

基于传感器的智能膝关节矫形器力矩预测方法及系统

皇艳波¹, 徐彼得², 吴 昊³, 马寻君⁴, 吴云成¹

¹上海理工大学健康科学与工程学院, 上海

²上海交通大学转化医学研究院, 上海

³上海大学医学院, 上海

⁴徐州医科大学医学信息与工程学院医学信息学系, 江苏 徐州

收稿日期: 2025年3月16日; 录用日期: 2025年4月9日; 发布日期: 2025年4月18日

摘 要

膝骨性关节炎作为高致残性疾病, 传统治疗手段受限于实验室评估的实时性与便捷性。本研究提出一种基于多源传感器的智能膝关节矫形器力矩预测系统, 通过融合3D打印矫形器、惯性测量单元(IMU)及表面肌电传感器, 实时监测膝关节内收力矩(KAM)与屈曲力矩(KFM)。通过构建融合一维卷积神经网络、双向长短期记忆网络及注意力机制(CNN-BiLSTM-Attention)的深度学习模型, 以动态预测关节力矩。实验招募10名健康受试者, 采集步行、跑步、上下楼梯及转向等六类日常活动的运动数据, 利用逆动力学计算力矩作为基准。结果显示, KAM预测性能优于KFM: KAM平均相关系数为 0.739 ± 0.094 , 均方根误差(RMSE)为 0.172 ± 0.033 Nm/kg; KFM平均相关系数为 0.720 ± 0.107 , RMSE为 0.215 ± 0.048 Nm/kg。研究进一步验证了传感器数据与云平台结合的长期康复管理可行性。该系统突破了传统实验室评估的局限, 为个性化矫形器干预和智能康复设备的发展提供了创新解决方案。

关键词

膝骨关节炎, 膝关节矫形器, 力矩预测, 传感器, 深度学习

Sensor-Based Intelligent Knee Orthosis Moment Prediction Method and System

Yanbo Huang¹, Bide Xu², Hao Wu³, Xunjun Ma⁴, Yuncheng Wu¹

¹School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai

²Institute of Translational Medicine, Shanghai Jiao Tong University, Shanghai

³School of Medicine, Shanghai University, Shanghai

⁴Department of Medical Informatics, School of Medical Information and Engineering, Xuzhou Medical University, Xuzhou Jiangsu

文章引用: 皇艳波, 徐彼得, 吴昊, 马寻君, 吴云成. 基于传感器的智能膝关节矫形器力矩预测方法及系统[J]. 建模与仿真, 2025, 14(4): 514-524. DOI: 10.12677/mos.2025.144305

Abstract

Knee osteoarthritis, as a highly disabling disease, has traditional treatment methods limited by the real-time and convenience of laboratory assessments. This study proposes an intelligent knee orthosis torque prediction system based on multi-source sensors, which integrates 3D-printed orthoses, inertial measurement units (IMUs), and surface electromyography sensors to monitor knee adduction moment (KAM) and knee flexion moment (KFM) in real time. By constructing a deep learning model that combines one-dimensional convolutional neural networks, bidirectional long short-term memory networks, and attention mechanisms (CNN-BiLSTM-Attention), the system dynamically predicts joint torque. The experiment recruited 10 healthy subjects, collecting motion data from six types of daily activities including walking, running, ascending and descending stairs, and turning. Inverse dynamics were used to calculate the torque as a benchmark. The results show that the prediction performance for KAM is superior to that for KFM: the average correlation coefficient for KAM is 0.739 ± 0.094 , with a root mean square error (RMSE) of 0.172 ± 0.033 Nm/kg; the average correlation coefficient for KFM is 0.720 ± 0.107 , with an RMSE of 0.215 ± 0.048 Nm/kg. The study further validates the feasibility of long-term rehabilitation management by combining sensor data with a cloud platform. This system breaks through the limitations of traditional laboratory assessments and provides an innovative solution for personalized orthotic intervention and the development of intelligent rehabilitation equipment.

