

DOI:10.11784/tdxbz202503011

一种用于部分负重行走期间实时监测胫骨力的 可穿戴监测系统

孙 涛¹, 徐 讯¹, 范天洋¹, 王 腾², 沈先涛², 马 涛¹

(1. 天津大学机构理论与装备设计教育部重点实验室, 天津 300350;

2. 华中科技大学同济医学院武汉儿童医院骨科, 武汉 430015)

摘 要: 胫骨骨折患者通常采用部分负重(PWB)的方式进行康复治疗. PWB 的关键是控制负荷, 负重不足会导致愈合延迟, 过度负重会导致二次骨折. 因此, 康复行走期间对胫骨受力的实时监测和负重范围的精准控制至关重要. 现有受力监测设备存在无法实时监测或监测不准确的问题, 为此, 通过惯性测量单元(IMU)和柔性足底压力鞋垫搭建可穿戴监测系统, 能够实时采集下肢运动学与动力学数据, 并通过振动/语音反馈提供实时负荷预警; 在此基础上, 基于可穿戴监测系统分别提出了逆动力学模型(物理驱动)、多层感知机预测模型(静态映射)及双层长短期记忆(LSTM)预测模型(时序建模), 实现对胫骨轴向力的动态预测. 为验证系统预测性能, 招募 6 名受试者模拟 4 种 PWB 行走实验, 并对比逆动力学模型、多层感知机模型及双层 LSTM 模型的预测结果. 结果表明: 双层 LSTM 模型在不同负重任务下的预测表现优异, 平均绝对误差在 $(0.04 \pm 0.02) \sim (0.08 \pm 0.05)$ BW 之间, 均方根误差在 $(0.04 \pm 0.03) \sim (0.11 \pm 0.04)$ BW 之间, 预测结果与参考值拟合程度最高. 可穿戴监测系统的多模态传感器方案与 LSTM 时序建模的协同作用, 能够有效捕捉步态周期内的时序动态特征, 提高预测的准确性. 这套便携式可穿戴监测系统能够为下肢胫骨骨折患者提供有效的康复指导, 具有重要临床意义.

关键词: 胫骨力; 可穿戴监测系统; 部分负重; 双层长短期记忆神经网络

中图分类号: R318

文献标志码: A

文章编号: 0493-2137(2026)07-0711-12

Wearable Monitoring System for Real-Time Tibial Force Monitoring During Partial Weight-Bearing Walking

Sun Tao¹, Xu Xun¹, Fan Tianyang¹, Wang Teng², Shen Xiantao², Ma Tao¹

(1. Key Laboratory of Mechanism Theory and Equipment Design of Ministry of Education, Tianjin University, Tianjin 300350, China; 2. Department of Orthopaedics, Wuhan Children's Hospital, Tongji Medical College,

Huazhong University of Science and Technology, Wuhan 430015, China)

Abstract: Patients with tibial fractures typically undergo partial weight-bearing (PWB) rehabilitation. The key of PWB lies in precise load control, as insufficient loading may delay healing, while excessive loading risks secondary fractures. Therefore, real-time monitoring of tibial forces and accurate regulation of weight-bearing ranges are critical during rehabilitation. The existing monitoring devices suffer from challenges in achieving real-time measurement and accuracy. To address this issue, a wearable monitoring system that integrates inertial measurement units and customized plantar pressure insoles had been developed to collect lower-limb kinematic and kinetic data in real time, with vibration/audio feedback providing instant load warnings. Building upon this system, three "tibial axial force" prediction models were proposed: an inverse dynamics model (physics-driven), a multilayer perceptron model (static mapping), and a two-layer long short-term memory (LSTM) model (temporal modeling). Six subjects were recruited to simulate four PWB walking conditions, validating the predictive performance of these models. Results

收稿日期: 2025-03-06; 修回日期: 2025-06-25.

作者简介: 孙 涛 (1983—), 男, 博士, 教授, stao@tju.edu.cn.

通信作者: 马 涛, 2097808@163.com.

基金项目: 国家自然科学基金资助项目 (62027812).

Supported by the National Natural Science Foundation of China (No. 62027812).

demonstrate the superior performance of the two-layer LSTM model across tasks, achieving a mean absolute error ranging from (0.04 ± 0.02) to (0.08 ± 0.05) body weight (BW) and a root mean square error ranging from (0.04 ± 0.03) to (0.11 ± 0.04) BW, with the highest correlation to reference values. The synergistic integration of the multi-modal sensor configuration and LSTM-based temporal modeling results in the effective capturing of temporal dynamic characteristics within gait cycles, significantly increasing the prediction accuracy. This portable, wearable monitoring system offers a reliable solution for guiding tibial fracture rehabilitation, showing a substantial clinical value.

