(att-long short-term memory, Att-LSTM)对加速度和角度变化分别做特征提取,最后进行回归拟合。实验结果表明,M-Att-LSTM在速度上误差为0.058 m/s,标准偏差为0.013 m/s,而在步幅上误差为0.023 m,标准偏差为0.022 m,两项指标都优于单纯的Att-LSTM。

**关键词:**惯性传感器;主成分分析;皮尔逊系数;长短期记忆网络;多模态

中图分类号:P237

文献标识码:A

收稿日期:2023-06-24

DOI:10.13203/j.whugis20220229

文章编号:1671-8860(2024)07-1079-09

## Analysis of Running Parameters Using IMU and Multi-modal Network

XIANG Mian<sup>1</sup> YI Benshun<sup>2</sup> ZHOU Bingtao<sup>1</sup> TAN Jianjun<sup>1</sup> ZHU Li<sup>1</sup>

1 School of Intelligent Science and Engineering, Hubei Minzu University, Enshi 445000, China

2 School of Electronic Information, Wuhan University, Wuhan 430072, China

**Abstract:** Objectives: Real-time measurement of running speed and stride length is of great significance in avoiding injury and improving exercise efficiency. Methods: We propose a method using inertial measurement unit (IMU) to detect these two indicators. First, 3 IMU are placed on the foot, calf and thigh of the 10 runners which we recruited, and 5 137 data of gait cycles are collected. Second, principal component analysis is used to analyze the data, and Pearson correlation coefficient is used to discuss the relationship between the detection indicators of running and the sensor position and physical parameters. Then a multi-modal attention-long short-term memory (M-Att-LSTM) is proposed for feature extraction, two long short-term memory (LSTM) modules with attention mechanism are used to extract features of acceleration and angle, and regression fitting is carried out. Results: The experiment result shows that M-Att-LSTM has errors of 0.058 m/s in speed and 0.023 m in stride, the standard deviation is 0.013 m/s and 0.022 m, respectively. Both indicators are better than pure Att-LSTM. Conclusions: The studies show that multi-modal network can improve network processing capabilities, compared with relevant researches in recent years, our study has obvious advantages in error control.

**Key words:** inertial sensor; principal component analysis; Pearson coefficient; long short-term memory networks; multi-modal

**基金项目:**国家自然科学基金(61771188,61961017);2020年湖北省教育厅科学技术研究计划青年人才(Q20201902);恩施州科技局技术支撑类项目(D20220004)。

**第一作者:**向勉,博士,讲师,主要从事信号处理、无线通信的研究。xm@hbmzu.edu.cn

**通讯作者:**易本顺,博士,教授。yibs@whu.edu.cn

随着全民健身的热潮,长跑作为普适性强、廉价的运动,越来越受到人们的青睐。篮球、足球等专业运动员可以通过长跑训练进行体能储备<sup>[1]</sup>,普通人长期进行长跑运动,可以有限地减轻体重,提升心肺功能,降低心血管疾病发生概率<sup>[2]</sup>。而在长跑运动中,最重要的两个运动参数就是速度以及步幅。有研究表明,长跑者跑步过程中速度和步幅的变化对身体机能反应的影响很大<sup>[3]</sup>,大的速度和步幅可以增强心率,有助于心肺功能的提高,而低速和小步幅更多用于伤病恢复或更适合普通人群。对长跑者在跑动过程的速度和步幅进行实时监控可以有效地进行实时调整<sup>[4]</sup>,达到最佳训练效果。

目前,对于人体运动参数和位置信息的获取,主要靠智能穿戴或可携带设备<sup>[5-7]</sup>,而对于下肢运动如慢跑、骑行、步行等相关参数的采集,目前运用较为广泛的有足底压力传感器<sup>[8]</sup>、表面肌电传感器<sup>[9]</sup>和惯性测量单元(inertial measurement unit, IMU)<sup>[10-12]</sup>。足底压力传感器能够很好地反映出足底接触地面时的反作用力,但是对于脚离地的阶段不能反映其特征,而表面肌电传感器目前还存在着受干扰严重、滤波难度大等问题。IMU常常运用在建筑等工业领域<sup>[13]</sup>,而将其使用在人体运动中,能够实时准确地采集出人体运动点的加速度、角度、角速度等运动参数,在体育运动的检测方面应用面广、潜力突出。文献[14]将惯性测量装置放在测试者腿的关节点上,分析腿摆动时的数据,通过深度学习网络进行训练,可对13种运动意图进行分类,最终获得了94.15%的准确率。文献[15]提出了一种基于地形几何的线性矩阵不等式算法,运用IMU模块估计足部轨迹来推导出倾斜坡度,其在平地行走、上坡、下坡、下楼梯和上楼梯5种运动模式下分类准确率达到了98.5%。文献[16]采用IMU模块实时预测一名骨集成经股截肢者的运动和过渡意图,将采集到的数据输入递归神经网络进行分类,实现7种不同运动模式(坐、站、平地行走、上下楼梯、坡道上移、下走)的识别。文献[17]也进行了相似的研究,将惯性传感器采集到的数据使用高斯混合模型-隐马尔可夫模型进行处理,在13类运动模式中的识别率可达到96.92%。文献[18]提出了一种基于两阶段人工神经网络的高精度步态相位估计与预测算法,使用只有两个布置在大腿处的IMU传感器,能够实时估计和预测步态类型。以上所列举的研究主要集中于运动

