

文章编号: 1004-7220(2023)03-0568-06

基于鞋垫传感器测量垂直地面反作用力的算法

邓盛中^{1,2}, 戴厚德², 陈昱光², 万邗琦^{1,2}

(1. 福州大学 先进制造学院, 福建 晋江 362251; 2. 中国科学院 海西研究院, 泉州装备制造研究中心, 福建 晋江 362216)

摘要: **目的** 提出一种实用、高精度的足底压力动态监测算法, 通过电容式鞋垫传感器测量走路时垂直地面反作用力 (vertical ground reaction force, vGRF), 并验证预测精度的可靠性。 **方法** 4名健康男性受试者穿戴电容式鞋垫传感器, 在 Kistler 三维测力台上采集快速和慢速行走数据。对电容式鞋垫传感器采集到的数据进行像素化处理, 处理后的数据输入残差神经网络 ResNet18, 预测得到高精度 vGRF。 **结果** 与 Kister 测力台收集的数据分析比较, 快速和慢速行走的归一化均方根误差 (normalized root mean square error, NRMSE) 分别为 8.40% 和 6.54%, 皮尔森相关系数 (Pearson correlation coefficient) 均大于 0.96。 **结论** 本研究为移动场景下 GRF 动态测量提供了一种新型算法, 可以用于实验室外完整 GRF 估计, 而不受测力台数量和位置的约束, 潜在应用领域包括步态分析以及有效捕捉病理性步态。

关键词: 鞋垫传感器; 垂直地面反作用力; 动态监测; 残差神经网络; 步态分析

中图分类号: R 318.01 文献标志码: A

DOI: 10.16156/j.1004-7220.2023.03.021

An Algorithm for Measuring Vertical Ground Reaction Force Based on Insole Sensors

DENG Shengzhong^{1,2}, DAI Houde², CHEN Yuguang², WAN Zhiyu^{1,2}

(1. School of Advanced Manufacturing, Fuzhou University, Jinjiang 362251, Fujian, China; 2. Quanzhou Institute of Equipment Manufacturing, Haixi Institutes, Chinese Academy of Sciences, Jinjiang 362216, Fujian, China)

Abstract: **Objective** A practical and highly accurate algorithm for dynamic monitoring of plantar pressure was proposed, the magnitude of vertical ground reaction force (vGRF) during walking was measured by a capacitive insole sensor, and reliability of the prediction accuracy was verified. **Methods** Four healthy male subjects were require to wear capacitive insole sensors, and their fast walking and slow walking data were collected by Kistler three-dimensional (3D) force platform. The data collected by the capacitive insole sensors were pixelated, and then the processed data were fed into a residual neural network, ResNet18, to obtain high-precision vGRF. **Results** Compared with analysis of the data collected from Kister force platform, the normalized root mean square error (NRMSE) for fast walking and slow walking were 8.40% and 6.54%, respectively, and the Pearson correlation coefficient was larger than 0.96. **Conclusions** This study provides a novel algorithm for dynamic measurement of GRF in mobile scenarios, which can be used for estimation of complete GRF outside the laboratory without being constrained by the number and location of force plates. Potential application areas include gait analysis and efficient capture of pathological gaits.

Key words: insole sensor; vertical ground reaction force (vGRF); dynamic monitoring; residual neural network; gait analysis

收稿日期: 2022-06-10; 修回日期: 2022-07-13

基金项目: 中央引导地方科技发展专项资金项目 (2020L3028, 2021L3047)

通信作者: 戴厚德, 研究员, E-mail: dhd@fjirsm.ac.cn

走路是人体运动最频繁的活动之一。对行走过程中足部的垂直地面反作用力 (vertical ground reaction force, vGRF) 进行方便而有效的评估,对康复训练、病理诊断和评估跌倒风险等至关重要^[1-4]。

三维测力台由于其高精度,被称为测量分析地面反作用力 (ground reaction force, GRF) 的金标准。然而,测力台安装固定在地面,测量范围受到限制,无法捕捉自由生活下的步态模式。此外,如果受试者刻意瞄准测力台,可能会导致步态不自然^[5]。