Keywords: tibial force; wearable monitoring system; partial weight-bearing; two-layer long short-term memory (LSTM) neural network

下肢骨折约占所有骨折的 1/3, 其中胫骨骨折是常见的下肢骨折类型^[1]. 胫骨骨折手术后, 患者通常采用部分负重 (partial weight-bearing, PWB) 的方式进行康复治疗^[2]. PWB 是指患者在康复过程中借助辅助设备支撑, 使患肢承受特定重量, 以进行站立或行走的康复训练. 医生或康复专家通常会制定患肢的具体负重比例^[3], 以确保骨折部位负重在安全范围内, 并提供适度的机械刺激促进骨骼愈合. 其原理是合理的重复负荷可以促进成骨细胞生长和固定承重肢体结构, 从而加快康复过程并减少术后并发症发生^[4].

PWB 行走的关键是控制负荷. 负重不足会导致骨折愈合延迟^[5], 过度负重会导致二次骨折, 因此控制负荷在合理的范围内至关重要. 现有的控制负荷方法主要通过助行器分担重量, 使用下肢受力监测设备进行患肢负荷监测. 其中, 下肢受力监测设备分为侵入式和非侵入式两种. 侵入式设备包括测量植入骨折患者体内的固定装置上的应力或应变^[6]. 然而, 当下肢受到外部载荷时, 骨折部位会承受一定应力, 进而导致固定装置发生变形, 使得测量的胫骨力不准确. 对于非侵入式设备, 传统方法使用体重秤等进行监测, 但该方法已被证明在指导 PWB 行走方面效果不佳^[7]. 其原因是体重秤只能提供静态的负重测量, 无法反映动态的行走负荷. 随着传感技术的发展, 生物反馈装置被应用于 PWB 训练方面, 可用来实时监测下肢创伤患者在训练过程中的地面反作用力 (ground reaction force, GRF)^[8]. 这些设备以足底压力为指标, 默认足底压力等于胫骨轴向力. 然而, GRF 通常不能直接反映肌肉骨骼结构所承受的实际负荷. 最新研究表明, 在同一步态周期内, GRF 的峰值与胫骨力的峰值出现时间通常不一致^[9], 且胫骨力的增加可以在 GRF 未增加的情况下发生. 这是因为绝大多数胫骨负荷是源于运动时的肌肉收缩, GRF 对胫骨力的贡献相对较小. 因此, 仅依靠 GRF 作为衡量标准不足以全面评估胫骨力, 现有生物反馈装置也难以准确反映胫骨内部所承受的实际受力.

为了更精确测量胫骨轴向力, 通过整合光学运动

捕捉系统与测力台采集的患者运动数据, 并基于生物力学软件 (例如 OpenSim、Anybody) 的肌肉骨骼模型进行仿真分析, 可实现组织负荷的间接估计. 这种方法提供更详细和准确的内部负荷数据, 克服了仅依靠足底压力测量获取胫骨力的局限性. 然而, 该装置成本非常高昂, 且只能在特定的实验室场地使用, 限制其在日常临床实践中的应用. 为了能在不需要实验室的环境下对人体运动进行受力监测, 小型便携式的可穿戴传感器以及配套的软件算法被许多研究者使用^[10]. 可穿戴监测系统通常由惯性测量单元和压力传感器组成, 可以采集到人体下肢运动角度与足底压力数据. 然而, 可穿戴系统受到传感器设备数据质量低、数据维度有限等限制, 在监测胫骨负荷时难以达到预期^[11]. 现有文献从设备改进和算法优化两方面解决上述问题. 对于设备改进, 一些研究人员使用由 2 个三轴力传感器组成的定制鞋垫测量足底压力数据^[12]. 但该鞋垫只能采集足底两块特定区域的压力, 导致计算的足底压力相关特征存在一定缺陷. 对于算法优化, 近年来机器学习方法被应用于使用可穿戴设备进行监测的过程. Matijevich 等^[13]将可穿戴传感器信号中提取的离散特征作为输入, 使用机器学习算法输出估计的胫骨力的峰值. Elstube 等^[10]将惯性测量单元、足底压力鞋垫与 Lasso 算法相结合, 预测跑步期间的胫骨峰值力. 但这些方法使用离散信号数据, 只能求解出最大胫骨力, 无法进行全程实时反馈, 限制了其在需要连续监测场景中的应用.

本文针对现有受力监测设备存在的无法实时监测或监测不准确的问题, 开发了一款新型便携式可穿戴监测系统. 系统由 2 个惯性测量单元 (inertial measurement unit, IMU) 和柔性足底压力鞋垫组成, 可实时采集下肢运动学与动力学数据. 在此基础上, 分别构建了逆动力学模型、多层感知机 (multi-layer perceptron, MLP) 模型, 以及双层长短期记忆 (long short-term memory, LSTM) 神经网络模型 3 种求解方法, 实现对胫骨力的动态预测. 同时招募 6 名受试者开展 4 种 PWB 行走实验, 以验证模型性能.

