

文章编号:1004-7220(2022)01-0073-06

基于惯性传感网络的穿戴式步行膝关节力矩估计

王钊鑫, 谈天, Peter B. SHULL

(上海交通大学 机械与动力工程学院, 机器人研究所, 上海 200240)

摘要:目的 通过惯性传感网络 (inertial sensor network, ISN) 估计多种步态下膝关节内翻力矩 (knee adduction moment, KAM) 和膝关节屈曲力矩 (knee flexion moment, KFM)。方法 12 名健康成年男性穿戴 8 个惯性传感器 (位于躯干、骨盆、左右大腿、左右小腿、左右脚) 在不同步态下 (改变足偏角、躯干摇晃角、步宽和步速) 行走。使用 ISN, 并从中提取生物力学特征作为循环神经网络 (recurrent neural network, RNN) 模型的输入, 用于估计 KAM 和 KFM。结果 整体 KAM 估计精度: 相对均方根误差 (relative root mean square error, rRMSE) 为 8.54%, $r=0.84$; 整体 KFM 估计精度: rRMSE=6.40%, $r=0.94$ 。结论 该 RNN 模型可作为实验室外膝关节载荷估计的基础, 潜在应用领域包括步态训练以及膝关节术后康复效果评估。

关键词: 膝关节内翻力矩; 膝关节屈曲力矩; 惯性传感网络; 循环神经网络; 步态分析

中图分类号: R 318.01 文献标志码: A

DOI: 10.16156/j.1004-7220.2022.01.011

Knee Joint Moment Estimation During Walking via Wearable Inertial Sensor Network

WANG Dianxin, TAN Tian, Peter B. SHULL

(Institute of Robotics, School of Mechanical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China)

Abstract: Objective To estimate knee adduction moment (KAM) and knee flexion moment (KFM) under different gait test conditions via an inertial sensor network (ISN). **Methods** Twelve healthy young male subjects wore eight inertial sensors (located in the trunk, pelvis, both thighs, both shanks, both feet) and walked under different test conditions (changing foot progression angle, trunk sway angle, step width and walking speed). An ISN was used to extract biomechanical features as the input of recurrent neural network (RNN), so as to estimate the KAM and KFM. **Results** The overall KAM estimation accuracy: relative root mean square error (rRMSE) was 8.54% and $r=0.84$. The overall KFM estimation accuracy was rRMSE = 6.40% and $r=0.94$. **Conclusions** The model can be used as the basis for load estimation of knee joints out of the lab and its potential application includes gait training and rehabilitation assessment after knee surgery.

Key words: knee adduction moment (KAM); knee flexion moment (KFM); inertial sensor network (ISN); recurrent neural network (RNN); gait analysis

收稿日期: 2021-01-22; 修回日期: 2021-03-06

基金项目: 国家自然科学基金项目 (51875347)

通信作者: Peter B. Shull, 副教授, E-mail: pshull@sjtu.edu.cn

膝关节炎是当今最主要的健康威胁之一,多患于中老年人群^[1]。在中国 50 岁以上的中老年人群中,男、女性的膝关节炎发病率分别为 5% 和 25%,且仍有上升趋势^[2]。生物力学相关研究表明,膝关节内翻力矩(knee adduction moment, KAM)是一个表征膝关节内部载荷的重要参数,与膝关节疼痛系数、症状严重程度、软骨减少程度等因素紧密相关^[3-5]。膝关节屈曲力矩(knee flexion moment, KFM)则是另一种常用的生物力学指标,其对胫骨软骨和髌骨软骨的退化具有重大影响^[6-8]。因此,综合分析 KAM 和 KFM 可以提供更加全面的关节负荷评估^[9-10]。有研究利用步态训练来减少 KAM 和 KFM,例如通过更改足偏角^[11-12]或躯干摇摆角^[13]等减小作用力臂。步态训练一般需要以 KAM 和 KFM 作为验证指标,故准确估计 KAM 和 KFM 有助于膝关节炎的病理分析以及后续的康复治疗诊断^[14]。