大量研究提出了移动传感技术来解决上述限制,近年来基于电容式传感器^[6-7]或者电阻式传感器^[8-9]的鞋垫有了很大发展。此外,机器学习方法,如线性回归和非线性回归被用来将鞋垫的测量值 (电容变化量、电阻变化量) 与实际 GRF 相拟合。Fong 等^[10]基于 PedarX 鞋垫的若干传感器通道测量值,线性加权估计 vGRF,然而这依赖对传感器的精确布置,否则会出现较大的偏载误差。Eng 等^[11]基于六轴光电传感器提出非线性加权的测量方案,虽然精度高,却需要复杂的传感器校准,处理周期长。Eguchi 等^[12]提出了基于约束函数的线性最小二乘拟合方案,实现了归一化均方根误差 (normalized root mean square error, NRMSE) 为 10%。Eguchi 等^[8]提出基于高斯过程回归学习模型的方法,预处理降低了设备的噪声误差,然而,不同步速 (快速和慢速行走) 对测量 vGRF 的影响还有待研究。

深度学习的发展为测量 vGRF 提供了另一种解决方案。Johnson 等^[13]基于放置在身体上的 8 个运动捕捉标记,对比分析了 5 种卷积神经网络 (convolutional neural network, CNN) 模型预测 vGRF 的效果,相关系数 r 最高达到 0.988,拟合性能极大提升。

本文基于自主研发的电容式传感器鞋垫,提出一种深度学习的 vGRF 预测算法。首先,将行走过程中足底若干传感器的一维变化量像素化处理后,得到 6×6 传感器输入变化量矩阵;接着,通过 ResNet18 残差网络模型预测输出实际 GRF。与传统算法相比,预期以更高的精度实现对足底压力分布和大小的动态监测;与传统采用测力台的测量方案相比,所设计的采集系统具有体积小、价格低、便携等优势。

1 材料和方法

1.1 鞋垫传感器

本文开发了一款每只鞋垫有 13 个电容式传感器的柔性鞋垫。电容随外部压力的变化而变化,可以根据压强与电容变化呈正相关的关系来预测施加在传感器区域的力。使用该鞋垫前,采用标准气压加压设备校准每个电容式传感器,消除传感器部分非线性测量因素^[9] (见图 1)。

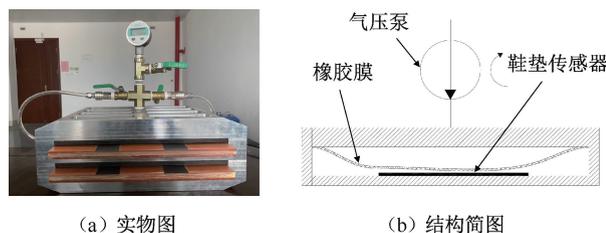


图 1 气压加压设备结构

Fig. 1 Structure of the gas pressurization equipment

(a) Picture, (b) Structure diagram

研究发现,行走过程中前脚掌承担 61% 的体重 (body weight, BW),后脚掌和中脚掌分别承担了约 34% BW 和 5% BW^[14]。相比之下,内侧足弓几乎没有压力。因此,单侧柔性鞋垫的传感器接触区域被划分为脚跟、跖趾关节、脚趾和外侧足弓中的 3 个区域,这可以覆盖典型足底压力分布中的生物力学负荷区。单侧传感模块由 1 个微控制器、1 个模数转换器、1 张 SD 卡和 1 个蓝牙传输模块组成。数据以 100 Hz 频率保存到 SD 卡上,或通过蓝牙传输到计算机上。1 双具有适当尺寸的鞋垫传感器被插入鞋中,存储盒被放在受试者的鞋子外面 (见图 2)。



图 2 数据采集系统

Fig. 2 Data collection system (a) Sensor distribution,

(b) Embedded modules

1.2 研究对象和数据采集

招募 4 名男性受试者参与本研究,年龄 (25.0 ±

2.6) 岁,身高(175±8) cm,体质量(76.1±14.2) kg。
招募条件:① 身体健康,实验前半年没有下肢损伤;
② 脚尺寸和鞋垫传感器大小相近,41 码;③ 行走习
惯脚后跟先触地。

数据采集在运动分析实验室进行,同时从 Kistler 三维测力台和鞋垫传感器收集数据。实验前,测力台和鞋垫的采样频率都被设定为 100 Hz, 以方便数据同步。实验当天,受试者穿着插有鞋垫传感器的鞋,自行选择步速(快速、慢速)行走,第 4 步或者第 5 步接触安装在地面上的测力台。如果足部完全落在测力台并且没有出现步态不自然,则该数据就被保存为样本。每位受试者在测力板上采集 20 步快速、慢速行走有效数据(见图 3)。每一步包含 60~90 组样本点(100 Hz 采样频率下,步速不同,每一步采集的样本点数量也不一样),4 名受试者总计采集 6 164 组有效样本点。



