

文章编号: 1004-7220(2025)05-1295-08

基于长短时记忆模型与无标记动作捕捉系统估算 跑步地面反作用力曲线

周玉林¹, 赵峻辰¹, 李翰君^{1,2}, 时会娟^{1,2}, 刘卉^{1,2}

(1. 北京体育大学 运动人体科学学院, 北京 100084; 2. 北京体育大学 国家体育总局体能训练与身体机能恢复实验室, 北京 100084)

摘要:目的 应用长短时记忆神经网络(long short-term memory, LSTM)模型,以无标记动作捕捉系统所得下肢关节点坐标作为输入变量,估算跑步过程中的地面反作用力(ground reaction forces, GRF)曲线。方法 采用无标记动作捕捉系统和三维测力台同步采集 59 名业余跑者跑步动作下的视频图像和动力学数据。建立 LSTM 模型,以 Theia3D 无标记动作捕捉系统获取的 11 个下肢关节点三维坐标作为输入变量估算跑步支撑阶段三维 GRF 曲线。使用相关系数、均方根误差(root mean square error, RMSE)和标准化均方根误差(normalized root mean square error, nRMSE)评估 LSTM 模型的估算效果,采用统计参数映射分析 LSTM 模型估算和测力台实测曲线的差异,采用配对样本 t 检验分析模型估算与实测 GRF 特征差异。结果 LSTM 模型估算所得 GRF 与实测值之间高度相关($r > 0.85, P < 0.001$)且误差较小(RMSE < 0.3 倍体重, nRMSE < 15%)。LSTM 模型估算所得 GRF 曲线与实测曲线之间不存在显著差异区间。基于 LSTM 估算曲线计算所得 GRF 特征与实测值不存在显著差异($P > 0.05$)。结论 基于 LSTM 模型,可从无标记动作捕捉系统获取的下肢关节点三维坐标有效估算人体跑步时 GRF 曲线,并获得准确性较高的 GRF 特征。本研究建立的 LSTM 模型可以用于户外环境下监控跑步过程中的损伤风险。

关键词: 长短时记忆模型; 地面反作用力; 无标记动作捕捉; 跑步损伤

中图分类号: R 318.01 文献标志码: A

DOI: 10.16156/j.1004-7220.2025.05.028

Estimating Running Ground Reaction Force Curves Using Long Short-Term Memory Neural Network and Markerless Motion Capture System

ZHOU Yulin¹, ZHAO Junchen¹, LI Hanjun^{1,2}, SHI Huijuan^{1,2}, LIU Hui^{1,2}

(1. School of Sport Science, Beijing Sport University, Beijing 100084, China; 2. Key Laboratory for Performance Training & Recovery of General Administration of Sport, Beijing Sport University, Beijing 100084, China)

Abstract: Objective By applying the long short-term memory (LSTM) neural network model and using lower body landmark coordinates obtained from a markerless motion capture system as inputs, to estimate ground reaction force (GRF) curves during running. **Methods** The video images and GRF data of 59 amateur runners during running were collected by the markerless motion capture system and three-dimensional (3D) force plates. The LSTM model was established, and the 3D coordinates of 11 lower body landmarks, obtained via the Theia3D markerless system, were used as inputs to estimate the 3D GRF curves during the stance of running. The estimation performance was evaluated using correlation coefficients r , root mean square error (RMSE), and

收稿日期: 2025-03-02; 修回日期: 2025-03-25

基金项目: 国家自然科学基金项目(12132009), 中央高校基本科研业务费专项资金(2024TJNJ009)

通信作者: 刘卉, 教授, E-mail: liuhuibupe@163.com

normalized root mean square error (nRMSE) by comparing LSTM model estimation and force plate measurement. Statistical parametric mapping was used to analyze differences in GRF curves estimated by the LSTM model and measured by the force plate, while paired *t*-tests were used to assess differences in GRF characteristics between model estimation and actual measurement. **Results** A strong correlation ($r > 0.85$, $P < 0.001$) and lower error (RMSE < 0.3 body weight, nRMSE $< 15\%$) was found between the LSTM model estimation and actual measurements. No significant difference was found in GRF curve intervals between LSTM model estimation and actual measurements. There was no significant difference in GRF characteristics between LSTM model estimation and actual measurements ($P > 0.05$). **Conclusions** Based on the LSTM model, the 3D GRF curves can be effectively estimated by lower body landmark coordinates obtained from the markerless motion capture system, thereby acquiring the highly accurate GRF characteristics. The LSTM model developed in this study can be used to monitor injury risks during running in outdoor environments.