Keywords

Knee Osteoarthritis, Knee Orthosis, Moment Prediction, Sensors, Deep Learning

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

膝关节骨性关节炎(KOA)是以关节软骨退变为特征的致残性疾病,我国 50 岁以上人群患病率高达 50%,70 岁以上达 80% [1] [2],其引发的社会医疗负担已占西方国家 GDP 的 1%~2.5%且持续攀升[3]。该病严重影响患者日常生活,现有治疗中运动训练改善功能有限,药物治疗存在副作用,全膝关节置换术虽有效但术后满意度仅 81%~89% [4]-[7]。膝关节矫形器作为无创保守疗法,通过调整髌间隙降低关节负荷,兼具纠正力线和促进软骨修复的优势[8],临床应用日益广泛。

生物力学研究表明,膝关节内翻力矩(KAM)和屈曲力矩(KFM)是评估关节负荷的核心指标,分别与软骨退变和胫骨髌骨损伤密切相关[9]-[13]。传统三维运动捕捉系统虽能精确测量步态力学参数,但存在设备昂贵、场地受限及反复检测耗时等问题[14]。可穿戴传感器技术为解决这一瓶颈提供了新路径:由加速度计、陀螺仪和磁力计构成的惯性测量单元(IMU)可实时采集关节运动学参数,结合机器学习算法可预测动力学指标[15]-[17]。这类系统具有便携、低成本和连续监测优势,特别适用于矫形器疗效的动态评估。

本研究旨在开发基于传感器的智能膝关节矫形器力矩预测系统。通过将 IMU 和肌电集成于 3D 打印减荷式矫形器,实时获取不同运动模式下的运动学数据,建立基于 CNN-BiLSTM-Attention 的膝关节力矩预测模型。该技术突破传统实验室检测局限,为个性化调整矫形器力学干预方案提供实时生物力学反馈,

有望提升 KOA 康复治疗精准度[18]。研究成果将推动可穿戴医疗设备在骨关节疾病管理中的转化应用，助力实现动态化、智能化的康复治疗新模式。

2. 模型构建

2.1. 基于 CNN-BiLSTM-Attention 的膝关节力矩预测模型

本文使用的 CNN-BiLSTM-Attention 膝关节力矩预测模型由五个主要模块构成，先前的研究可见文献[19]，包括输入模块、特征提取模块、序列学习模块、注意力模块和预测模块。输入模块负责接收原始数据，特征提取模块由卷积层和池化层组成，序列学习模块包含 Bi-LSTM 层和 Dropout 层，注意力模块由注意力层构成，而预测模块则由全连接层和输出层组成。CNN-BiLSTM-Attention 预测模型的整体架构如图 1 所示。




Figure 1. CNN-BiLSTM-Attention model architecture diagram
图 1. CNN-BiLSTM-Attention 模型的架构图

2.2. 模型原理及参数设置

本文提出的关节力矩预测模型采用图 1 所示的 CNN-BiLSTM-Attention 混合架构，主要包含以下层次结构：

- 1) 输入层：将多通道 IMU 信号与表面肌电信号经预处理后构建为时间切片数据，输入维度为 $N \times T$ (N 为传感器通道数， T 为时间步长)。
- 2) 特征提取模块：采用单层 Conv1D 进行空间特征提取，配置 128 个卷积核(核尺寸 = 1，激活函数 ReLU)，后接 Dropout 层(失活率 0.5)以防止过拟合。
- 3) 时序建模模块：通过双向 LSTM 层捕获信号的前后向时序依赖，设置 64 个隐藏单元，输出序列经相同参数的 Dropout 层处理。
- 4) 注意力加权层：采用全连接网络计算各时间步特征的重要性权重(5 个隐单元，Softmax 激活)，实现关键特征的自适应增强。
- 5) 回归输出层：将加权特征经 Flatten 操作后输入全连接网络(1 个神经元，ReLU 激活)，最终输出关节力矩预测值。