目前,多数 KAM 和 KFM 的测量依赖于实验室特有的视觉运动捕捉系统及测力装置。该测量方法精度高,但是需要膝关节患者定期往返实验室。相比之下,在居家乃至室外场景下的测量方法,可以显著降低患者的时间成本。基于惯性测量单元的传感网络,具有体积小、质量轻、功耗低、价格远低于实验室设备等优势,是一种合适的可穿戴传感方式。本文提出一个用于估计 KAM 和 KFM 的循环神经网络(recurrent neural network, RNN)模型。

1 材料与方法

1.1 实验对象

招募 12 名健康成年男性志愿者,年龄(23.0 ± 1.0)岁,身高(1.75 ± 0.05)m,体重(65.6 ± 5.7)kg,身体质量指数(body mass index, BMI)为(21.4 ± 2.0) kg/m^2 。排除标准为有下肢肌骨疾病史。本研究经过上海交通大学附属第六人民医院伦理委员会批准,所有受试者均签署知情同意书。

1.2 实验设备

具有 10 个摄像头的视觉运动捕捉系统(Vicon 公司,英国)以 100 Hz 采集固定在受试者身上的 32 个反光标记。反光标记点固定于:左右肩胛骨下角中点、第 7 颈椎、胸骨剑突、胸骨柄、肩峰、髌嵴、髌后上棘、股骨大转子、股骨中间、内外股骨髁、

胫骨节点、胫骨中间、内外踝、足跟后方、脚背第 2、5 跖趾关节。双带测力跑台(Bertec Fit 公司,美国)以 1 kHz 频率同步采集受试者受到的地面反作用力(ground reaction force, GRF)。配备 8 个惯性传感器的惯性传感系统(Sagemotion 公司,美国)以 100 Hz 采集身体各个部位的角速度和加速度。惯性传感器通过绑带固定在 8 个身体部位:躯干(胸骨中心)、骨盆(两侧髂前上棘的中点)、双股(髌嵴和外侧髌的中点)、双胫(外侧髌和外踝的中点)、双足(第 2 跖骨)。惯性传感器三维坐标 x 、 y 、 z 轴分别于受试者的左右、前后、上下方向对齐(见图 1)。




图 1 惯性传感网络、视觉运动捕捉系统、测力跑台布局图
Fig.1 Instrumentation layout of inertial sensor network, optical motion capture system and treadmill with embedded force plates

1.3 实验过程

测试条件包括不同的步行速度、足偏角、步宽和躯干摇晃角。足偏角为足后跟到第 2 跖趾关节所在直线与跑步机长边所在直线的夹角^[15]。步宽为双足着地时双足踝关节中心的沿着跑步机短边的投影距离^[16]。躯干摇晃角为两侧髌后上棘的中心到两侧肩峰的中心所在的直线与地面垂直轴之间在实验室冠状面投影的最大夹角^[16]。由于惯性传感网络和视觉运动捕捉系统两者采集并不同步,需要受试者作同步动作(摆动右小腿 3 次)以便后续进行数据对齐操作。

首先,受试者选定其舒适的基准步速(1.16 ± 0.04)m/s。随后,进行持续 2 min 正常步行实验,并计算足偏角和步宽作为后续实验的基准。受试者按随机顺序进行足偏角、步宽和躯干摇晃角试验。足偏角试验由 3 种步行速度(正常速度

-0.2 m/s、正常速度和正常速度+0.2 m/s)和3种足偏角度(基准足偏角-15°、基准足偏角和基准足偏角+15°)交叉组合而成^[17]。步宽试验由3种步行速度(同足偏角实验)和3种步行宽度(基准步宽-54 mm、基准步宽和基准步宽70 mm)交叉组合^[16]。躯干摇晃角试验由3种步行速度(同足偏角实验)和3种躯干摇晃角(4°、8°和12°)交叉组合^[13]。每个组合持续30 s,故每种试验持续4.5 min。每个试验内的组合按随机顺序进行。受试者根据实时的视觉反馈做出步态更改。在每次试验开始时,受试者将练习一段时间直至能适应视觉反馈及步态改变。