Key words: long short-term memory model; ground reaction forces; markerless motion capture; running injury

采集分析跑步过程中所受地面反作用力 (ground reaction force, GRF) 对防治跑步相关损伤 (running related injury, RRI) 具有重要意义,但目前实验室之外很难准确获得跑步时的三维 GRF。跑步是群众参与最广泛的运动之一,但 RRI 发生率高达 71.3%^[1]。此类损伤轻则制约人体运动,严重时会影响正常生活质量。已有研究表明,跑步支撑阶段 GRF 峰值^[2]和垂直加载率 (vertical loading rate, VLR)^[3]与 RRI 的发生有关。目前,三维测力台是准确采集三维 GRF 相关数据的主要方法,但在户外环境下由于安装和信号传输问题,测力台使用受限^[4];而压力鞋垫等可穿戴设备只能测量垂直压力,且设备易损坏^[5-6]。因此,在非实验室环境下多通过模型估算的方式获取 GRF。

以神经网络为代表的驱动模型在估算动力学方面效果较好,但其输入变量的实用性较低。神经网络模型具备深入挖掘数据的能力,进而构建出输入与输出变量之间的复杂映射关系,最终进行数据估算。其中,长短时记忆 (long short-term memory, LSTM) 模型能够处理不同输入长度的数据,特别适合时间序列数据分析^[7]。目前,该模型已经成功应用于走路^[8]、跑步^[9]和侧切变向^[10]等动作下的 GRF 估算中。此外,现有动力学估算研究中的输入变量主要为基于惯性传感器获得的环节加速度^[11-12]和红外动作捕捉系统获得的体表反光点坐标^[10,13-14]等参数。户外环境下,红外动作捕捉系统几乎无法使用。惯性传感器易受磁场干扰,长时间佩戴会产生较大的累积偏移误差,且对人体自

然运动模式产生一定影响^[15]。因此,现有研究成果很难直接应用到户外实践中。

无标记动作捕捉系统可在户外环境下获得人体关节坐标等运动学参数,然而该参数能否有效估算跑步过程中的 GRF 尚不明确。拍摄运动员动作视频并进行解析是户外环境下获取运动学数据最常用的方式^[16],能够克服红外动作捕捉系统和惯性测量单元 (inertial measurement unit, IMU) 的缺陷。目前,智能识别算法已经能够快速准确地从视频图像中获取人体运动过程中的关节坐标^[17],甚至估算环节姿态^[18-19]。上述算法提升了视频解析的效率。因此,以智能识别算法所获运动学参数作为神经网络模型的输入变量对 GRF 进行估算,具有极大的应用潜力。Theia3D 能够从多视角图像中估算人体 17 个环节的运动学数据,并以 4×4 矩阵的形式给出环节坐标系原点和三维姿态角度,目前已经成功应用在步行^[20]、跑步^[21]以及侧切变向^[18]等多种运动的数据采集中。然而,基于该系统获取的关节坐标作为输入变量估算跑步过程中的 GRF,效果尚不明确。

本文旨在建立以无标记动作捕捉系统获取的下肢关节坐标作为输入变量的 LSTM 模型,估算跑步过程中三维 GRF 曲线,并验证其有效性。本研究假设如下:① LSTM 模型估算与实测的 GRF 曲线之间高度相关;② LSTM 模型估算与实测 GRF 曲线之间不存在显著差异区间;③ 基于 LSTM 模型估算所得 GRF 特征与实测值之间无显著差异。

1 研究对象与方法

1.1 受试者

选取 59 名以健身休闲为目的且不具备专业训练背景的业余跑者(男性 24 名,女性 35 名),身高(170 ± 7.8) cm,体重(63.7 ± 10.5) kg,周跑量(12 ± 8.9) km。所有受试者半年内均无下肢手术史,且实验前 24 h 内没有进行剧烈运动。经 1 名专业康复师筛查发现,28 名受试者(男性 10 名,女性 18 名)存在髌股关节疼痛综合征。本研究获得北京体育大学伦理委员会批准(2024499H)。