1 可穿戴监测系统的搭建

本文设计的可穿戴监测设备由 2 个 IMU 和柔性足底压力鞋垫组成。IMU 集成高精度的陀螺仪、加速度计和地磁场传感器,采用数字滤波技术和卡尔曼动态滤波算法,能够快速求解实时运动姿态。足底压力鞋垫使用柔性超电容触觉传感器设计,触觉传感器由顶部(行)电极层、底部(列)电极层和离子凝胶涂层微纤维基层构成。顶部和底部交叉组装,将离子纤维基层夹在中间,形成超电容传感单元,具有灵敏度高、线性度强和抗干扰性好的特点^[14]。鞋垫内置 STM32H743 微控制器与多路复用器,构建信号测量电路输出 9×24 的电容矩阵。通过材料试验机标定传感单元,建立电容-压力线性映射关系,根据对应关系将电容矩阵转换为压力分布矩阵。对矩阵内所有元素的压力值求和,计算得到垂直地面反力。如图 1 所示,IMU 分别布置在受试者小腿外侧中部与足背中部,以有效提高姿态解算精度。其通过蓝牙将三轴加速度、三轴角速度和四元数信息实时传输至移动端,姿态测量精度为 0.2° ,采集频率为 10 ms。足底压力鞋垫通过黑色绑带固定于足底,用于采集足底压力信息。其通过 WiFi 模块将足底压力数据传输至移动端,采集频率为 10 ms。

基于 QT 框架开发上位机界面,通过蓝牙(IMU

数据)与 WiFi(足底压力数据)模块同步接收可穿戴监测设备信号。如图 2 所示,平台主界面划分为 4 个区域,实现设备通信管理、多模态数据可视化、数据存储与胫骨力预测的功能。其中,区域 1 为惯性测量单元控制区,负责 IMU 设备连接与运动学数据显示。区域 2 为足底压力监测区,用于鞋垫设备连接与压力分布热力图可视化。区域 3 为数据管理区,实现患者信息录入及数据存储管理。区域 4 为胫骨力实时预测区,支持生物力学阈值设置、胫骨力预测与数据显示。系统运行流程如下:完成 IMU 与压力鞋垫的无线通信配对,各区域实时显示运动学与动力学参数,基于此数据动态预测胫骨力,结合患者信息与预设阈值,通过语音反馈提示患者调整姿态,确保 PWB 训练的安全性与科学性。




图 1 可穿戴监测系统框架

Fig.1 Framework of the wearable monitoring system




图 2 上位机界面设计

Fig.2 Host computer interface design

2 实验

本文共招募 6 名健康受试者进行实验,受试者平均年龄为 (27.0 ± 2.7) 岁,身高为 (174.00 ± 2.24) cm,体重为 (72.12 ± 7.65) kg. 在实验之前,每位受试者都签署了一份书面知情同意书,该同意书经过华中科技大学同济医学院武汉儿童医院伦理委员会批准. 受试者健康且无任何影响步态的疾病,在过去两年内没有下肢或脊椎手术.

2.1 部分负重

PWB 是指患者在康复过程中,逐步将部分体重施加于患肢,以促进骨折愈合和功能恢复. 本文参考了骨科康复中最常用的 PWB 训练方法,下肢骨折患者术后康复的标准是 12 周不负重,然后在体重百分比的指导下逐渐增加负重^[15]. 训练过程中,患肢负重程度根据患者情况及愈合阶段进行控制,一般以患者体重的百分比衡量,例如 25% PWB(患肢承受 25% 体重)、50% PWB(患肢承受 50% 体重)、75% PWB(患肢承受 75% 体重)直至过渡完全负重(full weight bearing, FWB)阶段.

为帮助受试者熟悉 PWB 要求,如图 3 所示,正式实验开始前,每位受试者接受为期 2 d 的适应性训练:在研究人员指导下使用两根拐杖,以 3 点步态方法按照自选速度行走,感受不同目标负荷所对应的体重分配状态. 受试者首先通过测力台获取自身体重数据,再分别计算体重的 100%、75%、50% 和 25% 4 个目标负荷值. 这些目标负荷将作为 PWB 训练的阶段性标准. 按照传统训练方法,PWB 训练目标通过监测和控制受试者行走时患肢的垂直地面反力来实现,即通过地面反作用力的峰值变化判断受试者是否达到目标负荷. 训练期间,受试者佩戴可穿戴监测系统,该系统实时监测并反馈患肢的垂直 GRF 峰值. 患

肢的垂直 GRF 峰值与目标负荷之间的误差在体重的 5% 以内是可以接受. 当实验过程中超过目标负荷时,移动端触发振动或音频提醒信号,提示调整步态或负重力度. 受试者被要求进行无拐杖正常行走和有拐杖的 PWB 步态训练 (75% PWB, 50% PWB, 25% PWB),持续 2 d. 研究人员通过实时反馈帮助受试者调整步态节奏和负重分配,确保受试者能够充分适应目标负荷,掌握控制方法.