本文使用网络模型基于在 MATLAB R2024a 平台搭建，模型训练采用 Adam 优化器，以均方根误差 (RMSE) 作为损失函数。设置批量大小为 100 [20]，初始学习率 0.001，并采用指数衰减策略(衰减因子 0.1，每 700 次迭代衰减一次)。整个训练过程进行 500 个 epoch 以确保收敛。

3. 材料与方法

3.1. 实验设备

本研究构建的人体下肢运动学信息采集系统由主控、传感器及电源三大模块组成。主控模块采用 ATmega328 微控制器, 通过其内置 12 位 ADC 实现肌电信号采集, 采样频率设置为 1000 Hz。传感器模块整合了表面肌电传感器和 MPU6050 六轴惯性测量单元(IMU), 后者通过 I²C 协议以 100 Hz 采样频率获取下肢三轴加速度与角速度数据。系统采用双 9V 可充电锂电池供电, 确保移动测量的稳定性。

实验采用 3D 打印膝关节矫形器制作过程可参考文献[21], 通过调整其结构实现膝关节内收力矩的调控。基于生物力学预实验与穿戴稳定性分析, 将 IMU 固定于大腿和小腿外侧, 同时选取股直肌与胫骨前肌作为肌电信号采集位点。主控模块通过蓝牙传输至上位机进行存储并带有时间戳。该采集系统如图 2 所示。




Figure 2. Human lower limb kinematics data acquisition system

图 2. 人体下肢运动学信息采集系统

本实验在上海养志康复医院生物力学步态实验室里进行, 使用具 6 个高速摄像头的运动捕捉系统 (Vicon Motion System Ltd. Oxford, UK) 以 100 HZ 采集受试者身上的 24 个反光标记, 分别为骨盆, 左、右股骨, 左、右胫骨, 左、右足。以其配套的测力跑台以 1 kHz 的频率同步采集受试者的地面反作用力 (Ground Reaction Force, GRF)。

3.2. 实验对象

本研究共招募了 10 名男性健康受试者参与下肢运动信息采集实验, 无下肢运动功能障碍或其他影响运动练习的疾病。志愿者信息如表 1 所示。

本研究已获得上海交通大学医学院附属第九人民医院生命伦理委员会批准。所有受试者 (志愿者和患者) 均自愿参加本实验并了解实验内容, 并全部签署知情同意书。

Table 1. Subject Information

表 1. 受试者信息

性别	年龄	身高(cm)	体重(Kg)	总人数
男	24.57 ± 1.92	175.57 ± 4.44	72.71 ± 8.05	10

3.3. 实验过程

本研究针对步行、跑步、上/下楼梯及左/右转弯六类日常活动，建立标准化运动信息采集流程如图 3 所示。实验前执行以下预处理：1) 对受试者下肢肌电电极区域进行备皮处理以降低皮肤阻抗；2) 通过动作演示与预训练规范运动姿态；3) 要求受试者执行动作时保持左足单侧落于测力台区域。每组运动模式连续采集 5 次，单次持续 2 min，组间设置 5 min 间歇期以消除肌肉疲劳。同步采用时间戳标记相机全程记录运动过程，以便后续进行数据对齐操作。



Figure 3. Daily Human Activities: (A) Walking; (B) Running; (C) Ascending Stairs; (D) Descending Stairs; (E) Turning Left; (F) Turning Right

图 3. 人体日常活动：(A) 走；(B) 跑；(C) 上楼梯；(D) 下楼梯；(E) 左转弯；(F) 右转弯

3.4. 数据预处理

三维光标数据与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，截止频率设置为 15 Hz。在三维步态分析软件 Visual 3D 中采用逆动力学的方法计算每种运动步态周期内的膝关节力矩并沿时间轴标准化为 100 个标准化点。使用巴特沃斯低通滤波器以 15 Hz 的截止频率对 IMU 数据进行滤波。表面肌电信号使用 20~150 Hz 带通滤波器和 50 Hz 陷波滤波器去除高频噪声和工频干扰，随后将肌电信号下采样到 100 HZ。通过运动相机确定每种运动步态周期时间节点，将 IMU、肌电信号及标准化的膝关节力矩数据按完整步态周期进行时空对齐。最终构建多维数据集包含 10 名受试者 × 5 组运动试验 × 100 时间点，单个步态周期特征维度为 14 通道 × 100 时间点。