1.4 数据预处理

三维光标数据和测力板原始数据通过4阶低通巴特沃斯滤波器进行去噪处理,截止频率为15 Hz^[18]。步行时支撑相和摆动相通过垂直方向GRF识别,阈值为20 N^[19]。用于参考的真值力矩根据右侧GRF和膝关节中心的作用力臂叉乘积得出。KAM和KFM分别对应真值力矩在额状面和矢状面上的分量^[20],并对身高(body height, BH)和体重(body weight, BW)进行归一化:

$$\text{KAM} = \frac{r_z F_x - r_x F_z}{\text{BW} \cdot \text{BH}} \quad (1)$$

$$\text{KFM} = \frac{r_z F_y - r_y F_z}{\text{BW} \cdot \text{BH}} \quad (2)$$

式中: r 为GRF压力中心到膝关节的矢量; F 为GRF; x 沿着跑步机短边指向受试者右侧, y 沿着跑步机长边指向受试者前侧, z 为垂直方向向上。

根据受试者同步动作的角速度幅值,对视觉运动捕捉系统数据与惯性传感数据进行同步对齐。根据右足的惯性传感数据检测出足跟着地和足尖离地时刻,将连续惯性传感数据切片成离散的数据(从足跟着地前0.2 s到足尖离地后0.2 s)^[21]。

1.5 KAM和KFM估计模型

KAM和KFM估计模型包括以下3个步骤。首先,从惯性传感数据中提取生物力学特征:加权加速度 α^s 和右侧足部及小腿角速度 ω 。然后,将提取的生物力学特征分别作为6个RNN的输入,并估计GRF分量 F_x 、 F_y 及 F_z 以及膝关节中心的作用力臂分量 r_x 、 r_y 和 r_z 。最后通过式(1)、(2)分别计算出KAM和KFM(见图2)。

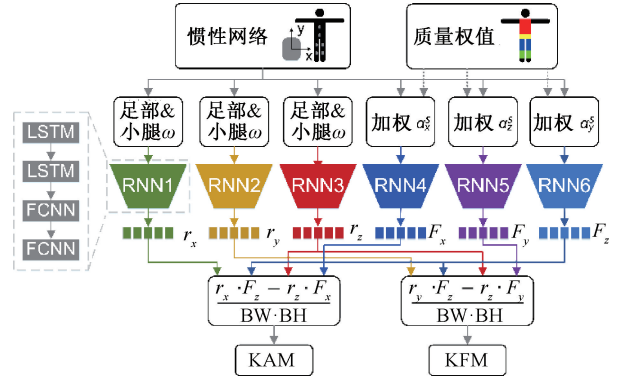


图2 膝关节内翻和屈曲力矩估计模型框架

Fig.2 Frame of the model for KAM and KFM estimation

生物力学特征选择依据解释如下。对于GRF,可以通过牛顿第2定律进行推导:

$$F = \sum_{i=1}^N m_i (\alpha_i^G + g) \quad (3)$$

式中: N 为身体部位的数量; m_i 表示为身体部位 i 的质量; α_i^G 是全局坐标系 G 下的身体部位 i 的加速度; g 为重力加速度。加权 α^s 由近似部位质量(受试者BW与部位质量比例^[22]的乘积)和惯性传感数据所测加速度的乘积。加权 α^s 采用传感器局部坐标系 s 而非式(3)所使用全局坐标系,无法直接通过式(3)计算GRF,故通过RNN网络学习加权加速度与GRF之间的映射关系。 r 为GRF压力中心到膝关节中心的向量,其强烈依赖于右侧小腿和右侧足部的精细运动,故将右侧足部及小腿的角速度 ω 作为 r_x 、 r_y 、 r_z 估计网络的输入。