2.2 正式实验

实验在标准化生物力学实验室内进行,配备光学运动捕捉系统(Nokov, 采样频率 100 Hz)和测力台(Bertec, 采样频率 100 Hz),用于同步获取人体运动学和动力学数据. 同时,为验证可穿戴监测系统的性能,实验过程中受试者佩戴可穿戴监测设备进行实时数据采集.

正式实验期间,每位受试者统一身穿黑色紧身衣,并于体表黏贴 39 个反光标记点,以便光学运动捕捉系统能够实时追踪其运动轨迹. 使用黑色绑带将两个 IMU 分别固定在小腿外侧中部和足背中部,足底压力鞋垫固定在脚下. 首先,对惯性测量单元进行校准,需要受试者双脚对准标记线,以中性姿势站在行走的平台上静止 10 s. 此时,惯性导航设备会采集受试者初始姿态和站立状态的参考数据,作为后续实验运动的校准基准. 校准完毕后,6 位受试者依次进入 PWB 实验阶段. 实验过程中使用可调节腋窝拐杖,研究人员根据受试者身高和手臂长度调整拐杖长度. 如图 4 所示,PWB 时,每位受试者采用标准三点步态行走方式,拐杖和患肢同时着地后健肢向前迈步,从而减少患肢承受负荷. 实验任务包括正常行走、75% PWB、50% PWB 和 25% PWB. 受试者先以自选速度完成正常行走,再按照实验指导依次完成 PWB 任务,每组实验至少进行 10 次.




图 3 受试者适应 PWB 训练要求

Fig.3 Subjects participating in PWB training adaptation experiment



图 4 受试者执行 4 种 PWB 训练实验

Fig.4 Subjects performing four types of formal PWB training experiments

实验过程使用光学运动捕捉系统、测力台以及可穿戴监测系统同时记录数据。运动捕捉相机和测力台连接同一个数据采集软件,点击界面按钮启动记录过程。可穿戴监测系统数据采集通过自主研发的QT界面实现。该软件在移动端运行,点击“保存数据”按钮,同步开启惯性测量单元和足底压力鞋垫数据记录。实验过程中,如果受试者未能准确达到目标负重范围要求,可穿戴监测系统会发出信号提醒,纠正步态节奏。4种PWB水平实验均完成后,对实验数据进行复查。每位受试者每种实验至少需要达到10组完整合格的步态周期数据。

2.3 数据预处理

由于运动捕捉系统与可穿戴监测系统采用不同记录软件,导致时序偏差,因此需要对两系统数据进行同步处理。本文通过步态支撑期的特征点实现数据同步。步态支撑期是指步态周期中足部与地面接触的阶段。支撑期的起始点为足部触地瞬间(此时垂直地面反作用力从0开始显著上升),结束点为足部完全离地(此时垂直地面反作用力归0)。通过识别测力台GRF曲线与足底压力鞋垫的总压力曲线的起始点和结束点,对二者进行时序对齐。完成同步后,截取两者重合区间的完整步态支撑期数据,确保数据的完整性与一致性。

3 胫骨力求解方法

为实现可穿戴监测系统对胫骨力的准确估计,首先基于OpenSim构建的胫骨骨折模型进行仿真分析,得到下肢胫骨力,并将其作为后续研究的参考值。之后通过可穿戴监测系统采集的运动学和动力学数据,分别构建逆动力学模型(物理驱动)、MLP预测模型(静态映射)及双层LSTM预测模型(时序建模),实现对胫骨轴向力的动态预测。

3.1 OpenSim胫骨骨折模型仿真

在开展下肢胫骨力实时预测研究中,为确保不同方法的准确性,选择一个金标准作为参考值是至关重要的。OpenSim是一款由斯坦福大学开发的免费开源软件,可创建人体肌肉骨骼模型并模拟各项运动,具有较高的可靠性。本文基于OpenSim提供的“gait2354_simbody.osim”肌肉骨骼模型进行胫骨骨折建模,在模型的胫骨中段添加刚性关节,以模拟骨折真实状态。