1.2 测试流程

受试者签署知情同意书并充分热身后,换上紧身衣物并穿着测试跑鞋进行跑步测试。为充分模拟跑者日常跑步训练以及采集更多的数据建立数据库,要求受试者围绕数据采集区域进行 5 km 场地跑,并分别在跑步前以及跑步 1、2、3、4 和 5 km 时共 6 次进入采集区域进行数据采集。受试者每次进入采集区域需要进行 3 次有效测试,1 次有效测试定义为:① 跑步动作流程自然无任何调整;② 跑步速度在(13 ± 0.65) km/h 范围内;③ 左右腿各有 1 次完整的支撑期;④ 支撑腿足部与测力台完整接触。上述测试结束 24 h 之后,为扩大数据库中的数据量,受试者再次来到采集区域穿着另一双测试跑鞋进行同样的 5 km 跑步测试。两次测试结束之后,受试者所有测试工作完成。

1.3 数据采集

采用 12 个视频镜头(采样频率 100 Hz,Qualisys 公司,瑞典)和 3 块 9287C 三维测力台(采样频率 1 kHz,Kistler 公司,瑞士)同步采集跑步过程中的影像学 and 动力学数据,采用 Smartspeed 分段计时实时反馈系统(Fusion Sport Pty 公司,澳大利亚)监控受试者跑速(见图 1)。

1.4 数据处理

1.4.1 图像数据处理 使用 Qualisys Track Manager 编写好的 PAF 文件^[22]进行以下操作:① 调用 Theia3D 2022(Theia Markerless 公司,加拿大)对视频数据进行处理,基于逆向运动学估算获得人体全身环节运动学数据,其下肢运动链中骨盆和髌、膝、踝关节的自由度分别为 6、3、3 和 6^[20];② 调用 Theia3D 将处理好的运动学数据联合测力台信号导




图 1 实验场地

Fig. 1 Experimental site

出为 C3D 格式文件;③ 调用 Visual 3D 软件(Preview v2022.06.02,C-Motion 公司,美国)导入 C3D 文件,自动生成骨盆、大腿、小腿、前足和后足环节坐标系,其中将骨盆、大腿、小腿和后足坐标系的原点分别定义为骨盆、髌/膝/踝关节中心点。虚拟生成足跟点和足尖点^[22]。由此获取骨盆中心、双侧髌/膝/踝中心、足跟点和足尖点共 11 个关节的三维坐标。随后,将 GRF 通过体重(body weight, BW)进行标准化。仅对双侧下肢的支撑阶段进行分析,其定义为垂直 GRF > 10 N 阶段,并将垂直 GRF > 10 N 的第 1 帧定义为着地时刻。

1.4.2 坐标系转换 数据库的单个数据样本中只包含单侧腿的支撑阶段前后 10 ms 内所有下肢关节点坐标和 GRF 曲线。因此,1 次有效测试数据中包含左、右腿共 2 个有效数据样本。数据样本包含支撑阶段前后 10 ms 内 11 个关节点坐标和 3 个方向 GRF。建立着地坐标系,以避免大地坐标系原点设置对估算结果的影响。着地坐标系原点为着地时刻骨盆中心点在水平面的投影,坐标轴方向和大地坐标系一致。将计算获取的 11 个关节点均转换到着地坐标系中。转换完成的关节点坐标通过 3 次样条插值为 GRF 相同的数据长度。跑步腾空阶段的 GRF 数据设置为 0。

1.4.3 LSTM 模型建立及验证 将 59 名受试者随机划分到训练集(55 名)和测试集(4 名)。部分视频数据目标识别错误(识别到镜头内受试者之外的人)导致运动学数据无效,且测试集受试者间数据缺失状况差异大,为保证测试集中数据的均衡性,对数据进行分层随机抽样,选取了其中 1 双鞋下人物识别正确的任意 3 圈下的数据用于模型测试。最终,训练集中和测试集的样本数量分别为 3 924、

72例。为增加模型的适用性,将左右腿样本一并放入模型进行训练,且各子集中比例相同。本文建立的LSTM估算模型的输入变量特征为33(11个关节点 \times 3维坐标) \times 动作时间长度,输出特征为3(1个GRF \times 3个方向) \times 动作时间长度。模型训练前使用MinMaxScaler将各类数据缩放到0~1,以确保GRF各方向均能被有效训练。训练过程中,将训练集中的数据随机划分为5份,每份数据依次作为验证集进行超参数验证,其余数据进行模型训练,因此每组超参数进行了5次验证。使用Optuna^[23]进行最优超参数搜索,其搜索范围和最优超参数如图2所示。当最优超参数确定后,基于最初的训练集训练模型,并基于测试集评估模型效果。神经网络模型的训练过程在Python Pytorch 2.4.1中进行,使用Cuda 12.1加速,其硬件设备为台式机,处理器为Core i7-7800X,内存为16 GB,显卡为GeForce RTX 2080 Ti,内存为12 GB(NVIDIA公司,美国)。