图 3 数据采集
Fig. 3 Data acquisition

1.3 残差神经网络

1.3.1 数据预处理 将测力台采集的 vGRF 和鞋垫传感器采集的 13 路传感器变化量校准、时间同步后,导入 Pycharm 中便于进行数据分析。13 路传感器变化量 X 可表示为:

$$X = (x_1, x_2, \dots, x_i)^T, \quad i = 13 \quad (1)$$

对于 vGRF 预测,使用 Tensorflow 环境和 Python 3.7 搭建残差神经网络 ResNet18 模型。其中,13 路传感器的数据 X 作为残差神经网络的输入特征,三维测力台采集的 vGRF 作为网络回归预测的真值。

为了更好地保存 13 路传感器变化量的大小和位置信息,根据传感器分布情况,将一维展平的输

入特征 X 转换为 6×6 的矩阵:

$$X^T = \begin{pmatrix} 0 & 0 & x_1 & x_2 & 0 & 0 \\ 0 & x_3 & x_4 & x_5 & x_6 & 0 \\ 0 & 0 & x_7 & 0 & 0 & 0 \\ 0 & 0 & x_8 & x_9 & 0 & 0 \\ 0 & 0 & x_{10} & x_{11} & 0 & 0 \\ 0 & 0 & x_{12} & x_{13} & 0 & 0 \end{pmatrix} \quad (2)$$

随后,将 X^T 中的数据转换为 6×6 的灰度图(见图 4),通过 ResNet18 网络可以更好地训练像素化的输入矩阵数据,ResNet 的残差块可以防止梯度爆炸或者降级^[15-16]。



图 4 像素化输入特征 X
Fig. 4 Pixelate input feature X

1.3.2 网络训练 ResNet 网络的训练在 Tensorflow 环境下 Keras 库中进行。网络的损失函数定义为均方误差(mean square error, MSE):

$$E_i = \frac{1}{2}(f_i - f_{est})^2 \quad (3)$$

式中: f_i 为测力台收集的真实 vGRF; f_{est} 为网络的估计值。

设置初始学习率 lr 为 0.001,最大迭代次数 Epochs 为 1 000,批 batch 为 32,Adam 被选为优化器。

1.3.3 交叉验证 当数据样本量较小时,仅选择 1 组训练集和测试集可能会导致模型的评估结果可靠性不足。交叉验证是一种验证神经网络预测性能的统计学方法^[24]。 k 折交叉验证是将样本分成 k 个互斥的子集,每次选择 $(k-1)$ 个子集为训练集,1 个子集为测试集,从而可以获得 k 次测试结果,将 k 次结果的平均值作为该算法的预测准确率。实验采用 5 折交叉验证,将数据随机 5 等分,其中 4 份数据作为训练集,1 份数据作为测试集。

1.4 评价指标

为了评估预测网络的性能,将鞋垫的预测结果与三维测力台的测量真值进行比较。计算每一步的 NRMSE 和 Pearman 相关系数。其中,NRMSE 用于评估预测值和真实值之间的误差,在预测 vGRF 的工作中被广泛使用。NRMSE 定义为:

$$\text{NRMSE} = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (f_{pi} - f_{ii})^2}}{mg} \times 100 \quad (4)$$

式中: f_{pi} 为三维测力台采集的 vGRF; f_{ii} 为鞋垫传感器估计的 vGRF; n 为该样本的采样点数量; mg 为受试者的体重。

为了评估 NRMSE,本文将估计准确度的临界值设为 10%,因为该值通常用于相关工作^[21-22],并且已经报告了其捕捉病理性步态的有效性。

皮尔森相关系数 (Pearson correlation coefficient) 的范围是 0~1,它用于比较两条曲线的相似性,定义为:

$$R = \frac{E(f_i f_{est}) - E(f_i)E(f_{est})}{\sqrt{E(f_i^2) - E^2(f_i)} \sqrt{E(f_{est}^2) - E^2(f_{est})}} \quad (5)$$