每一个RNN子网络包括两层双向长短期记忆人工神经网络(long short-term memory, LSTM)和两层全连接网络(fully connected neural network, FCNN)。每一层LSTM和FCNN均包含10个神经元。第1层FCNN为激活函数的修正线性单元,而第2层FCNN不设置激活函数。

KAM估计模型和KFM估计模型通过开源机器学习框架Pytorch 1.7.0进行构建和训练。在训练前,加权加速度整体使用最大最小值归一化,其余特征逐通道使用最大最小值归一化。训练过程分两个阶段进行:在阶段1,各个RNN子网络根据KAM和KFM的组成部分(如 F_x)作为网络输出以及对应的生物力学特征作为网络输入(如加权 α^s)单独训练。设置该阶段的损失函数为均方差

(mean square error, MSE), 优化器为 ADAM, 学习速率为 3×10^{-3} , 迭代次数为 5, 批尺寸为 20; 在阶段 2, 4 个独立的 RNN 子网络结合起来, 并以 KAM 或 KFM 作为整体网络的输出进行微调训练。该阶段相比阶段 1, 学习速率调整为 3×10^{-4} , 批尺寸为 200。

该网络通过交叉验证法进行训练和评估, 循环从所有受试者中取出一个受试者作为测试集验证网络泛化能力, 剩余受试者作为训练集训练网络。以支撑相期间的均方根误差 (root mean square error, RMSE)、相对均方根误差 (relative root mean square error, rRMSE)、互相关系数 (r)、平均绝对误差 (mean absolute error, MAE) 作为网络估计精度评价指标:

$$RMSE = \sqrt{\left(\sum_{t=1}^N (y_{\text{estimated}}(t) - y_{\text{measured}}(t))^2\right) / N} \quad (4)$$

$$rRMSE = \frac{RMSE}{\left(\max_{1 \leq t \leq N} y_{\text{measured}}(t) - \min_{1 \leq t \leq N} y_{\text{measured}}(t)\right)} \quad (5)$$

式中: N 为试验的采样点数量; t 为采样点序号; $y_{\text{estimated}}$ 为估计值, y_{measured} 为真值。

2 结果

KAM 和 KFM 估计值的均值和标准差与真实值相接近 (见图 3)。KAM 估计结果的 MAE (10^{-3})、RMSE (10^{-3})、rRMSE (%)、 r 分别为 5.41 ± 1.85 、 6.92 ± 2.45 、 8.54 ± 2.76 、 0.84 ± 0.06 。KFM 估计结果的 MAE (10^{-3})、RMSE (10^{-3})、rRMSE (%)、 r 分别为 6.34 ± 1.31 、 8.14 ± 1.67 、 6.40 ± 1.21 、 0.94 ± 0.03 。KFM 的 rRMSE 优于 KAM 的 rRMSE。基准试验的 rRMSE 高于其他步态测试条件下的 rRMSE (见表 1)。




图 3 膝关节内翻和屈曲力矩估计结果

Fig. 3 Estimation results of knee adduction and flexion moments (a) Knee adduction moment, (b) Knee flexion moment

表 1 不同步态测试条件下膝关节内翻和屈曲力矩估计精度对比
Tab.1 Comparison of estimation accuracy for knee adduction flexion moment under different testing conditions

参数	测试条件	RMSE (10^{-3})	rRMSE/%	r
KAM	基准试验	6.03 (2.21)	10.11 (3.03)	0.88 (0.04)
	足偏角试验	7.17 (2.44)	7.32 (2.33)	0.86 (0.03)
	步宽试验	6.78 (2.63)	8.74 (2.43)	0.85 (0.05)
KFM	躯干摇晃角试验	7.60 (2.30)	9.71 (2.28)	0.79 (0.07)
	基准试验	7.78 (1.81)	7.18 (1.37)	0.94 (0.04)
	足偏角试验	7.91 (1.09)	6.32 (0.87)	0.93 (0.02)
	步宽试验	7.73 (1.47)	6.36 (1.15)	0.94 (0.02)
	躯干摇晃角试验	9.04 (2.15)	6.52 (1.31)	0.95 (0.02)