使用均方根误差(root mean square error, RMSE)和标准化均方根误差(normalized root mean square error, nRMSE)评价LSTM模型估算误差^[8,13,24-26],仅对支撑阶段内估算所得数据进行分

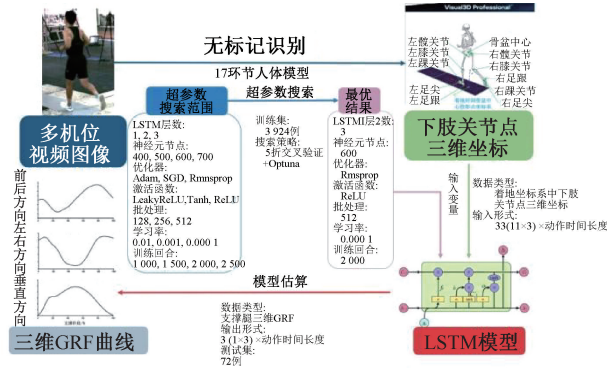


图2 无标记动作捕捉系统估算GRF曲线框架

Fig. 2 Framework of the markerless motion capture system for GRF curve estimation

析。此外,将支撑阶段的GRF数据标准化为100个时间节点用于曲线间差异分析。为了进一步探究本文建立的LSTM估算模型在RRI相关研究中的实用性,还从估算的GRF数据中提取冲击峰值、主动峰值和VLR等垂直方向特征^[11,27-28]以及制动力和推进力峰值等前后方向特征^[29]进行分析(见图3)。由于部分跑者不存在明显的冲击峰值,故采用支撑期13%的垂直GRF作为冲击峰值^[30]。




图3 GRF特征计算方式

Fig. 3 GRF characteristics calculation (a) Vertical GRF with first peak absent, (b) Vertical GRF with first peak present, (c) Anterior-posterior GRF

1.5 数据分析

针对研究假设①,使用Pearson相关分析LSTM模型估算与实测GRF曲线间相关性;针对研究假设②,使用统计参数映射(statistical parametric mapping, SPM)对两种方法获得GRF曲线区间差异进行分析;针对研究假设③,使用配对样本 t 检验分析两种方法所得GRF特征的差异。上述所有检验中统计显著性定为一类误差概率不大于0.05,所有分析使用Matlab 2020a(MathWorks公司,美国)完成。

2 结果

相关分析结果显示,LSTM模型估算的GRF曲线与实测值均高度相关,其72个样本中均呈现高度相关(前后方向: $r>0.947$;左右方向: $r>0.851$;垂直方向: $r>0.961$),且 $P<0.001$ 。估算误差方面,3个方向上表现出较小的绝对误差(前后方向:RMSE <0.060 BW;左右方向:RMSE <0.033 BW;垂直方向:RMSE <0.360 BW)和相对误差(前后方向:nRMSE $<12.82\%$;左右方向:nRMSE $<15.26\%$;垂直方向:

nRMSE<11.32%),见表1。

表1 LSTM模型估算跑步动作GRF结果($n=72$)

Tab.1 Results of LSTM model for estimating GRF during running ($n=72$)

方向	r	RMSE/BW	nRMSE/%
前后	0.992±0.008	0.038±0.018	5.78±2.81
左右	0.951±0.048	0.019±0.007	10.68±3.83
垂直	0.993±0.012	0.110±0.059	4.36±2.28