如图5所示,OpenSim具体仿真流程如下:首先,利用光学运动捕捉系统和测力台的数据对模型进

行个性化缩放;随后,调用OpenSim内置的逆运动学工具,计算下肢关节运动轨迹;进一步使用逆动力学工具计算关节力矩,并基于静态优化方法求解肌肉力;最后,通过OpenSim的关节反力分析模块导出胫骨内部负荷。由于作用于胫骨的剪切力和侧向力较小,通常可以忽略不计^[16],胫骨轴向压缩力是评估胫骨负荷的关键参数,因此本文后续只计算胫骨轴向压缩力,并将其视为模型训练和结果对比的真实骨负荷。




图5 OpenSim胫骨力预测模型仿真分析

Fig.5 Simulation analysis of the tibial force prediction model using OpenSim

3.2 基于可穿戴监测系统的逆动力学模型

基于逆动力学模型求解胫骨力是一种物理驱动的传统方法。Romani等^[17]认为作用于胫骨的压缩力可以分为足部接触地面引起的外力和肌肉收缩引起的内力。本文通过分别求解外力 F_{ext} 和内力 F_{int} 来计算胫骨轴向力 F_{tibia} ,即

$$F_{tibia}(t) = F_{ext}(t) + F_{int}(t) \quad (1)$$

式中:外力 F_{ext} 是指GRF通过一定角度 β 作用在胫骨上的力,如图6所示;内力 F_{int} 则主要由跖屈肌等小腿肌肉的力组成。




图6 胫骨力计算参数示意

Fig.6 Tibial force-calculation parameters

根据可穿戴监测系统采集到的信号估算胫骨力,对式(1)进行简化。外力 F_{ext} 通过将垂直地面反力 GRF_n 投影到胫骨长轴上进行计算,内力 F_{int} 使用矢状面踝关节力矩除以跟腱力臂近似求解,即

$$F_{ext}(t) = |GRF_n(t)| \cos \beta(t) \quad (2)$$

$$F_{\text{int}}(t) = \frac{M_{\text{ankle}}(t)}{r_{\text{tendon}}} = \frac{\text{GRF}_n(t) \cdot \text{COP}_{\text{ap}}}{r_{\text{tendon}}} \quad (3)$$

式中: β 为胫骨节段在矢状面上的角度和方向; M_{ankle} 为矢状面踝关节力矩; r_{tendon} 为跟腱相对于踝关节中心的力臂长度, 本文假设 r_{tendon} 长度恒定, 并参考现有研究取其平均值为 $5 \text{ cm}^{[18]}$; COP_{ap} 为指压力中心相对于踝关节位置在前后方向上的距离, 其求解方式为

$$\text{COP}_{\text{ap}} = \sqrt{(P_x^2 + P_y^2)} = \sqrt{\left(\frac{\sum_{i=1}^n P_{ix} F_i}{\sum_{i=1}^n F_i} \right)^2 + \left(\frac{\sum_{i=1}^n P_{iy} F_i}{\sum_{i=1}^n F_i} \right)^2} \quad (4)$$

式中: P_x 、 P_y 为 COP_{ap} 坐标分量; $P_i(P_{ix}, P_{iy})$ 为足底压力鞋垫各传感单元坐标位置; F_i 为足底压力鞋垫各传感单元压力值。

为明确各传感单元坐标及 COP_{ap} 的数值, 需要在足底压力鞋垫上建立对应坐标系。首先, 受试者需保持自然站立姿势, 足部与小腿垂直, 赤足平放于鞋垫表面。随后, 找到受试者的内踝(胫骨下端内侧突出的骨性标志)和外踝(腓骨下端外侧突出的骨性标志), 并用标记笔分别标记两部位的中心位置。将内踝和外踝的标记点沿垂直方向投影至鞋垫平面, 两点投影之间连线中点即为踝关节中心在足底平面的投影。该投影点被定义为鞋垫坐标系的原点, x 轴沿鞋垫长轴指向足尖, y 轴垂直于 x 轴指向足外侧。建立好坐标系后, 基于鞋垫的传感单元布局, 可确定每个传感单元在坐标系中的位置, 用于后续 COP_{ap} 的计算。

综上, 逆动力学模型输入包含小腿 IMU 测得的矢状面角度 β 、足底压力鞋垫计算的垂直地面反力 GRF_n 及压力中心相对于踝关节位置的距离 COP_{ap} 。模型计算步骤如下, 将 GRF_n 沿胫骨长轴方向分解获得外力分量, 基于踝关节力矩与跟腱力臂计算内力分量。最终通过外力与内力线性叠加输出胫骨轴向力估计值。