注: RMSE 和 rRMSE 的定义见式(4)和(5)。

3 讨论

本文重点提出基于惯性传感网络 (inertial sensor network, ISN) 膝关节力矩估计模型。该神经网络模型以 8 个可穿戴惯性传感器组成的传感网络数据作为输入, 并输出 KAM 和 KFM 估计值。该模型在不同步态测试条件下, KAM 和 KFM 估计结果 rRMSE 为 6.32% ~ 10.11%。实验结果表明, 通过 ISN 估计 KAM 和 KFM 具备一定的可行性。

Stetter 等^[23] 提出一种人工神经网络模型来估计各种日常生活活动中的 KAM。30 名受试者在大腿与小腿处的各固定 1 个惯性传感器, 并执行 6 种日常生活中运动 (如直行、转向等)。直行下 KAM 的估计结果为 $r = 0.71$ 和 $rRMSE = 22.3\%$, KFM 的估计结果为 $r = 0.72$ 和 $rRMSE = 18.4\%$ 。Brabandere 等^[24] 使用智能手机里的惯性传感器及全连接网络来估计髌、膝关节处载荷, 得到膝关节载荷的估计结果为 $rRMSE = 29.1\%$ 。Wang 等^[25] 通过固定在膝盖附近两个惯性传感器数据作为全连接神经网络的输入来估计 KAM。该网络在针对受试者作特定矫正后, 其平均决定系数 R^2 可以达到 0.956, 然而该研究并没有验证该神经网络对未曾参与过网络训练的受试者的泛化能力, 故该网络在实际使用时可能存在精度下降^[26]。Karatsidis 等^[27] 用 17 个惯性传感器及肌肉骨骼模型进行逆向运动学分析并计算膝关节力矩, 得到 KAM、KFM 估计结果的 rRMSE 分别为 18.9%、29.8%。本文提出的网络估计模型在估计精度上优于上述已有研究, 推测原因如下: ① 使用 ISN 能够较为完整采集身体各个部位的运动信息, 例如在 Stetter 等^[23] 的研究中并未采集

躯干的运动数据,而躯干质量占比大,对膝关节力矩有不可忽视的影响。② 通过采集多种步态测试情况,扩大数据集内部的差异性,从而增强了训练集的丰富性和代表性。③ 本文提出的模型结合了具备记忆力的 LSTM,非常适合用于处理与时间序列高度相关的问题。此外,LSTM 无需对每步进行重采样至相同窗口长度,因此保留了每一步的时间长度信息。④ 结合生物力学知识进行特征提取,将部分相关性较大的模态数据拆分重组作为输入,分别估计 r_x 、 r_y 、 r_z 以及 F_x 、 F_y 和 F_z ,以减轻过拟合的影响。

本文提出的模型基于数据驱动,其相对于通过肌肉外骨骼模型及逆向动力学基于物理模型的估计方法而言,规避了许多错误来源和简化假设。基于物理模型的估计方法存在误差来源,如特定受试者的个体体态参数不准确、惯性传感器方向估计^[28]。在双足支撑相,人体为闭链机构,基于物理模型的估计方法无法单从惯性数据求解关节力矩,需要一定的简化和假设。而基于数据驱动的模型能够避开这些错误来源和简化假设,但需要采集大量数据进行训练。

本文结果表明,KAM 和 KFM 在基准试验的 rRMSE 高于其他步态测试条件下的试验。本文推测,基准试验的持续时间(2 min)相对其他试验(4.5 min)较短,基准试验的训练数据相对其他试验较少,导致模型对基准试验测试条件下的泛化能力相对较差。在所有的步态实验中,KFM 的估计精度 rRMSE 高于 KAM,原因可能是 KFM 的 r_y 幅值比 KAM 的 r_x 大,同等估计误差对 r_y 的影响比 r_x 小,故 KFM 最终估计结果优于 KAM。