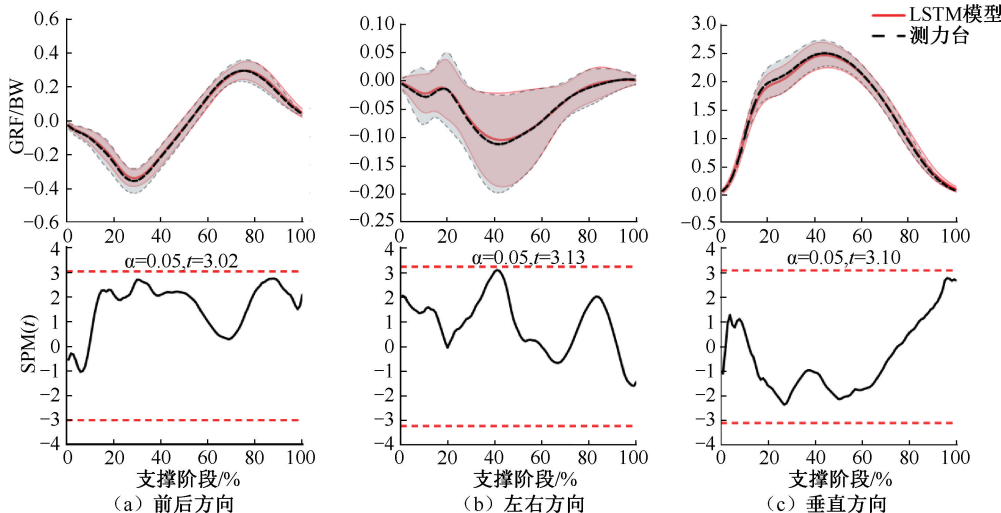


图4 LSTM模型估算GRF曲线SPM分析结果

Fig.4 SPM analysis results of LSTM model estimation for GRF curves (a) Anterior-posterior direction, (b) Medial-lateral direction, (c) Vertical direction

表2 LSTM模型估算和测力台实测GRF特征结果比较($n=72$)

Tab.2 Comparison of GRF characteristics between LSTM model estimation and force plate measurement ($n=72$)

指标	LSTM	测力台	P
推进力峰值/BW	0.296±0.053	0.297±0.062	0.789
制动力峰值/BW	0.360±0.068	0.362±0.074	0.403
垂直冲击峰值/BW	1.524±0.296	1.540±0.306	0.372
垂直主动峰值/BW	2.513±0.227	2.528±0.224	0.277
VLR/(BW·s ⁻¹)	50.84±7.92	51.60±8.80	0.380

本文还发现,基于模型所得GRF特征的绝对误差均较小,且所有GRF峰值特征的相对误差均小于10%,VLR的相对误差小于15%(见表3)。

表3 LSTM模型估算GRF特征误差($n=72$)

Tab.3 Estimation error of LSTM model for estimating GRF characteristics ($n=72$)

指标	绝对误差	相对误差/%
推进力峰值/BW	0.02±0.01	6.85±5.22
制动力峰值/BW	0.02±0.01	4.78±3.84
垂直冲击峰值/BW	0.11±0.08	7.29±5.86
垂直主动峰值/BW	0.09±0.06	3.51±2.44
VLR/(BW·s ⁻¹)	5.30±4.02	10.39±3.75

SPM分析结果显示,LSTM模型估算跑步动作支撑阶段3个方向的GRF曲线与测力台实测曲线之间均不存在具有显著差异区域(见图4)。

配对样本 t 检验结果显示,基于LSTM估算所得GRF曲线提取的推进力峰值、制动力峰值、垂直冲击峰值、垂直主动峰值和VLR与测力台实测值之间差异没有统计学意义(见表2)。

3 分析讨论

本文发现,基于LSTM模型,从无标记动作捕捉系统获取的关节坐标估算所获GRF与实测值之间高度相关,且两种方法获取的曲线之间不存在统计学上的显著差异区间。此外,基于LSTM模型估算所获GRF曲线计算的特征值与实测值也无统计学显著差异。上述结果证明,LSTM模型结合无标记动作捕捉系统可作为在非实验室环境下获取动力学参数的一种有效手段,并可应用于RRI风险监控。

3.1 LSTM模型估算效果

本文结果支持研究假设①,即LSTM模型估算获得与实测的GRF曲线之间高度相关。本研究估算所得GRF与实测值之间的相关系数 r 在0.85~0.99之间,与前人基于IMU^[11-12,24,31-32]和体表反光点^[27-28]的相应结果接近,表明基于无标记动作捕捉系统获取的运动学数据可有效估算跑步动作下

GRF。此外,本文相关系数 r 还明显优于以图像二维关节点作为输入变量的研究^[25,33-34],提示三维关节点坐标含有的信息更丰富且对于模型估算效果更重要。左右方向上相关系数 r 低于其他方向,这与文献^[13, 24, 31, 33-34]结果类似。机器学习模型在处理变化幅度较大的数据时,具有更强的分类和预测效果。跑步动作下左右方向 GRF 变化幅度较小,故该方向的估算效果较差。在侧切变向等左右方向 GRF 幅度和变化较大的活动中^[26],模型在学习这些变化时更加有效,故估算结果具有更高的相似性。