3.3 基于可穿戴监测系统的 MLP 预测模型

为了提高胫骨轴向力的预测精度, 本文引入神经网络进行预测。相比于传统物理模型和线性回归, 神经网络具有更强的非线性拟合能力, 能够超越逆动力学模型的线性假设局限, 提高预测准确性。多层感知机是一种基于静态映射的传统神经网络, 能够作为基线模型进行性能评估。基于可穿戴监测系统数据特性, 本文构建了 MLP 预测模型。如图 7 所示, 模型输入层包含归一化处理后的足底压力鞋垫 24 个分区压

力值以及 2 个 IMU 采集的三轴加速度、三轴角速度。其中, 足底压力数据是将每一帧压力矩阵通过列向量求和处理得到。输入层接收数据后传递至模型的 1 个隐藏层, 隐藏层 1 包含 100 个神经元, 通过 ReLU 激活函数实现非线性变换, 以提取关键特征。隐藏层 2 包含 50 个神经元, 同样使用 ReLU 激活函数, 以进一步挖掘数据特征关系。输出层用于生成胫骨轴向力预测值。该任务是回归任务, 因此输出层采用线性激活函数, 以生成任意范围的连续值。为评估模型预测值与真实值之间的差距, 使用均方误差作为损失函数。选择 Adam 优化器, 默认学习率设置为 0.001, 可实现快速收敛并有效处理梯度消失或爆炸问题。模型开发基于 Matlab R2020a 平台, 利用其 Deep Learning Toolbox 构建神经网络。训练和验证通过 Matlab 的 `trainNetwork` 函数完成, 并基于 `validationFrequency` 参数设置验证间隔。训练完成后, 模型被导出为 Matlab 格式文件(.mat), 以便后续调用和部署。该模型能够在训练过程中逐步调整参数, 确保预测更加精准。




图 7 MLP 神经网络预测模型

Fig.7 MLP neural network prediction model

3.4 基于可穿戴监测系统的双层 LSTM 预测模型

在基于可穿戴传感器信号的胫骨力预测任务中, IMU 与足底压力鞋垫采集的数据与步态周期密切相关, 具有显著的时间序列特性。然而, MLP 作为传统神经网络, 其静态结构难以有效捕捉复杂时间序列数据中的动态变化。随着深度学习的发展, 相关算法在预处理、活动识别和回归预测等任务中取得显著成果。其中, LSTM 是目前最流行的一种能够捕捉输入变量动态时间关系的递归神经网络。LSTM 通过其特殊的记忆结构, 能够选择性地记忆和遗忘时间序列中的模式^[19]。这种结构通过跨时间步更新信息, 并通过输入门、遗忘门和输出门来控制信息的保留、更新和输出, 使得 LSTM 在需要分析时间依赖关系的数据任务中表现出色。

因此, 本文构建一种双层 LSTM 神经网络模型。如图 8 所示, 模型输入层包含归一化处理后的足

底压力鞋垫 24 个分区压力值以及 2 个 IMU 采集的三轴加速度、三轴角速度。其中足底压力鞋垫每一帧数据通过列求和方式处理,以降低数据冗余同时全面反映步态周期中的足底负载变化。模型核心由 2 层 LSTM 结构组成,第 1 层 LSTM 包含 60 个隐藏单元,第 2 层包含 100 个隐藏单元,两层均使用 tanh 激活函数,以增强对时间序列数据特征提取能力。LSTM 层的输出连接全连接层,用于将提取的时间序列特征映射至目标变量。为降低过拟合风险,全连接层后添加 dropout 层,丢弃率设置为 0.2。经过 dropout 层的输出被传递至输出层,用于生成胫骨轴向力预测值。训练过程中采用 Adam 优化算法提升收敛效率,并使用均方根误差 (root mean square error, RMSE) 作为损失函数,以衡量预测值与真实值之间误差。为进一步优化模型训练效果,采用分段学

习率衰减策略,初始学习率设置为 0.010,在训练 1200 个 epoch 后按 0.100 倍衰减至 0.001,从而实现早期快速收敛与后期精细优化。训练过程最多进行 1500 个 epoch,设置提前停止机制,若连续 50 个 epoch 验证集性能未提升,则终止训练。所有超参数通过网格搜索法优化确定,确保模型在验证集上达到最优性能,实现对目标变量的准确预测。模型开发基于 Matlab R2020a 平台,通过 Deep Learning Toolbox 构建神经网络。所有训练和验证过程基于 Matlab 的 trainNetwork 函数完成。训练完成后,模型权重以 MATLAB 格式保存(.mat),并通过 Matlab Coder 工具箱将训练好的模型转换为 C++动态链接库。在 QT 开发环境中,加载 C++动态链接库文件实现模型的嵌入,从而实现胫骨力实时监测功能。