模式的分类,可以证明IMU可以很好地反映出人体运动的规律性。国内外对于IMU模块采集人体运动过程信息也有一些研究成果,例如文献[19]将8个IMU传感器分别安装在双脚、小腿、大腿、髌骨和躯干上,既能够进行步态分类,还能够进行平均步幅时间的预测。文献[20]将IMU放置在下背部,利用倒立摆对行走模式进行建模,然后计算步行、慢跑和跑步的步长,在40 m的实验中,总体平均均方根误差为2.6 m,算法准确率还有待提高。文献[21]同样使用置于下背部的IMU模块研究了步态与年龄的关系。文献[22]提出了一种基于IMU的跨步相位检测方法,使用安装在脚和躯干上的IMU采集的数据提供的对应标签,对两种不同的深度学习结构进行训练,取得了良好效果,但是此方法对于训练集步长数据的采集还有改善的空间。文献[23]使用5个位置来放置可穿戴IMU传感器进行数据采集,对步态中步幅数、距离、速度、步幅长度和周期、姿态和摆动阶段等数据进行分析,取得了良好效果。文献[24]做了相似的研究,通过两个IMU模块提取了17个相关步态特征。文献[25]的方法也很类似,采用足部惯性数据预测出了步幅、步幅长度、步幅频率、步幅速度、垂直高度等步态参数。文献[26]提出了一种基于惯性传感器的足部自适应步长估计算法,精确分析人的步态周期,定量计算出步态,最终在AHRsbox惯性传感器模块得出的步长和行走距离误差均小于2.5%,其计算方法严谨,但是对于不同运动姿态需要进行调整。文献[27]采用了一个放置于脚面的IMU模块,将步态数据采集后输入到单卷积神经网络(convolutional neural networks, CNN)模型来预测跑步和步行的步幅,在跑步实验中平均步幅估计误差约13.48 cm,因此,如果使用更多的IMU模块可以提升准确度。

本文根据以上研究,首先提出了一种测试人体跑步时速度与步长的新方法:使用3个无线IMU模块,分别布置在大腿、小腿、足部上,进行不同速度、不同步长的数据采集,形成一个量大、有效的数据集;然后通过主成分分析与皮尔逊相关系数计算,探讨了相关传感器位置与参数和速度、步幅的关系;最后使用了多模态的长短期记忆网络(long short-term memory, LSTM)进行数据回归预测,实现了人体运动时的速度预测和单步的步长预测。

# 1 数据采集与预处理系统

## 1.1 数据采集系统

人体进行步行、慢跑、跑步时,下肢的运动基本处于矢状面上,而在冠状面和水平面上的位移分量可以忽略不计,如图1所示。而人在进行运动的过程中,下肢主要关节移动可以分为3个部分,分别是脚踝的角度变化、膝关节的角度变化以及髋关节的角度变化,而这3个角度变化带动足部、小腿以及大腿进行矢状面上的平移和旋转。因此,本文专注于矢状面上的下肢移动分量,使用3个九轴IMU模块分别置于大腿中部、小腿中部和足部上。在人体正常站立时,保证模块平行于矢状面且方向一致,x轴方向平行于水平面,y轴垂直于水平面,测试图如图2所示。IMU模块为维特公司(中国)生产的WT901BLE模块,可以提取出运动点的三轴( $x, y, z$ )的加速度、角度、角速度量,通过蓝牙与计算机连接,主要参数见表1。

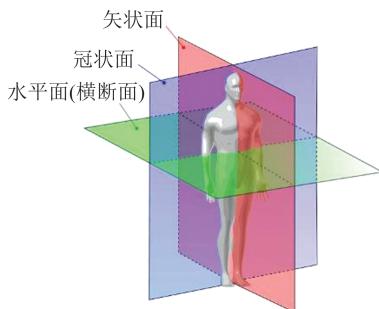


图1 人体解剖学示意图

Fig. 1 Diagram of Human Anatomy

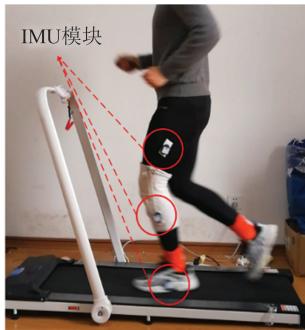


图2 测试示意图

Fig. 2 Diagram of Test

共招募了10名健康状况好、下肢健全的志愿者进行数据采集,参与者的年龄在19~32岁之间,身高在163~181 cm之间,体重在49~89 kg之间。每位志愿者在数据采集前都被介绍了安全预防措施。每位志愿者将带有IMU模块的运动装备进行穿戴,再以不同的速度、步长进行测

试,其中速度的选择参照了一般情况下跑步者的速度区间,为6~12 km/h,1 km/h为一个速度变化梯度,每种速度志愿者要求测试1 min,并且使用不同的步幅。最终采集到一共约490 000条数据。

表1 IMU模块主要参数

Tab. 1 Main Parameters of the IMU Module

指标	标准
尺寸	51.3 mm×36 mm×15 mm
质量/g	21
工作电压/V	3.3~5
量程	加速度:±16g,角速度:±2 000 °/s,角度:±180°
稳定性	加速度:0.01g,角速度0.05 °/s
输出频率/ Hz	0.1~50
数据接口	波特率: 115 200 bit/s

## 1.2 数据分割

本文专注于人体运动时矢状面的分析,根据人体运动时的矢状面运动规律来看,主要是质点加速度的运动以及矢状面角度的转动,如图3所示,本文中,安装后模块所在平面与人体矢状面是平行的,随着人跑步,模块在矢状面的平行移动可以用x轴、y轴的加速度进行描述,而模块的转动可以从z轴的角度进行描述。