本文基于 LSTM 模型,通过无标记动作捕捉系统所获关节点坐标估算得到的 GRF 误差较小。垂直 GRF 是跑步相关研究中的重要参数,本文估算误差(RMSE = 0.11BW, nRMSE = 4.36%) 优于前人研究中基于 IMU^[9,11,24,31]、体表反光点^[27-29]和二维图像关节点坐标^[25,33-35]的相应结果。在前后和左右 GRF 的估算误差方面,本文结果同样低于文献^[25, 31, 33-35]研究结果。本文认为,以无标记动作捕捉系统获取的关节点坐标作为输入变量时,其估算的跑步三维 GRF 误差更低。然而,垂直 GRF 估算误差要略大于 Ngoh 等^[12]结果,推测与本文测试速度要大于该研究有关。左右 GRF 具有较小的估算绝对误差和较大相对误差,该结果与前人研究结果一致^[25,31,35]。由于跑步过程中左右 GRF 的幅度较小,尽管绝对误差较低,但相对误差较大。目前,尚无明确证据表明左右方向 GRF 与 RRI 存在直接关联,因此该方向较差的估算效果对实际应用影响较小。

3.2 LSTM 模型估算 GRF 曲线效果

本文结果支持研究假设②,即 LSTM 模型估算获得与实测的 GRF 曲线之间不存在显著差异区间。相关系数 r 和 RMSE 等参数反映了模型的整个数据曲线估算效果,SPM 可以检测多组曲线间具有显著差异的部分,可以弥补上述参数的不足。LSTM 模型估算所获 3 个方向的 GRF 曲线与实测曲线之间均不存在显著差异区间,表明基于无标记动作捕捉系统获取的关节点坐标可准确估算跑步动作三维 GRF 曲线。Mundt 等^[25]研究发现,以图像二维关节点坐标估算所获跑步支撑阶段 GRF 曲线中,在前后和垂直方向上均与实测曲线具有显著差异的区间。

此外,Ripic 等^[36]基于 Kinect 结合肌骨模型估算步行动作 GRF,其估算结果与实测曲线在 3 个方向上均存在显著差异区间。上述结果提示,关节点三维坐标结合 LSTM 模型是获取人体运动过程中准确 GRF 曲线的有效手段。

3.3 LSTM 模型估算 GRF 特征效果

本文结果支持检验假设③,基于 LSTM 模型估算所得的 GRF 特征与实测值之间不存在显著差异。垂直冲击峰值、垂直主动峰值和 VLR 等指标已被证明与 RRI 的发生密切相关^[2,37]。为确保本文模型的应用效果,对上述指标的有效性进行分析。结果显示,垂直冲击峰值、垂直主动峰值和 VLR 的估算误差均小于文献^[9, 11-12, 27-29, 31]研究结果。此外,推进力峰值和制动力峰值估算误差同样小于文献^[29]研究结果。上述结果表明,下肢关节点三维坐标含有的信息足够用于 LSTM 模型准确估算跑步动作下 GRF 特征。然而,垂直主动峰值误差要大于 Bogaert 等^[38]基于 TSFresh 算法从胫骨加速度提取的特征作为输入的结果,从三维关节点坐标曲线中进一步提取特征作为输入变量可能会提升模型的估算性能。

3.4 未来应用

本文基于 LSTM 模型,利用无标记动作捕捉系统获取的三维关节点坐标,实现了跑步动作下三维 GRF 的准确估算。该方法具有以下优势:① LSTM 模型不需要对输入变量进行时间标准化,可实时进行数据估算,方便后期进行 VLR 和冲量等时间相关指标的计算;② 输入变量来自视频拍摄,其受环境限制较小,适用于训练比赛等户外环境。此外,本文提出的方法还可用于估算压力中心,并结合 Theia 获取的人体模型,进行关节动力学分析。

3.5 局限性

① 只选取了 1 种跑步速度进行训练和估算,在未来研究中应探究模型在其他跑步速度下的 GRF 估算效果。② 只选取了 Theia 这 1 种人体姿态识别算法获取的关节点坐标进行估算,然而,当使用如 Openpose 等其他常用的姿态识别算法获取的关节点坐标作为输入变量时,其 GRF 的估算效果尚不明确,需在后续研究加以验证。

4 结论

基于 LSTM 模型,可从 Theia3D 无标记动作捕

捉系统获取的关节坐标有效估算人体跑步的GRF曲线,并基于估算曲线可获得准确性较高的GRF特征。本研究建立的模型可用于户外环境下监控跑步过程中的损伤风险。

利益冲突声明:无。

作者贡献声明:周玉林负责研究设计、数据采集、数据分析及撰写论文;赵峻辰协助研究实施及数据采集;李翰君、时会娟、刘卉负责研究设计、研究指导和论文修改。

参考文献:

[1] 杨辰, 冯茹, 万祥林, 等. 跑步相关损伤危险因素与干预手段研究进展 [J]. 中国运动医学杂志, 2022, 41(6): 484-493.