图 8 基于双层 LSTM 神经网络的胫骨力预测模型

Fig.8 Tibial force prediction model based on a two-layer LSTM neural network

4 性能验证

基于可穿戴监测系统构建胫骨力求解模型后,为验证模型预测性能,通过 6 名受试者 PWB 实验数据构建数据集,分别应用于逆动力学模型进行计算,MLP 模型及双层 LSTM 模型进行训练和预测,记录得到的胫骨力。并定义决定系数 R^2 、平均绝对误差 e_{MA} 、均方根误差 e_{RMS} 等评估指标,将各模型预测结果与 OpenSim 真实值进行对比。

4.1 数据集构建

构建数据集用于训练和测试模型。足底压力鞋垫每次输出一个大小为 9×24 电容矩阵,通过列向量求和将矩阵压缩为 24 维特征向量,在降低数据冗余的同时保留压力分布趋势。数据集的输入特征由处理后的足底压力特征向量以及 2 个 IMU 的三轴加速度、三轴角速度组成,总输入特征维度为 36 维。为统一步态支撑期数据尺度,对同一周期内的胫骨力参考值与可穿戴监测系统采集到的数据进行三次样条

插值,每个周期的数据均被插值到 120 个时间点。将胫骨力的数据除以受试者对应体重 BW,消除个体差异影响。为确保不同输入特征的量纲一致性,对所有输入特征(包含足底压力与 IMU 数据)进行归一化处理,将其数值映射到 0~1 区间,避免特定参数对模型训练产生不当的主导作用。同样地,对输出数据(胫骨力/BW)进行归一化处理,以保持输入输出数据范围的一致性,模型预测后再通过反归一化将输出数据转换至 BW 形式。数据集基于 6 名受试者在 4 种负重条件下采集的 10 组步态周期数据,构建 240 组完整步态周期样本。输出为 OpenSim 仿真得到的轴向胫骨力。

4.2 模型训练

本文首先使用双层 LSTM 模型进行胫骨力求解。LSTM 作为时序模型,能够有效捕捉步态周期内的时间动态特征,而双层结构进一步增强了对时间依赖性的建模能力。在模型训练前,将数据集按 7:3 比例随机划分为训练集与测试集。对每种负重行走条件采用交叉验证策略,确保模型的预测具有良好泛

化能力. 模型输入训练集数据, 输出每个时间点的轴向胫骨力. 记录预测结果, 用于后续分析. 双层 LSTM 模型预测完成后, 依次使用逆动力学模型和 MLP 模型对胫骨力进行计算. 对于逆动力学模型, 利用可穿戴监测系统采集的关节角度、足底压力及足压中心数据进行胫骨力计算. 对于 MLP 模型, 使用与双层 LSTM 相同的数据集进行训练, 记录输出的胫骨力数据. 通过将 3 种模型的预测结果与 OpenSim 仿真真值进行对比, 可量化评估物理驱动模型、静态数据驱动模型及时序模型对动态生物力学参数的捕捉能力差异, 明确各方法在 PWB 场景下的适用性边界.

4.3 评估标准

使用 3 种方法分别进行预测后, 为全面评估各方法性能, 采用多项评估指标对预测结果进行分析. 本文使用决定系数 R^2 评估模型对数据的拟合程度, 并计算以体重 BW 为单位的平均绝对误差和均方根误差. 其中, R^2 的取值范围在 0~1 之间, 其数值越接近于 1, 表明模型对数据的拟合程度越好. 此外, 本文进一步计算 3 种模型预测的胫骨力峰值与 OpenSim 肌肉骨骼模型计算的胫骨力峰值的百分比差异, 用于衡量不同方法在峰值预测上的偏差. 为深入分析 GRF 与胫骨力真实值之间的相关性, 计算

Person 相关系数, 并通过 Fisher 的 z 变换求得各负重任务下相关系数的平均值和标准差^[20].

5 结果分析

完成模型预测后, 对实验数据进行分析与讨论. 本文将从胫骨力预测误差分析、有效传感器组合方案方面进行详细说明, 旨在全面评估本文方法的预测效果和探讨潜在的改进方案.

5.1 胫骨力误差分析

3 种方法在不同负重任务下的 R^2 、 e_{MA} 和 e_{RMS} 的平均值及标准差如表 1 所示, 以综合评估各方法的预测误差. 对于 4 种负重类型, 双层 LSTM 预测的胫骨力 R^2 在 $(0.959 \pm 0.015) \sim (0.996 \pm 0.020)$ 之间, 相较其他方法表现出更高的拟合度. 同时, 其 e_{MA} 在 $(0.04 \pm 0.02) \sim (0.08 \pm 0.05)$ BW 之间, e_{RMS} 在 $(0.04 \pm 0.03) \sim (0.11 \pm 0.04)$ BW 之间, 均显著低于其他方法. 综合分析 3 种方法的预测结果可得, 双层 LSTM 模型在不同负重任务下均展现最佳预测性能, 其预测结果与 OpenSim 计算参考值拟合程度最高. MLP 模型的预测性能介于逆动力学模型和 LSTM 模型之间. 逆动力学模型误差最大, 表明其对胫骨力预测能力受限.