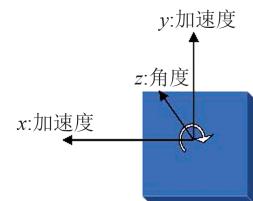


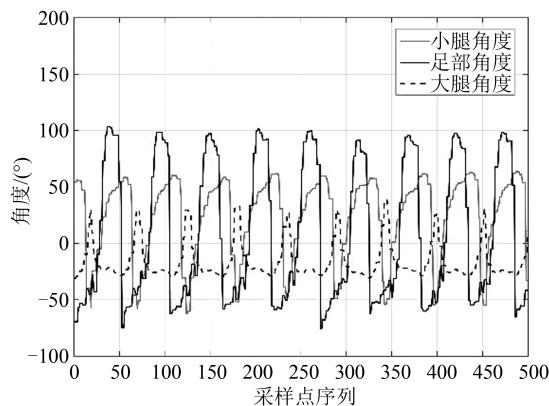
图3 IMU模块数据采集图

Fig. 3 Diagram of IMU Data Collection

角度在人体跑步中体现了良好的周期性,并且同样地,足部的角度变化大于小腿的角度变化,大腿的角度变化更小。分析图4中的数据可以得出结论:在一个运动周期里,大腿角度先发生变化,而后带动小腿,小腿在移动中带动足部,所以3个传感器角度值变化体现了这一运动学规律。

矢状面的加速度可以很好地反映出运动质点运动的趋势与状态,而质点在矢状面的总加速度 $a$ 为 $x$ 轴加速度 $a_x$ 与 $y$ 轴加速度 $a_y$ 的矢量和,即为:

$$a = \sqrt{|a_x|^2 + |a_y|^2} \quad (1)$$

图4  $z$ 轴角度变化Fig. 4 Angle Change of  $z$ -Axis

计算后的总加速度如图5所示(截取数据片段)。

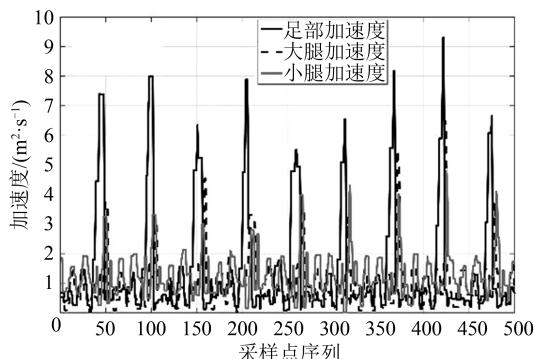


图5 加速度值

Fig. 5 Thigh Acceleration Values

由图5可以分析得出,加速度在人体跑步的循环运动中体现了一定的周期性,尤其体现在一个周期上极值的出现,极值的出现说明加速度发生急速改变,此时处于下肢发力、下肢角度变化方向变换的时刻,而在3个传感器中,足部加速度极值最大,大腿处最小。在跑步运动中,大腿围绕髋关节做周期往复运动,其运动的位移量仅为围绕髋关节的大腿骨一半长度,所以加速度变化值最小,而足部作为下肢运动时的末端,矢量位移量最大,所获得的加速度值也最大。

如图4所示,  $z$ 轴角度在步态上体现了良好的周期性,所以本文以大腿角度为参考量做步态的分割,分割方法为取大腿角度的极高值,运用极高值进行步态的分割。在采集到的数据集中实现了分割,本文使用的IMU模块采样数量为73帧/s,经过步态分割,最终的步态帧数范围为42~97,均小于100,步态帧数展示了步频,越小的帧数代表着更快的步频。为了验证分割的效果,本文采用3个角度的过零点来进行验证,理论上,本文所布置的IMU模块在下肢摆动过程中会经过

2个角度零点,从图4中也可看出这一点。本文对分割中得到的1794个周期求过零点,3个角度的值都为2,因此本文所设计的分割方法能够完整地将步态进行分割。

本文将数据格式设置为  $100 \times 9$ , 9为3个传感器的  $x$ 、 $y$  轴加速度和  $z$  轴角度,而100为时间维度,代表了步态帧数,不够100的进行补零处理,最终得到了1794个步态周期。而对于步幅的计算,本文对于分割后的每一个步态周期,计算公式为:

$$S_{\text{len}} = S_{\text{fra}} / 73 \times S \quad (2)$$

式中,  $S_{\text{len}}$  为步幅长度;  $S_{\text{fra}}$  为步态周期所占帧数;  $S$  为当前测试速度。经过计算,本文数据集的步幅长度在1.3~2.4 m之间,能够涵盖大多数跑步时的步长范围。

### 1.3 数据相关性分析

本文研究的主要内容是人体运动时的速度与步幅,采用主成分分析(principal component analysis, PCA)加皮尔逊相关系数分析的方法对3个下肢关键质点的加速度、角度变化和速度与步幅的关系进行探讨。本文采用的分析方法步骤如图6所示,首先使用PCA将1794个步态周期的100维时间特征映射到1维上,形成1794个  $1 \times 9$  的主成分向量,这一步的目的是在时间尺度上进行降维。然后将物理量一致的数据取出重组为9个维度为  $1 \times 1794$  的向量,最后分别对这9个向量进行速度和步幅的皮尔逊相关系数计算,计算公式为:

$$\rho(s, x) = \frac{\sum_{i=1}^n (s_i - \bar{s}) \times (x_i - \bar{x})}{|s_i - \bar{s}| \times |x_i - \bar{x}|} \quad (3)$$