3.5. 评价方法

该系统通过留一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模型泛化能力,剩余受试者作为训练集训练模型。以均方根误差(Root Mean Square Error, RMSE)、相对均方根误差(Relative Root Mean Square Error, RRMSE)、互相关系数(r)和平均绝对误差(Mean Absolute Error, MAE)作为网络估计精度的评价指标。公式如 1~2 所示。


$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (1)$$

$$\text{rRMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} / \bar{y}_i \quad (2)$$

其中式中: n 为采样点数量, i 为采样点序号; $\hat{y}$ 膝关节力矩的预测值; y_i 膝关节力矩的实际值;

4. 实验结果

本文选用 10 位受试者的前 9 位实验数据作为训练集,第 10 位受试者实验数据作为测试集,采用 CNN-BiLSTM-Attention 模型估计人体进行六种日常行为活动时的 KAM 和 KFM 的平均值(和标准误差)与其各自的逆动力学计算的 actual 值(红色)的比较如图 4 和图 5 示,估计结果的准确度如表 2 和表 3 所示。







Figure 4. Comparison between predicted (black, mean $\pm$ SE) and calculated (red) knee adduction moments (KAM) across tasks ((A) Walk; (B) Run; (C) Turn left; (D) Turn right; (E) Go upstairs)

图 4. KAM 在不同任务膝关节力矩预测值(黑色)的平均值(和标准误差)与计算值(红色)的比较((A) 走; (B) 跑; (C) 向左转弯; (D) 向右转弯; (E) 上楼梯; (F) 下楼梯)

对于图 4, 在六种不同的人体日常活动中, CNN-BiLSTM-Attention 模型估计的膝关节 KAM 曲线与逆动力学计算的 actual 值曲线走势基本一致。在进行跑如图 4(B)时, 支撑相后期预测曲线与实际曲线出现分离。在进行走、向左转弯、向右转弯、上楼梯和下楼梯时如图 4(A)、图 4(C)、图 4(D)~(F)预测曲线显示在峰值处逆动力学计算的 actual 值有较大差异。

对于图 5, 在六种不同的人体日常活动中, CNN-BiLSTM-Attention 模型估计的六种运动的 KFM 曲线与逆动力学计算的 actual 值曲线走势基本一致, 在进行下楼梯如图 5(F)时, 在支撑相后期, 预测曲线与实际曲线出现分离。在进行跑、向左转弯和上楼梯时如图 5(B)、图 5(C)、图 5(E), 预测曲线在支撑相的前期和后期出现较大分离, 在进行跑、向左转弯时如图 5(B)、图 5(C)预测曲线显示在峰值处与逆动力学计算的 actual 值有较大差异。

如表 2 所示, KAM 在六种日常活动中呈现中度至强相关性($r = 0.506 \pm 0.129$ 至 0.871 ± 0.026)。右转活动相关性最强($r = 0.871 \pm 0.026$), 显著高于下楼梯时的中度相关性($r = 0.506 \pm 0.129$)。所有任务预测误差范围为 0.097 ± 0.022 至 0.398 ± 0.059 , 而 RRMSE 显示活动间显著差异: 步行时最低(20.445 ± 6.158), 上楼梯时达峰值(43.663 ± 7.894)。






Figure 5. Comparison between predicted (black, mean $\pm$ SE) and calculated (red) knee flexion moments (KFM) across tasks ((A) Walk; (B) Run; (C) Turn left; (D) Turn right; (E) Go upstairs)

图 5. KFM 在不同任务膝关节力矩预测值(黑色)的平均值(和标准误差)与计算值(红色)的比较((A) 走; (B) 跑; (C) 向左转弯; (D) 向右转弯; (E) 上楼梯; (F) 下楼梯)