本文的局限性如下:① 受试者局限,仅征集男性无肌肉相关疾病的受试者,无法验证模型对膝关节炎患者的预测结果。② 训练集较小(12人),人工神经网络的鲁棒性取决于训练样本代表性,故小样本可能限制了该模型的泛化能力。

4 结论

本文提出了基于 ISN 的穿戴式膝关节力矩估计模型,该模型可作为实验室外膝关节载荷估计的基础,潜在应用领域包括步态训练和膝关节术后康复效果评估。如将该穿戴式估计模型推广,则膝关

节炎患者可以用其估计走路时的膝关节力矩,并指导实际生活中的步态训练以降低膝关节载荷;全膝关节置换术后患者同样可以用其评估患膝和健膝的受力再平衡情况,从而促进患者恢复正常步态。

参考文献:

- [1] WARLOW C, GIJN J, DENNIS M, et al. Stroke: Practical management [M]. 3rd ed. USA: Wiley-Blackwell, 2008.
- [2] 王定,史晓林,李文庆,等. 膝骨性关节炎中医药治疗的研究进展[J]. 中国中医骨伤科杂志, 2008, 16(4): 65-67.
- [3] HURWITZ DE, RYALS AB, CASE JP, et al. The knee adduction moment during gait in subjects with knee osteoarthritis is more closely correlated with static alignment than radiographic disease severity, toe out angle and pain [J]. J Orthop Res, 2002, 20(1): 101-107.
- [4] SHARMA L, HURWITZ DE, THONAR EJM, et al. Knee adduction moment, serum hyaluronan level, and disease severity in medial tibiofemoral osteoarthritis [J]. Arthritis Rheum, 41(7): 1233-1240.
- [5] MIYAZAKI T, WADA M, KAWAHARA H, et al. Dynamic load at baseline can predict radiographic disease progression in medial compartment knee osteoarthritis [J]. Ann Rheum Dis, 2002, 61(7): 617-622.
- [6] CHEHAB EF, FAVRE J, ERHART-HLEDIK JC, et al. Baseline knee adduction and flexion moments during walking are both associated with 5 year cartilage changes in patients with medial knee osteoarthritis [J]. Osteoarthritis Cartil, 2014, 22(11): 1833-1839.
- [7] TENG HL, MACLEOD TD, LINK TM, et al. Higher knee flexion moment during the second half of the stance phase of gait is associated with the progression of osteoarthritis of the patellofemoral joint on magnetic resonance imaging [J]. J Orthop Sport Phys Ther, 2015, 45(9): 656-664.
- [8] TENG HL, CALIXTO NE, MACLEOD TD, et al. Associations between patellofemoral joint cartilage T1 and T2 and knee flexion moment and impulse during gait in individuals with and without patellofemoral joint osteoarthritis [J]. Osteoarthritis Cartil, 2016, 24(9): 1554-1564.
- [9] WALTER JP, D' LIMA DD, COLWELL CW, et al. Decreased knee adduction moment does not guarantee decreased medial contact force during gait [J]. J Orthop Res, 2010, 28(10): 1348-1354.
- [10] MANAL K, GARDINIER E, SNYDER-MACKLER L, et al. An alternate predictor of peak medial compartment loading: The product of the peak knee extensor and abductor moments [C]//Proceedings of American Society of Biomechanics. Omaha: [s.n.], 2013.