式中,  $\rho$  为皮尔逊相关系数;  $i$  表示第  $i$  个步态周期;  $n=1794$ ;  $s$  为速度或步幅实际值;  $\bar{s}$  为  $s$  的平均值;而  $x$  为9个向量之一(分别为3个传感器的  $x$ 、 $y$  轴加速度和  $z$  轴角度经过PCA分析后的数值);  $x_i$  为  $x$  的元素;  $\bar{x}$  为  $x_i$  的均值。最终计算得到了9个物理量与速度和步幅之间的关系,代表了相关系数,结果如表2所示。

本文分两个维度对相关性进行讨论,针对传感器位置,图7展示了传感器位置相关系数的对比图。从图7中可见,对于速度的影响,足部的相关参数是最明显的,这是因为人体跑步运动中,速度最大的质点为足部。而分析其内部参数,加速度的相关性要大于角度的相关性,足部作为人体运动链的端点,其加速度能够很好地反映出速

度的变化趋势。同时,  $y$  轴加速度相关系数较低, 在大腿处体现得最为明显。这是因为在本文实验中,  $y$  轴起始方向垂直于地面, 起始的加速度为 0, 而跑步时, 下肢角度的变化不大, 所以 IMU 模块在  $y$  轴上的加速度分量不高, 易被测量误差影响, 从而对速度的影响不大。

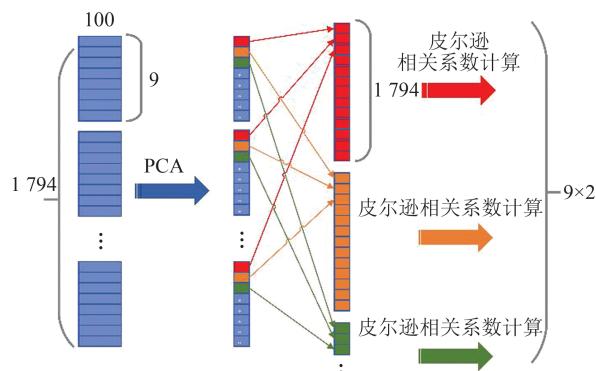


图 6 相关性分析流程图

Fig. 6 Correlation Analysis

表 2 数据相关性分析结果

Table 2 Results of Correlation Analysis

传感器	模型类型	速度相关系数	步幅相关系数
传感器 1(大腿)	$x$ 轴加速度	0.61	0.12
	$y$ 轴加速度	0.06	0.25
	$z$ 轴角度	0.41	0.58
传感器 2(小腿)	$x$ 轴加速度	0.55	0.16
	$y$ 轴加速度	0.21	0.17
	$z$ 轴角度	0.55	0.41
传感器 3(足部)	$x$ 轴加速度	0.70	0.06
	$y$ 轴加速度	0.61	0.21
	$z$ 轴角度	0.55	0.30

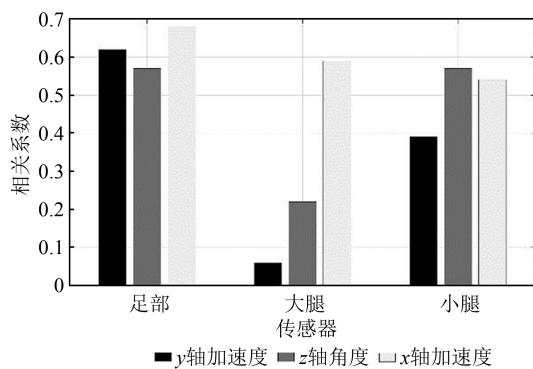


图 7 速度相关系数

Fig. 7 Correlation Coefficient of Velocity

对于步幅而言, 由图 8 可知, 相关系数最高的传感器为大腿处的编号, 而且加速度的相关系数很小, 基本与步幅不相关。步幅的大小主要取决于人体跑步时下肢展开的角度, 角度越大则步幅

越大, 而大腿的角度更是人体运动链的发起端, 其角度变化大则步幅大, 具有强相关性。

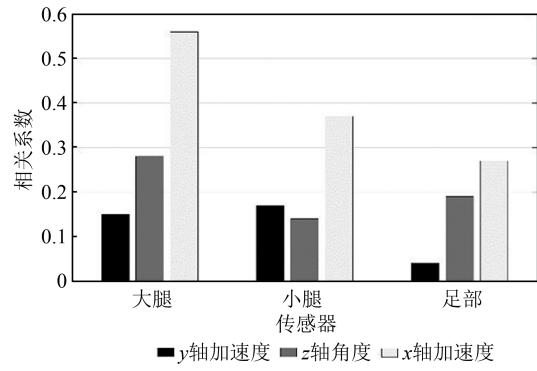


Fig. 8 Correlation Coefficient of Step

经过数据相关性分析, 可以得出结论: 3 个位置的 IMU 的加速度、角度的数据与人体运动时的速度、步幅具有一定的相关性。但是凭借简单相关性分析无法实现高精度的预测, 在 PCA 时数据也有一定的损失, 时间维度上的特征没有体现出来。