Table 2. KAM estimation accuracy

表 2. KAM 估计结果的准确度

运动任务	KAM		
	r	RMSE (Nm/kg)	
步行	0.850 $\pm$ 0.026	0.105 $\pm$ 0.007	20.445 $\pm$ 6.158
跑	0.817 $\pm$ 0.040	0.398 $\pm$ 0.059	26.676 $\pm$ 6.565
上楼梯	0.733 $\pm$ 0.108	0.147 $\pm$ 0.051	43.663 $\pm$ 7.894
下楼梯	0.506 $\pm$ 0.129	0.184 $\pm$ 0.050	33.926 $\pm$ 13.080
向左转弯	0.739 $\pm$ 0.055	0.101 $\pm$ 0.009	26.581 $\pm$ 6.598
向右转弯	0.871 $\pm$ 0.026	0.097 $\pm$ 0.022	36.774 $\pm$ 3.279
均值	0.739 $\pm$ 0.094	0.172 $\pm$ 0.033	31.344 $\pm$ 7.262
			20.445 $\pm$ 6.158

Table 3. KFM estimation accuracy
表 3. KFM 力矩估计结果的准确度

运动任务	KFM		
	r	RMSE (Nm/kg)	RRMSE (%)
步行	0.811 ± 0.075	0.131 ± 0.042	10.757 ± 3.940
跑	0.748 ± 0.141	0.307 ± 0.065	33.315 ± 11.990
上楼梯	0.569 ± 0.180	0.213 ± 0.010	21.382 ± 2.167
下楼梯	0.820 ± 0.074	0.223 ± 0.067	20.473 ± 8.363
向左转弯	0.683 ± 0.106	0.226 ± 0.061	30.027 ± 8.375
向右转弯	0.692 ± 0.066	0.188 ± 0.041	42.118 ± 11.387
均值	0.720 ± 0.107	0.215 ± 0.048	26.345 ± 7.704

如表 3 所示，KFM 在六种日常活动中呈现中度至强相关性($r = 0.569 \pm 0.180$ 至 0.820 ± 0.074)。其中下楼梯活动表现出最强相关性($r = 0.820 \pm 0.074$)，显著高于上楼梯的中度相关性($r = 0.569 \pm 0.180$)。各任务预测误差维持在 0.131 ± 0.042 至 0.307 ± 0.065 范围，而 RRMSE 存在显著活动差异：步行时最低(10.757 ± 3.940)，右转时达到峰值(42.118 ± 11.387)。

5. 讨论

本研究通过集成惯性测量单元(IMU)与表面肌电传感器的 3D 打印减荷式膝关节矫形器系统，成功构建了基于 CNN-BiLSTM-Attention 神经网络的关节力矩预测模型。相较于传统实验室依赖光学运动捕捉与测力平台的逆动力学分析方法，该可穿戴系统实现了六种日常活动中膝关节生物力学负荷的实时监测。实验发现该系统在中等强度直线运动(如走和跑)中具有较好的 KAM 预测性能($r = 0.850 \pm 0.026$, 0.817 ± 0.040)，这一发现使临床医生能够根据实时反馈调整矫形器的力学干预方案成为可能。整体来看该系统对 KAM 的估计性能较高(r 均值 = 0.739 ± 0.094 , RMSE 均值 = 0.172 ± 0.033)，相比之下，KFM 的估计精度相对较低(r 均值 = 0.720 ± 0.107 , RMSE 均值 = 0.215 ± 0.048)，且表现出更大的个体间差异(标准差 > 0.1)。