式中: f_i 是三维测力台收集的 vGRF; f_{est} 是鞋垫传感器的估计值。

一般认为, $R = 0.9 \sim 1.0$ 、 $0.7 \sim 0.9$ 、 $0.5 \sim 0.7$ 、 $0.3 \sim 0.5$ 分别表示相关性非常高、高、中等、低,而 $R < 0.3$ 表示相关性可以忽略^[17]。

此外,为了验证所提出预测 vGRF 算法的优势,在相同数据集的基础上进行线性最小二乘拟合^[9],作为比较方案。

2 结果与讨论

本文发现,受试者穿戴鞋垫传感器慢速行走和

快速行走时,神经网络估计值的均值和标准差与测力板测力值相近(见图 5)。所提出算法的预测值与三维测力台采集的真实值相比,快慢行走两种步态下估计 vGRF 的相关性整体显示出良好性能,相关系数 r 均大于 0.96。快速行走下的预测精度要略低于慢速行走下的预测精度,推测原因如下:① 步态速度和 vGRF 峰值之间存在正相关关系^[19]。vGRF 峰值从 1.5 m/s 时的 1.2 BW 增加到 6 m/s 时的 6.0 BW,整体上较大力导致预测误差增大;② 快速行走下,覆盖在鞋垫传感器表面的复合材料 (ethylene vinyl acetate, EVA) 层产生形变,影响传感器的受力分布。本文所提出的神经网络算法估计 vGRF 误差在 10% 以内,未来可能应用于有效捕捉病理性步态的工作中,如扁平足^[18] 和中风患者^[22]。

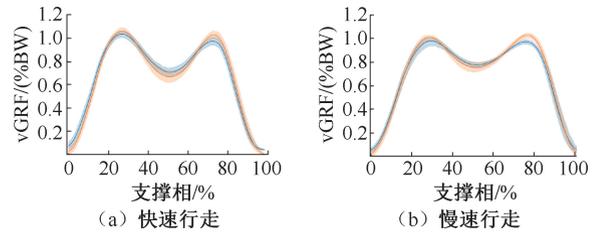


图 5 不同速度行走时神经网络估计值估计结果

Fig. 5 Estimation results of ResNet18 at different walking speeds (a) Fast walking, (b) Slow walking

表 1 总结了 5 折交叉验证下 4 名受试者慢速行走和快速行走时的 NRMSE 和 r 相关系数。结果表明,对于 NRMSE,与线性最小二乘法比较,所提出的基于 ResNet 残差神经网络预测算法提高了估计精度,慢速行走和快速行走时所有受试者平均 NRMSE 分别为 6.54% 和 8.40%,而基于传统线性最小二乘法下两种步态的平均 NRMSE 为 9.27% 和 11.93%。

表 1 不同速度行走时预测 vGRF 精度对比

Tab. 1 Comparison of predicted vGRF accuracy at different walking speeds

受试者	慢速行走				快速行走			
	ResNet 神经网络		线性最小二乘法		ResNet 神经网络		线性最小二乘法	
	NRMSE/%	r	NRMSE/%	r	NRMSE/%	r	NRMSE/%	r
A	7.30±2.90	0.97±0.02	9.38±1.45	0.95±0.03	8.83±1.65	0.96±0.01	11.88±1.32	0.93±0.02
B	6.38±1.97	0.98±0.01	9.63±2.08	0.95±0.01	7.87±1.44	0.96±0.01	12.17±2.88	0.92±0.04
C	5.07±1.50	0.98±0.01	8.79±2.14	0.96±0.02	7.25±2.73	0.97±0.02	10.02±2.54	0.94±0.04
D	7.43±2.32	0.96±0.03	9.31±1.85	0.95±0.03	9.66±1.82	0.95±0.01	13.65±1.69	0.91±0.03
平均值	6.54±2.03	0.97±0.02	9.27±1.91	0.95±0.02	8.40±1.98	0.96±0.01	11.93±2.21	0.92±0.03

Park 等^[9]采用线性最小二乘拟合估计走路和跑步过程中的 vGRF, 结果表明, 长距离行走的 NRMSE 仅为 14.68%, 本文所提出的估计精度优于此项研究。Howell 等^[22]在传感器布局上进行优化, 同时验证正常受试者和中风患者的 VRGF 预测精度, 但是该研究未考虑走路速度对精度的影响, 该算法在各种速度下的适用性还有待验证。Eng 等^[11]基于自主研发的六自由度传感器, 对比分析线性校准和神经网络非线性校准的 vGRF 预测精度, 分别为 9.39% 和 5.21%; 然而该研究没有经过交叉验证, 预测模型的泛化性还有待研究, 故在实际使用过程中可能存在精度下降的问题^[25]。