## 2 多模态网络计算系统

对于人体运动步态分类、回归问题, 一般都会使用 CNN 或者是循环神经网络, 本文的对象是时序信号, 变化量随时间而变化, 时间轴上数据的相关性十分重要。循环神经网络的特点体现在对时序信号的敏感性上, 在处理时序信号上更具有优势, 而 LSTM 作为一种循环神经网络, 能够解决长序列训练过程中的梯度消失和梯度爆炸问题。将注意力机制引入网络中, 能够增强网络对于关键信息的捕捉能力, 进一步提升特征提取能力。笔者之前的研究证明带有注意力机制的 LSTM (attention-LSTM, Att-LSTM) 在步态分类问题中体现了比 CNN 更好的效果。本文继续深入这一研究, 将 Att-LSTM 作为基准, 开发一种多模态架构的 Att-LSTM (multi-modal-Att-LSTM, M-Att-LSTM) 来对信号进行处理。多模态近年来在人体信息处理上有着良好的前景, 利用多模态能够从不同模态的信息中分别提取特征, 并在后续网络中进行特征融合, 进行回归运算。本文中, 加速度  $a_i$  和角度  $p_i$  处于两个不同的模态, 拟使用相同的 Att-LSTM 分别提取特征, 在最后一层网络进行特征融合。

总体网络结构如图 9 所示, 两个相同 Att-LSTM 分别接受两种模态 (加速度、角度) 的输

入,输入的向量维度分别为 $6 \times 100$ 和 $3 \times 100$ ,数据维度分别为6和3,代表3个IMU模块的加速度或角度,时间维度为100,本文对于帧数低于100的步态,将每个步态周期的帧数进行补零。两种模态的输入在两层LSTM提取特征后,进入注意力机制模块,将从最后一层LSTM传递的向量与前 $n$ 个时间步的隐含层做点积,计算出注意力分数;再经过矩阵拼接形成新的向量,而后经过两个全连接层分别输出特征向量 $a_i, p_i$ ,两种模态的特征向量在最后一层进行特征融合为 $[a, p]$ ,形成一组最终的特征向量;最后进行回归操作,选择优化器自适应矩估计,平均绝对误差函数作为损失函数。图9中, $Q, K, V$ 为注意力机制中的查询向量、键向量和值向量。

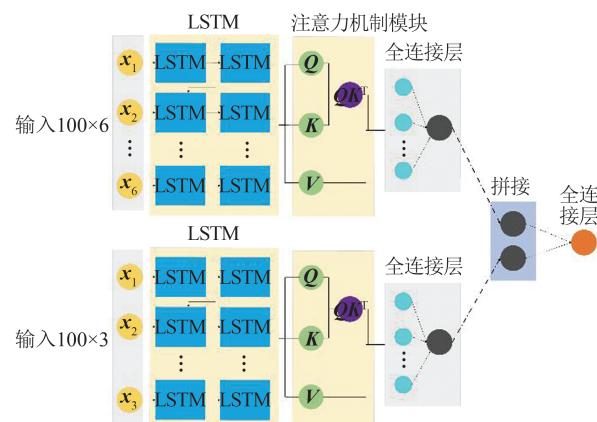


图9 总体网络结构

Fig. 9 Total Network Structure

对比参照模型,本文采用非多模态的Att-LSTM模型,网络结构设计如图10所示,将两个向量(加速度 $a_i$ 和角度 $p_i$ )在输入模型之前进行向量拼接,输入到模型中的向量为 $[a_i, p_i]$ ,而输入维度也发生了变化,为 $100 \times 12$ ,后续的LSTM层以及全连接层的结构不变,为双层100维LSTM相连,特征提取后再与50维的全连接层相连,最终进行回归操作。

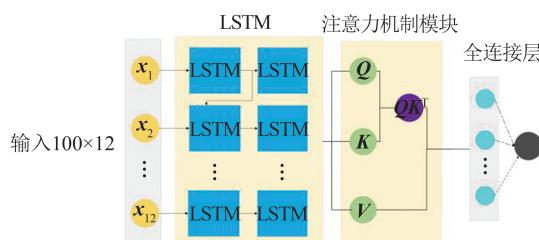


图10 Att-LSTM模型

Fig. 10 Att-LSTM Model

实验共分为两组,输入量都是3个IMU模块的加速度 $a_i$ 和角度 $p_i$ ,而目标数据分别为跑步的

速度和步幅,两组实验分别在M-Att-LSTM和Att-LSTM上完成。

### 3 跑步参数解析实验与分析

本文将采集到的数据按照5:1的比例分为训练集和测试集。每组实验运行5次,每次训练100个世代,在训练中,设置批大小为10,经过观察,训练的损失函数在第100个世代稳定下来。记录了训练过程中损失函数的变化,并且将训练好的模型进行了测试,将5次测试的结果(误差、标准偏差)记录下来,同时将5次测试结果回归值的平均值与实际值进行对比。表3为统计检验结果,M-Att-LSTM速度与步幅的误差分别为 $0.058 \pm 0.013 \text{ m/s}$ 和 $0.023 \pm 0.022 \text{ m}$ ,而Att-LSTM速度与步幅的误差分别为 $0.199 \pm 0.035 \text{ m/s}$ 和 $0.051 \pm 0.034 \text{ m}$ 。图11、12使用箱图直观地显示了5次训练后的结果,分别为速度误差与步幅误差。图13、14展示了回归值的平均值与实际值的对比,横坐标为步数,纵坐标分别为速度与步幅。在图13、14中将M-Att-LSTM、Att-LSTM与实际曲线进行展现,图15、16为训练损失函数变化,横坐标为训练的世代,而纵坐标为损失函数值。

表3 模型测试结果对比

Tab. 3 Comparison of the Model Test Results

测试对象	模型类型	误差	标准偏差
速度/( $\text{m} \cdot \text{s}^{-1}$ )	M-Att-LSTM	0.058	0.013
	Att-LSTM	0.199	0.035
步幅/m	M-Att-LSTM	0.023	0.022
	Att-LSTM	0.051	0.034