值得注意的是，系统在直线行走任务中，KAM 估计达到最优性能($r = 0.850 \pm 0.026$)，而下楼梯任务中相关性显著降低至 0.506 ± 0.129 ，表现出较大的性能差异，说明运动强度与方向变化对估计精度具有显著影响。相类似地是，KFM 在下楼梯时获得最高相关性($r = 0.820$)，但在上楼梯任务中表现最差($r = 0.569$)。进一步分析发现，运动模式的可重复性与估计精度存在潜在关联。对于具有较高运动变异性的任务(如方向转换和速度变化)，模型性能下降可能源于动作执行过程中生物力学特征的不可控波动。这一现象与 Fluit 等人[22]通过三维运动分析系统获得的动力学参数估计结果具有一致性，提示复杂运动模式下关节力矩估计存在普遍性挑战。另一方面，在做复杂的运动时，膝关节矫形器可能存在较大的晃动，这会导致采集到的信号产生较大的干扰，进而影响结果。

本研究也存在受试者样本量有限、运动模式覆盖不足以及并未用 KOA 患者数据验证的局限性，未来通过扩大训练数据集覆盖更多步态模式，并优化 IMU 与肌电传感器的空间配置方案，有望进一步提升复杂运动场景下的估计精度。

基金项目

上海市科学技术委员会“科技创新行动计划”国内科技合作领域项目(项目编号：22015820100)。国家自然科学基金重大研究计划 92048205。

参考文献

- [1] 任硕. 膝关节关节炎治疗方案的优化选择[D]: [硕士学位论文]. 济南: 山东中医药大学, 2010.
- [2] 孙小琴, 徐兰凤. 近 10 年骨性膝关节炎的治疗方法综述[J]. 针灸临床杂志, 2009, 25(2): 46-48+59.
- [3] O'Neill, T.W., McCabe, P.S. and McBeth, J. (2018) Update on the Epidemiology, Risk Factors and Disease Outcomes of Osteoarthritis. *Best Practice & Research Clinical Rheumatology*, **32**, 312-326. <https://doi.org/10.1016/j.berh.2018.10.007>
- [4] Bjordal, J.M., Ljunggren, A.E., Klovning, A. and Slørdal, L. (2004) Non-Steroidal Anti-Inflammatory Drugs, Including Cyclo-Oxygenase-2 Inhibitors, in Osteoarthritic Knee Pain: Meta-Analysis of Randomised Placebo Controlled Trials. *BMJ*, **329**, Article No. 1317. <https://doi.org/10.1136/bmj.38273.626655.63>
- [5] Zhang, W., Nuki, G., Moskowitz, R.W., Abramson, S., Altman, R.D., Arden, N.K., *et al.* (2010) OARSI Recommendations for the Management of Hip and Knee Osteoarthritis. *Osteoarthritis and Cartilage*, **18**, 476-499. <https://doi.org/10.1016/j.joca.2010.01.013>
- [6] Fawaz, W.S. and Masri, B.A. (2020) Allowed Activities after Primary Total Knee Arthroplasty and Total Hip Arthroplasty. *Orthopedic Clinics of North America*, **51**, 441-452.
- [7] 程兴旺, 张峡. 膝关节外翻全膝关节置换术的进展[J]. 中国矫形外科杂志, 2020, 28(6): 527-531.
- [8] Rodriguez-Merchan, E.C. and De La Corte-Rodriguez, H. (2018) The Role of Orthoses in Knee Osteoarthritis. *Hospital Practice*, **47**, 1-5. <https://doi.org/10.1080/21548331.2018.1527168>
- [9] Hurwitz, D.E., Ryals, A.B., Case, J.P., Block, J.A. and Andriacchi, T.P. (2002) 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. *Journal of Orthopaedic Research*, **20**, 101-107. [https://doi.org/10.1016/s0736-0266\(01\)00081-x](https://doi.org/10.1016/s0736-0266(01)00081-x)
- [10] Miyazaki, T., Wada, M., Kawahara, H., Sato, M., Baba, H. and Shimada, S. (2002) Dynamic Load at Baseline Can Predict Radiographic Disease Progression in Medial Compartment Knee Osteoarthritis. *Annals of the Rheumatic Diseases*, **61**, 617-622. <https://doi.org/10.1136/ard.61.7.617>
- [11] Chehab, E.F., Favre, J., Erhart-Hledik, J.C. and Andriacchi, T.P. (2014) Baseline Knee Adduction and Flexion Moments during Walking Are both Associated with 5 Year Cartilage Changes in Patients with Medial Knee Osteoarthritis. *Osteoarthritis and Cartilage*, **22**, 1833-1839. <https://doi.org/10.1016/j.joca.2014.08.009>