行走过程中, 根据鞋垫传感器预测的 vGRF 大小与分布能够识别出支撑相的 5 个步态阶段(见图 6), 即通过 Python 编写上位机将足底压力可视化。结果表明, 受试者在初始接触阶段 vGRF 不断增大, 脚后跟着地阶段时达到第 1 个波峰, 随着整足接触阶段形成波谷, 接着脚后跟离地阶段达到第 2 个波峰, 最后整足离地阶段 vGRF 不断变小, 直到为 0。压力可视化结果表明, 所提出的 vGRF 估计算法未来可以应用在步态分析的相关领域^[20]。

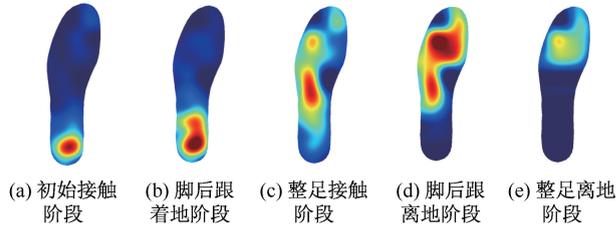


图 6 基于 vGRF 预测识别步态阶段

Fig. 6 Identifying gait stages based on vGRF prediction (a) The moment the heel first touches the ground, (b) The moment the heel hits the ground completely, (c) The moment the entire foot hits the ground, (d) The moment the heel leaves the ground, (e) The moment toes leave the ground

本研究的局限性如下: ① 残差神经网络模型的训练中只包含快慢行走两种样本, 这意味着这些结果不能立即推广到更广泛的运动模式中, 否则可能会导致预测结果的过拟合; ② 只调查了 4 名健康成年男性的使用情况, 女性、老年人和步态切换障碍者的适用性尚不清楚。同时, 样本较小可能会影响模型的泛化性。

本文搭建的采集系统和算法可被应用于一些

临床使用或者需要动态测量足底压力的场景, 以便医生、患者更有效地进行康复评估或者病理诊断。例如, 临床医生可以根据从膝关节骨性关节炎患者收集的 vGRF 数据, 制定更有效的个性化定制治疗方案^[21]。

3 结语

本文基于深度学习提出了一种预测行走过程 vGRF 的算法。预测结果与三维测力台相比, NRMSE < 10%, 相关系数 $r > 0.96$, 具有较高的准确性。

参考文献:

- [1] ZHOU Z, LIANG B, HUANG G, *et al.* Individualized gait generation for rehabilitation robots based on recurrent neural networks [J]. *IEEE Trans Neural Syst Rehabil Eng*, 2020, 29: 273-281.
- [2] HSIAO HY, GRAY VL, CREATH RA, *et al.* Control of lateral weight transfer is associated with walking speed in individuals post-stroke [J]. *J Biomech*, 2017, 60: 72-78.
- [3] ALAM MN, GARG A, MUNIA T, *et al.* Vertical ground reaction force marker for Parkinson's disease [J]. *PLoS One*, 2017, 12(5): 1-13.
- [4] LAROCHE DP, COOK SB, MACKALA K. Strength asymmetry increases gait asymmetry and variability in older women [J]. *Med Sci Sports Exerc*, 2012, 44(11): 2172-2181.
- [5] GREENHALGH A, TAYLOR PJ, SINCLAIR J. The influence of different force and pressure measuring transducers on lower extremity kinematics measured during walking [J]. *Gait Posture*, 2014, 40(3): 476-479.
- [6] AQUEVEQUE P, OSORIO R, PAS Ten EF, *et al.* Capacitive sensors array for plantar pressure measurement insole fabricated with flexible PCB [C]//*Proceedings of 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. Honolulu: IEEE, 2018.
- [7] MAZUMDER O, KUNDU AS, BHAUMIK S. Development of wireless insole foot pressure data acquisition device [C]//*Proceedings of International Conference on Communications*. Kolkata: IEEE, 2013.
- [8] EGUCHI R, TAKAHASHI M. Insole-based estimation of vertical ground reaction force using one-step learning with probabilistic regression and data augmentation [J]. *IEEE Trans Neural Syst Rehabil Eng*, 2019, 27(6): 1217-1225.
- [9] PARK J, NA Y, GU G, *et al.* Flexible insole ground reaction force measurement shoes for jumping and running