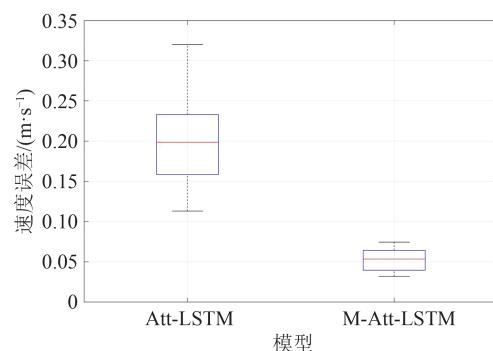


图11 速度误差

Fig. 11 Velocity Error

### 4 讨论

由表3和图11、12可以看出,不管是在速度还是在步幅的回归值误差上,M-Att-LSTM都要

比 Att-LSTM 的效果更好,在速度误差上前者仅为后者的 29.2%,而在步幅上为 45.1%,且产生的标准偏差也更低,更加稳定。这证明了不同模态之间的数据体现着不同的特征,使用多模态处理在特征提取后进行向量融合比提前使用向量融合更加有效。因为同模态的数据包含的信息类型、种类更加固定,更能够体现出特征,而不同模态(速度和加速度)由于数据类型的差异,共同提取特征时可能会互相影响。图 13、14 体现了同样的特点,使用训练好的模型进行拟合对比,M-Att-LSTM 也比 Att-LSTM 体现出了更好的效果,预测值和实际值更加接近,曲线更加贴近于实际曲线。对比图 15、16 明显可以看出,在模型的训练数据上,M-Att-LSTM 要比 Att-LSTM 的训练速度更快,最终得到的损失函数值更低,也说明了本文提出的模型能够更快、更准确地提取特征,完成回归任务。M-Att-LSTM 是一种更有优势的模型,进一步说明了多模态特征提取在人体运动信息采集处理上的优势。最终结果显示,本文在速度上的误差仅为 0.058 m/s,在步幅上为 0.023 m。

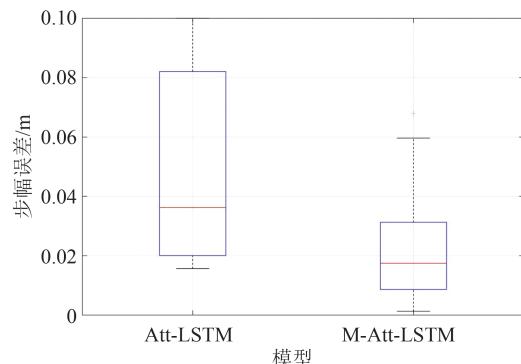


图 12 步幅误差  
Fig. 12 Step Error

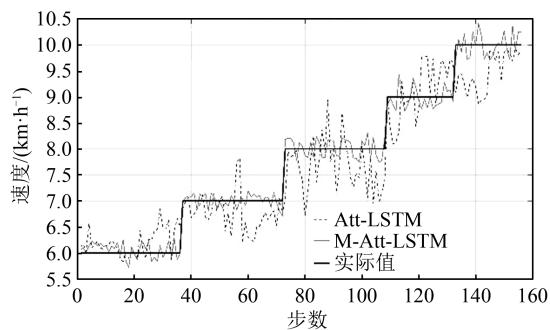


图 13 速度拟合对比  
Fig. 13 Contrast of Velocity Fit

本文的研究是使用可穿戴模块对人体运动步态特征的又一次探索,和近年来相关实验进行对比,如表 4 所示,对于人体运动速度的回归拟合

近年来研究较少,而对于步幅长度的预测,本文在误差控制方面最有优势,步幅误差仅为文献[11]的 35.7%,文献[27]的 17.1%。这说明采用本文方法,使用多模态的带有注意力机制的 LSTM 处理 IMU 模块数据是一种精度较高的速度、步幅预测方法。本文方法具有一定的实际意义,可以广泛用于户外运动数据检测、专业运动数据监控等方面,有着较高的实用潜力。