[2] DAVIS IS, BOWSER BJ, MULLINEAUX DR. Greater vertical impact loading in female runners with medically diagnosed injuries: A prospective investigation [J]. Br J Sports Med, 2016, 50(14): 887-892.

[3] BREDEWEG SW, KLUITENBERG B, BESSEM B, *et al.* Differences in kinetic variables between injured and noninjured novice runners: A prospective cohort study [J]. J Sci Med Sport, 2013, 16(3): 205-210.

[4] COLLINS SH, ADAMCZYK PG, FERRIS DP, *et al.* A simple method for calibrating force plates and force treadmills using an instrumented pole [J]. Gait Posture, 2009, 29(1): 59-64.

[5] JOO SB, OH SE, MUN JH. Improving the ground reaction force prediction accuracy using one-axis plantar pressure: Expansion of input variable for neural network [J]. J Biomech, 2016, 49(14): 3153-3161.

[6] LIN F, WANG A, ZHUANG Y, *et al.* Smart insole: A wearable sensor device for unobtrusive gait monitoring in daily life [J]. IEEE T Ind Inform, 2016, 12(6): 2281-2291.

[7] ALGHAMDI MA, ABDULLAH S, RAGAB M. Predicting energy consumption using stacked LSTM snapshot ensemble [J]. Big Data Min Anal, 2024, 7(2): 247-270.

[8] MUNDT M, THOMSEN W, WITTER T, *et al.* Prediction of lower limb joint angles and moments during gait using artificial neural networks [J]. Med Biol Eng Comput, 2020, 58(1): 211-225.

[9] ALCANTARA RS, EDWARDS WB, MILLET GY, *et al.* Predicting continuous ground reaction forces from accelerometers during uphill and downhill running: A recurrent neural network solution [J]. Peer J, 2022(10): e12752.

[10] FOHRMANN D, MUNDT M, DAVID S, *et al.* Creating virtual force platforms for cutting maneuvers from kinematic

data based on lstm neural networks [C] //Proceedings of the ISBS Conference. Liverpool: NMU Common, 2020.

[11] WOU DA FJ, GIUBERTI M, BELLUSCI G, *et al.* Estimation of vertical ground reaction forces and sagittal knee kinematics during running using three inertial sensors [J]. Front Physiol, 2018(9): 218.

[12] NGOH KJ, GOUWANDA D, GOPALAI AA, *et al.* Estimation of vertical ground reaction force during running using neural network model and uniaxial accelerometer [J]. J Biomech, 2018(76): 269-273.

[13] MUNDT M, KOEPE A, DAVID S, *et al.* Prediction of ground reaction force and joint moments based on optical motion 0capture data during gait [J]. Med Eng Phys, 2020(86): 29-34.

[14] LIU D, MA Y, WANG J, *et al.* Convolutional neural network based ground reaction forces and center of pressure estimation during stair walking using multi-level kinematics [J]. Expert Syst Appl, 2024(243): 122868.

[15] COLYER SL, EVANS M, COSKER DP, *et al.* A review of the evolution of vision-based motion analysis and the integration of advanced computer vision methods towards developing a markerless system [J]. Sports Med Open, 2018, 4(1): 1-15.

[16] 苑廷刚, 王国杰, 何卫, 等. 视频图像多重处理技术在体育科研领域中的应用和发展 [J]. 中国体育科技, 2022, 58(11): 92-102.

[17] 刘卉, 李翰君, 曲毅, 等. 无反光点人体运动自动捕捉人工智能系统的有效性 [J]. 北京体育大学学报, 2021, 44(1): 125-133.

[18] SONG K, HULLFISH TJ, SCATTONE SILVA R, *et al.* Markerless motion capture estimates of lower extremity kinematics and kinetics are comparable to marker-based across 8 movements [J]. J Biomech, 2023(157): 111751.

[19] 滕君敏, 马晔, 刘东威, 等. 基于深度学习融合算法的无标记点步态分析系统 [J]. 医用生物力学, 2022, 37(4): 733-740.

TENG JM, MA Y, LIU DW, *et al.* Markerless gait analysis system based on deep learning fusion algorithm [J]. J Med Biomech, 2022, 37(4): 733-740.