- [C]// Proceedings of 6th IEEE International Conference on Biomedical Robotics and Biomechanics (BioRob). Singapore: IEEE, 2016.
- [10] FONG TP, CHAN YY, HONG Y, *et al.* Estimating the complete ground reaction forces with pressure insoles in walking [J]. *J Biomech*, 2008, 41(11): 2597-2601.
- [11] ENG S, AL-MAI O, AHMADI M, *et al.* A 6 DoF, wearable, compliant shoe sensor for total ground reaction measurement [J]. *IEEE Trans Instrum Meas*, 2018, 67(11): 2714-2722.
- [12] EGUCHI R, YOROZU A, FUKUMOTO T, *et al.* Estimation of vertical ground reaction force using low-cost insole with force plate-free learning from single leg stance and walking [J]. *IEEE J Biomed Health Inform*, 2020, 24(5): 1276-1283.
- [13] JOHNSON WR, ALDERSON J, LLOYD D, *et al.* Predicting athlete ground reaction forces and moments from spatio-temporal driven cnn models [J]. *IEEE Trans Biomed Eng*, 66(3): 689-694.
- [14] MCKAY MJ, BALDWIN JN, FERREIRA P, *et al.* Spatiotemporal and plantar pressure patterns of 1000 healthy individuals aged 3-101 years [J]. *Gait Posture*, 2017, 58: 78-87.
- [15] CHOROMANSKA A, HENAFF M, MATHIEU M, *et al.* The loss surfaces of multilayer networks [C]// Proceedings of 18th International Conference on Artificial Intelligence and Statistics. San Diego: [s. n.], 2014.
- [16] HE K, ZHANG X, REN S, *et al.* Deep residual learning for image recognition [C]// Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016.
- [17] MUKAKA M. Statistics corner: A guide to appropriate use of correlation coefficient in medical research [J]. *J Med Malawi*, 2012, 24(3): 69-71.
- [18] 苏宏伦, 郭俊超, 莫中军, 等. 个性化扁平足矫形鞋垫的生物力学研究[J]. *医用生物力学*, 2016, 31(6): 490-494.
SU HL, GUO JC, MO ZJ, *et al.* Biomechanical study on the personalized orthopedic insoles for flatfoot [J]. *J Med Biomech*, 2016, 31(6): 490-494.
- [19] KELLER TS, WEISBERGER AM, RAY JL, *et al.* Relationship between vertical ground reaction force and speed during walking, slow jogging, and running [J]. *Clin Biomech*, 1996, 11(5): 253-259.
- [20] 赵敬, 李新伟, 何秉泽, 等. 基于运动学参数和足底压力测量的髌离断截肢者步态分析 [J]. *医用生物力学*, 2022, 37(1): 79-84.
ZHAO J, LI XW, HE BZ, *et al.* Gait analysis of hip disarticulation amputees based on kinematic parameters and plantar pressure measurement [J]. *J Med Biomech*, 2022, 37(1): 79-84.
- [21] FRANSEN M, MCCONNELL S, HARMER AR, *et al.* Exercise for osteoarthritis of the knee: A Cochrane systematic review [J]. *Br J Sports Med*, 2015, 49(24): 1554-1557.
- [22] HOWELL AM, KOBAYASHI T, HAYES HA, *et al.* Kinetic gait analysis using a low-cost insole [J]. *IEEE Trans Biomed Eng*, 2013, 60(12): 3284-3290.
- [23] JACOBS DA, FERRIS DP. Estimation of ground reaction forces and ankle moment with multiple, low-cost sensors [J]. *J Neuroeng Rehabil*, 2015, 12: 90.
- [24] KOHAVI R. A study of cross-validation and bootstrap for accuracy estimation and model selection [C]// Proceedings of International Joint Conference on Artificial Intelligence. Montreal: [s. n.], 1995.
- [25] ENI H, APOORVA R, MADALINA F, *et al.* Machine learning in human movement biomechanics: best practices, common pitfalls, and new opportunities [J] *J Biomech*, 2018, 81: 1-11.