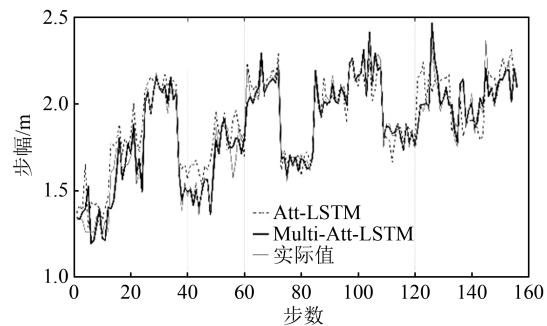


图 14 步幅拟合对比  
Fig. 14 Contrast of Step Fit

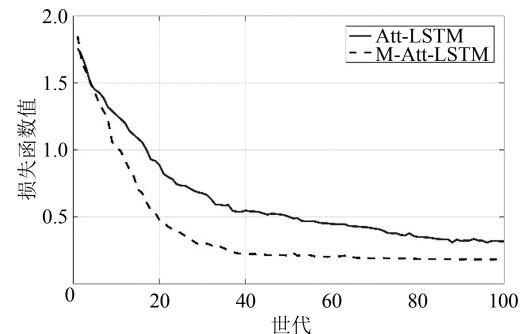


图 15 速度损失函数演变曲线  
Fig. 15 Loss Evolution of Velocity

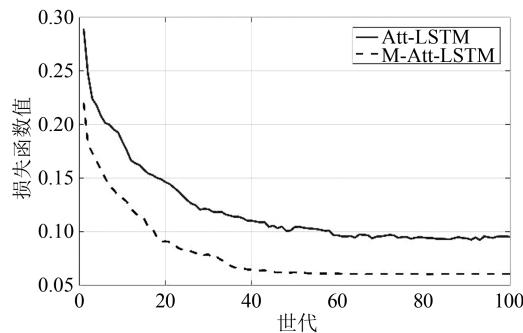


图 16 步幅损失函数演变曲线  
Fig. 16 Loss Evolution of Step

表 4 近年研究对比

Tab. 4 Comparison of the Recent Studies

方法	分析类型	步幅误差/cm
文献[11]	PCA	6.44
文献[27]	CNN	13.48
本文方法	多模态分析法	2.30

## 5 结语

本文对跑步运动的两个最重要因素,即速度和步幅进行了研究,将IMU模块布置在人体足部、小腿以及大腿3个点上,对于人体跑步时矢面上下肢的3个关键质点的x、y轴的加速度与角度变化进行了数据提取,同时记录下了运动速度并通过计算得出了步幅,形成了一组有效的数据集。对于数据的相关性利用PCA与皮尔逊相关系数进行了分析,探讨了人体运动时速度与步幅与传感器位置、物理参数之间的关系。在此基础上,本文提出了一种结合多模态特征提取以及注意力机制的M-Att-LSTM网络,对于数据集进行有监督的回归训练。实验结果表明,本文提出的检测方法在速度上得到了0.058 m/s的误差,在步幅上得到了0.023 m的误差,是一种精度较高的速度、步幅预测方法。

## 参 考 文 献

- [1] Huang Dongjin, Yao Yuanqiu, Ding Youdong, et al. Virtual Running Exercise System Based on Kinect[J]. *Journal of Graphics*, 2017, 38(5): 789-795. (黄东晋, 姚院秋, 丁友东, 等. 基于Kinect的虚拟健身跑锻炼系统[J]. 图学学报, 2017, 38(5): 789-795.)
- [2] Song Shuhua, Liu Jian, Gao Chungang, et al. Influence on Heart Rate Variability of Middle-Long Distance Athletes During Progressive Increasing Load Exercise[J]. *Journal of Shandong Institute of Physical Education and Sports*, 2010, 26(10): 62-65. (宋淑华, 刘坚, 高春刚, 等. 递增负荷运动对中长跑运动员心率变异性的影响[J]. 山东体育学院学报, 2010, 26(10): 62-65.)
- [3] Duan Zicai, Zhang Ge. Comparative Study on Athlete's Heart Rate Change of 5 km Running at Different Stride Frequency and Length[J]. *China Sport Science*, 2006, 26(4): 65-66. (段子才, 张戈. 不同步频和步幅的5 km跑过程中运动员心率变化的对比研究[J]. 体育科学, 2006, 26(4): 65-66.)
- [4] Wang Junqing, Zhang Xini, Luo Zhen, et al. The Influence of Cadence Retraining on Impact Forces and Lower Extremity Biomechanics During Running [J]. *Chinese Journal of Applied Mechanics*, 2020, 37(5): 2167-2175. (王俊清, 张希妮, 罗震, 等. 步频再训练对跑步时下肢冲击的生物力学影响研究[J]. 应用力学学报, 2020, 37(5): 2167-2175.)
- [5] Chen Guoliang, Yang Zhou. Step Counting Algorithm Based on Zero Velocity Update[J]. *Geomatics and Information Science of Wuhan University*, 2017, 42(6): 726-730. (陈国良, 杨洲. 基于加速度量测幅值零速检测的计步算法研究[J]. 武汉大学学报(信息科学版), 2017, 42(6): 726-730.)
- [6] Zhang Xiaohong, Luo Kegan, Tao Xianlu, et al. A Multi-mounted PDR Algorithm Based on Wearable MEMS Sensors State Recognition [J]. *Geomatics and Information Science of Wuhan University*, 2021, 46(12): 1791-1801. (张小红, 罗科干, 陶贤露, 等. 一种基于穿戴式MEMS传感器状态识别的多部位PDR算法[J]. 武汉大学学报(信息科学版), 2021, 46(12): 1791-1801.)
- [7] Zhang Xiaohong, Tao Xianlu, Wang Yingzhe, et al. MEMS-Enhanced Smartphone GNSS High-Precision Positioning for Vehicular Navigation in Urban Conditions [J]. *Geomatics and Information Science of Wuhan University*, 2022, 47(10): 1740-1749. (张小红, 陶贤露, 王颖喆, 等. 城市场景智能手机GNSS/MEMS融合车载高精度定位[J]. 武汉大学学报(信息科学版), 2022, 47(10): 1740-1749.)
- [8] Zhou Bingtao, Chen Shiqiang, Cheng Yuyang, et al. Biometric Identification Based on Plantar Pressure Sensor and Deep Learning[J]. *Chinese Journal of Scientific Instrument*, 2021, 42(7): 108-115. (周丙涛, 陈世强, 程宇阳, 等. 基于足底压力传感器与深度学习的生物身份识别[J]. 仪器仪表学报, 2021, 42(7): 108-115.)
- [9] Qiu Shi, Du Yihao, Wang Hao, et al. Research on Lower Limb Kinematic Analysis Method Based on sEMG[J]. *Chinese Journal of Scientific Instrument*, 2018, 39(2): 30-37. (邱石, 杜义浩, 王浩, 等. 基于sEMG的下肢运动解析方法研究[J]. 仪器仪表学报, 2018, 39(2): 30-37.)
- [10] Wang Zhimin, Tao Baolin, Yu Peng, et al. Indoor Positioning Technology of Pedestrian Based on Wearable IMU [J]. *Transducer and Microsystem Technologies*, 2021, 40(1): 46-48. (王智敏, 陶宝林, 于鹏, 等. 基于可穿戴式惯性测量单元的行人室内定位技术[J]. 传感器与微系统, 2021, 40(1): 46-48.)
- [11] Vezočnik M, Kamnik R, Juric M B. Inertial Sensor-Based Step Length Estimation Model by Means of Principal Component Analysis [J]. *Sensors*, 2021, 21(10): 3527.
- [12] Lu Zezhong, Lu Xiaoping, Ma Liangting, et al. Adaptive Gait Detection Algorithm Based on Dual State Machine [J]. *Science of Surveying and Mapping*, 2021, 46(1): 56-61. (路泽忠, 卢小平, 马靓婷, 等. 双状态机的自适应步态检测算法[J]. 测绘科学, 2021, 46(1): 56-61.)