- [12] Teng, H., Calixto, N.E., MacLeod, T.D., Nardo, L., Link, T.M., Majumdar, S., *et al.* (2016) Associations between Patellofemoral Joint Cartilage T1ρ and T2 and Knee Flexion Moment and Impulse during Gait in Individuals with and without Patellofemoral Joint Osteoarthritis. *Osteoarthritis and Cartilage*, **24**, 1554-1564. <https://doi.org/10.1016/j.joca.2016.04.006>
- [13] Walter, J.P., D'Lima, D.D., Colwell, C.W. and Fregly, B.J. (2009) Decreased Knee Adduction Moment Does Not Guarantee Decreased Medial Contact Force during Gait. *Journal of Orthopaedic Research*, **28**, 1348-1354. <https://doi.org/10.1115/sbc2009-206706>
- [14] Chiang, C., Chen, K., Liu, K., Hsu, S. and Chan, C. (2017) Data Collection and Analysis Using Wearable Sensors for Monitoring Knee Range of Motion after Total Knee Arthroplasty. *Sensors*, **17**, Article No. 418. <https://doi.org/10.3390/s17020418>
- [15] Wang, Z., Li, J., Wang, J., Zhao, H., Qiu, S., Yang, N., *et al.* (2018) Inertial Sensor-Based Analysis of Equestrian Sports between Beginner and Professional Riders under Different Horse Gaits. *IEEE Transactions on Instrumentation and Measurement*, **67**, 2692-2704. <https://doi.org/10.1109/tim.2018.2826198>
- [16] Cutti, A.G., Ferrari, A., Garofalo, P., Raggi, M., Cappello, A. and Ferrari, A. (2009) "Outwalk": A Protocol for Clinical Gait Analysis Based on Inertial and Magnetic Sensors. *Medical & Biological Engineering & Computing*, **48**, 17-25. <https://doi.org/10.1007/s11517-009-0545-x>
- [17] Siu, H.C., Sloboda, J., McKindles, R.J. and Stirling, L.A. (2021) A Neural Network Estimation of Ankle Torques from Electromyography and Accelerometry. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, **29**, 1624-1633. <https://doi.org/10.1109/tnsre.2021.3104761>
- [18] Gueugnon, M., Fournel, I., Soilly, A.-L., Diaz, A., Baulot, E., Bussière, C., *et al.* (2021) Effectiveness, Safety, and Cost-Utility of a Knee Brace in Medial Knee Osteoarthritis: The ERGONOMIE Randomized Controlled Trial. *Osteoarthritis and Cartilage*, **29**, 491-501. <https://doi.org/10.1016/j.joca.2020.11.009>
- [19] Liang, W., Wang, F., Fan, A., Zhao, W., Yao, W. and Yang, P. (2023) Deep-Learning Model for the Prediction of Lower-Limb Joint Moments Using Single Inertial Measurement Unit during Different Locomotive Activities. *Biomedical Signal Processing and Control*, **86**, Article ID: 105372. <https://doi.org/10.1016/j.bspc.2023.105372>
- [20] Kingma, D.P. and Ba, J. (2015) Adam: A Method for Stochastic Optimization. *International Conference on Learning*

Representations (ICLR), San Diego, 7-9 May 2015.

- [21] 李宁. 3D 打印个性化单侧减荷式膝关节矫形支具的研制[D]: [硕士学位论文]. 上海: 上海交通大学, 2018.
- [22] Fluit, R., Andersen, M.S., Kolk, S., Verdonchot, N. and Koopman, H.F.J.M. (2014) Prediction of Ground Reaction Forces and Moments during Various Activities of Daily Living. *Journal of Biomechanics*, **47**, 2321-2329.
<https://doi.org/10.1016/j.jbiomech.2014.04.030>