[20] KANKO RM, LAENDE EK, DAVIS EM, *et al.* Concurrent assessment of gait kinematics using marker-based and markerless motion capture [J]. J Biomech, 2021(127): 110665.

[21] MORAN MF, ROGLER IC, WAGER JC. Inter-session repeatability of marker-less motion capture of treadmill running gait [J]. Appl Sci, 2023, 13(3): 1702.

[22] QUALISYS. paf-theia-markerless-example [EB/OL]. <https://github.com/qualisys/paf-theia-markerless-example>.

- [23] AKIBA T, SANO S, YANASE T, *et al.* Optuna: A next-generation hyperparameter optimization framework [C]// Proceedings of the Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining. Anchorage: ACM, 2019.
- [24] JOHNSON WR, MIAN A, ROBINSON MA, *et al.* Multidimensional ground reaction forces and moments from wearable sensor accelerations via deep learning [J]. IEEE Trans Biomed Eng, 2021, 68(1): 289-297.
- [25] MUNDT M, BORN Z, GOLDACRE M, *et al.* Estimating ground reaction forces from two-dimensional pose data: A biomechanics-based comparison of AlphaPose, BlazePose, and Open Pose [J]. Sensors, 2022, 23(1): 78.
- [26] 周玉林, 李翰君, 刘卉, 等. 基于神经网络以全身关节点坐标估算侧切变向动作下肢动力学参数 [J]. 中国体育科技, 2024, 60(11): 90-97.
- [27] 王冬梅, 郭文霞, 袁书芳, 等. 基于主成分分析和小波神经网络预测跑步中垂直地面反作用力 [J]. 医用生物力学, 2022, 37(4): 706-712.
- WANG DM, GUO WX, YUAN SF, *et al.* Predicting vertical ground reaction force during treadmill running using principal component analysis and wavelet neural network [J]. J Med Biomech, 2022, 37(4): 706-712.
- [28] WANG D, LI S, SONG Q, *et al.* Predicting vertical ground reaction force in rearfoot running: A wavelet neural network model and factor loading [J]. J Sports Sci, 2023, 41(10): 955-963.
- [29] KOMARIS DS, PEREZ-VALERO E, JORDAN L, *et al.* Predicting three-dimensional ground reaction forces in running by using artificial neural networks and lower body kinematics [J]. IEEE Access, 2019(7): 156779-156786.
- [30] YANG Z, CUI C, ZHOU Z, *et al.* Effect of midsole hardness and surface type cushioning on landing impact in heel-strike runners [J]. J Biomech, 2024(165): 111996.
- [31] SCHELTINGA BL, KOK JN, BUURKE JH, *et al.* Estimating 3D ground reaction forces in running using three inertial measurement units [J]. Front Sports Act Living, 2023(5): 1176466.
- [32] DORSCHKY E, NITSCHKE M, MARTINDALE CF, *et al.* CNN-based estimation of sagittal plane walking and running biomechanics from measured and simulated inertial sensor data [J]. Front Bioeng Biotech, 2020(8): 604.
- [33] MORRIS C, MUNDT M, GOLDACRE M, *et al.* Predicting ground reaction force components from two-dimensional video using machine learning [C]// Proceedings of XXVIII Congress of the International Society of Biomechanics. Stockholm: ISB, 2021.
- [34] GOLDACRE M, EL-SALLAM A, WYATT H, *et al.* Predicting ground reaction forces from 2D video: Bridging the lab to field nexus [C] // Proceedings of the 39th International Conference of the International Society of Biomechanics in Sports (ISBS 2021). Online Conference: NMU Common, 2021, 39(1): 9.
- [35] MUNDT M, OBERLACK H, GOLDACRE M, *et al.* Synthesising 2D video from 3D motion data for machine learning applications [J]. Sensors (Basel), 2022, 22(17): 6522.
- [36] RIPIC Z, KUENZE C, ANDERSEN MS, *et al.* Ground reaction force and joint moment estimation during gait using an Azure Kinect-driven musculoskeletal modeling approach [J]. Gait Posture, 2022(95): 49-55.
- [37] DICKINSON JA, COOK SD, LEINHARDT TM. The measurement of shock waves following heel strike while running [J]. J Biomech, 1985, 18(6): 415-422.
- [38] BOGAERT S, DAVIS J, VANWANSEELE B. Predicting vertical ground reaction force characteristics during running with machine learning [J]. Front Bioeng Biotechnol, 2024(12): 1440033.