- [13] Li Qingquan, Chen Ruizhe, Tu Wei, et al. Real-Time Vision-Based Deformation Measurement of Long-Span Bridge with Inertial Sensors [J]. *Geomatics and Information Science of Wuhan University*, 2023, 48(11): 1834–1843. (李清泉, 陈睿哲, 徐伟, 等. 基于惯性相机的大跨度桥梁线形变形测量方法[J]. 武汉大学学报(信息科学版), 2023, 48(11): 1834–1843.)
- [14] Su B Y, Wang J, Liu S Q, et al. A CNN-Based Method for Intent Recognition Using Inertial Measurement Units and Intelligent Lower Limb Prosthesis [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2019, 27 (5) : 1032–1042.
- [15] Gao F, Liu G Y, Liang F Y, et al. IMU-Based Locomotion Mode Identification for Transtibial Prostheses, Orthoses, and Exoskeletons[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2020, 28(6): 1334–1343.
- [16] Bruinsma J, Carloni R. IMU-Based Deep Neural Networks: Prediction of Locomotor and Transition Intentions of an Osseointegrated Transfemoral Amputee [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering: A Publication of the IEEE Engineering in Medicine and Biology Society*, 2021, 29: 1079–1088.
- [17] Sheng Min, Liu Shuangqing, Wang Jie, et al. Motion Intent Recognition of Intelligent Lower Limb Prosthesis Based on GMM-HMM[J]. *Chinese Journal of Scientific Instrument*, 2019, 40(5): 169–178. (盛敏, 刘双庆, 王婕, 等. 基于GMM-HMM模型的智能下肢假肢运动意图识别[J]. 仪器仪表学报, 2019, 40(5): 169–178.)
- [18] Yu S Y, Yang J F, Huang T H, et al. Artificial Neural Network-Based Activities Classification, Gait Phase Estimation, and Prediction[J]. *Annals of Biomedical Engineering*, 2023, 51(7):1471–1484.
- [19] Baniasad M, Martin R, Crevoisier X, et al. Automatic Body Segment and Side Recognition of an Inertial Measurement Unit Sensor During Gait [J]. *Sensors*, 2023, 23(7): 3587.
- [20] Do T N, Liu R, Yuen C, et al. Personal Dead Reckoning Using IMU Device at Upper Torso for Walking and Running [C]//IEEE Sensors, Orlando, USA, 2016.
- [21] Elshehabi M, Del Din S, Hobert M A, et al. Walking Parameters of Older Adults from a Lower Back Inertial Measurement Unit, a 6-Year Longitudinal Observational Study[J]. *Frontiers in Aging Neuroscience*, 2022, 14: 789220.
- [22] Koroglu M T, Yilmaz A, Saul C J. A Deep Learning Strategy for Stride Detection [C]//IEEE Sensors, New Delhi, India, 2018.
- [23] Anwary A R, Yu H N, Vassallo M. Optimal Foot Location for Placing Wearable IMU Sensors and Automatic Feature Extraction for Gait Analysis [J]. *IEEE Sensors Journal*, 2018, 18(6): 2555–2567.
- [24] Hutabarat Y, Owaki D, Hayashibe M. Quantitative Gait Assessment with Feature-Rich Diversity Using Two IMU Sensors[J]. *IEEE Transactions on Medical Robotics and Bionics*, 2020, 2(4): 639–648.
- [25] Uno Y, Ogasawara I, Konda S, et al. Validity of Spatio-Temporal Gait Parameters in Healthy Young Adults Using a Motion-Sensor-Based Gait Analysis System (ORPHE ANALYTICS) During Walking and Running [J]. *Sensors (Basel, Switzerland)* , 2022, 23(1): 331.
- [26] Lu Yongle, Chen Yongwei, Di Ke, et al. High-Precision Step-Length Estimation Method Based on MEMS Inertial Sensor[J]. *Journal of Chinese Inertial Technology*, 2018, 26(2): 167–172. (路永乐, 陈永伟, 邓克, 等. 基于MEMS惯性传感器的高精度步长估计方法[J]. 中国惯性技术学报, 2018, 26 (2): 167–172.)
- [27] Sui J D, Chang T S. IMU Based Deep Stride Length Estimation with Self-supervised Learning [J]. *IEEE Sensors Journal*, 2021, 21(6) : 7380–7387.