- [11] 曹方园, 徐俊凯, 胡海, 等. 跑步时足偏角对胫骨冲击影响的探索性研究[J]. 医用生物力学, 2019, 34(2): 97-102.
CAO FY, XU JK, HU H, *et al.* Exploration study about influence of foot progression angle on tibial shock during running [J]. J Med Biomech, 2019, 34(2): 97-102.
- [12] FAVRE J, ERHART-HLEDIK JC, CHEHAB EF, *et al.* General scheme to reduce the knee adduction moment by modifying a combination of gait variables [J]. J Orthop Res, 2016, 34(9): 1547-1556.
- [13] HUNT MA, SIMIC M, HINMAN RS, *et al.* Feasibility of a gait retraining strategy for reducing knee joint loading: Increased trunk lean guided by real-time biofeedback [J]. J Biomech, 2011, 44(5): 943-947.
- [14] 林玉屏, 程刚, 郭锋, 等. 单侧全膝置换前后女性患者步态特征分析[J]. 医用生物力学, 2020, 35(4): 70-75.
LIN YP, CHENG G, GUO F, *et al.* Gait characteristics of female patients before and after unilateral total knee arthroplasty [J]. J Med Biomech, 2020, 35(4): 70-75.
- [15] SIMIC M, WRIGLEY TV, HINMAN RS, *et al.* Altering foot progression angle in people with medial knee osteoarthritis: The effects of varying toe-in and toe-out angles are mediated by pain and malalignment [J]. Osteoarthr Cartil, 2013, 21(9): 1272-1280.
- [16] FAVRE J, ERHART-HLEDIK JC, CHEHAB EF, *et al.* General scheme to reduce the knee adduction moment by modifying a combination of gait variables [J]. J Orthop Res, 2016, 34(9): 1547-1556.
- [17] VAN DEN NOORT JC, SCHAFFERS I, SNIJDERS J, *et al.* The effectiveness of voluntary modifications of gait pattern to reduce the knee adduction moment [J]. Hum Mov Sci, 2013, 32(3): 412-424.
- [18] KRISTIANSLUND E, KROSSHAUG T, BOGERT AJ. Effect of low pass filtering on joint moments from inverse dynamics: Implications for injury prevention [J]. J Biomech, 2012, 45(4): 666-671.
- [19] FELLIN RE, ROSE WC, ROYER TD, *et al.* Comparison of methods for kinematic identification of footstrike and toe-off during overground and treadmill running [J]. J Sci Med Sport, 2010, 13(6): 646-650.
- [20] RUTHERFORD DJ, BAKER M. Knee moment outcomes using inverse dynamics and the cross product function in moderate knee osteoarthritis gait: A comparison study [J]. J Biomech, 2018, 78: 150-154.
- [21] SINCLAIR J, HOBBS SJ, PROTHEROE L, *et al.* Determination of gait events using an externally mounted shank accelerometer [J]. J Appl Biomech, 2013, 29(1): 118-122.
- [22] LEVA P. Adjustments to Zatsiorsky-Seluyanov's segment inertia parameters [J]. J Biomech, 1996, 29(9): 1223-1230.
- [23] STETTER BJ, KRAFFT FC, RINGHOF S, *et al.* A machine learning and wearable sensor based approach to estimate external knee flexion and adduction moments during various locomotion tasks [J]. Front Bioeng Biotechnol, 2020, 8(1): 9.
- [24] BRABANDERE A, EMMERZAAL J, TIMMERMANS A, *et al.* A machine learning approach to estimate hip and knee joint loading using a mobile phone-embedded IMU [J]. Front Bioeng Biotechnol, 2020, doi: 0.3389/fbioe.2020.00320.
- [25] WANG C, CHAN PPK, LAM BMF, *et al.* Real-time estimation of knee adduction moment for gait retraining in patients with knee osteoarthritis [J]. IEEE Trans Neural Syst Rehabil Eng, 2020, 28(4): 888-894.
- [26] HALILAJ E, RAJAGOPAL A, FITERAU M, *et al.* Machine learning in human movement biomechanics: Best practices, common pitfalls, and new opportunities [J]. J Biomech, 2018, 81: 1-11.
- [27] KARATSIDIS A, JUNG M, SCHEPERS HM, *et al.* Musculoskeletal model-based inverse dynamic analysis under ambulatory conditions using inertial motion capture [J]. Med Eng Phys, 2019, 65: 68-77.
- [28] SHAHABPOOR E, PAVIC A. Measurement of walking ground reactions in real-life environments: A systematic review of techniques and technologies [J]. Sensors, 2017, 17(9): 2085.