表 1 3 种模型准确性
Tab.1 Accuracy of the three models

负重类型	逆动力学模型			MLP 模型			双层 LSTM 模型		
	R^2	e_{MA}/BW	e_{RMS}/BW	R^2	e_{MA}/BW	e_{RMS}/BW	R^2	e_{MA}/BW	e_{RMS}/BW
FWB	0.959 ± 0.027	0.17 ± 0.03	0.21 ± 0.08	0.995 ± 0.021	0.13 ± 0.06	0.15 ± 0.03	0.996 ± 0.020	0.08 ± 0.05	0.11 ± 0.04
75% PWB	0.912 ± 0.023	0.12 ± 0.06	0.15 ± 0.05	0.961 ± 0.024	0.09 ± 0.02	0.12 ± 0.05	0.980 ± 0.019	0.06 ± 0.03	0.09 ± 0.02
50% PWB	0.928 ± 0.026	0.09 ± 0.03	0.11 ± 0.04	0.949 ± 0.025	0.08 ± 0.04	0.09 ± 0.02	0.961 ± 0.020	0.05 ± 0.02	0.06 ± 0.02
25% PWB	0.901 ± 0.035	0.08 ± 0.04	0.09 ± 0.03	0.944 ± 0.018	0.05 ± 0.03	0.07 ± 0.03	0.959 ± 0.015	0.04 ± 0.02	0.04 ± 0.03

图 9 显示了基于可穿戴监测系统的逆动力学模型、基于 MLP 的预测方法和基于双层 LSTM 的预测方法对 4 种负重类型的结果与参考值的差异, 展示了 6 位受试者在 4 种不同负重步行条件下的轴向胫骨压缩力曲线. 其中, 绿色及其阴影区、黑色及其阴影区、橙色及其阴影区、蓝色及其阴影区分别表示由 OpenSim、逆动力学模型、MLP 模型、双层 LSTM 模型计算或预测得到的胫骨力的平均值和标准差. 图中双层 LSTM 模型预测曲线与 OpenSim 真实值区域高度吻合, 而逆动力学模型和 MLP 则表现出一定偏差, 进一步证明双层 LSTM 模型在捕捉胫骨力动态变化特征方面的显著优势.

此外, 本文还计算了 3 种方法在 4 种负重类型下

预测的胫骨力峰值与标准胫骨力峰值之间的百分比差异. 图 10 给出了 3 种方法在不同负重类型峰值预测的百分比差异数据分布特征, 其中 LSTM 在 4 种条件下预测的峰值与其他参考值的平均百分比差异分别为 4.02%、4.34%、4.52% 和 5.61%. 相比之下, 逆动力学模型的百分比差异平均值分别为 16.65%、17.72%、15.37%、18.19%. MLP 模型的百分比差异平均值分别为 5.67%、7.04%、6.97%、7.80%. 在胫骨力峰值预测分析中, LSTM 模型的平均误差和分布区域小于逆动力学模型和 MLP 模型, 表现出更高精度.

上述结果表明逆动力学模型相对效果不佳. 这是由于逆动力学模型忽略了来自前后和中外侧 GRF 的力矩和反作用力, 缺乏对踝关节中心的真实估计,




图 9 6名参与者在 4 种 PWB 行走条件下的胫骨力曲线

Fig.9 Tibial-force curves of six participants during four different weight-bearing walking conditions




图 10 预测胫骨力峰值与标准胫骨力峰值之间百分比差异
Fig.10 Percent difference between the predicted tibial peak force and the standard tibial peak force

会系统性低估或高估胫骨轴向力。因此本文同时引入神经网络来预测负重期间胫骨力。神经网络通过非映射能力,能够超越传统逆动力学模型的线性假设限制,提高预测的准确性。正因如此,MLP 模型在研究中的预测性能明显优于逆动力学模型。然而,传统神经网络在捕捉时间序列变化和动态特征方面的能力有限,其仅能根据当前时刻的输入预测当前值,缺乏对时间序列数据的记忆能力。因此,本文提出了使用双层 LSTM 模型对可穿戴监测设备数据进行处理。实验同时验证了 LSTM 模型在步态时序处理中的优势,在 4 种 PWB 实验中预测结果最佳。LSTM 模型能够自适应捕捉步态周期内长期依赖关系和动态变化,进一步提高预测的准确性。

5.2 有效传感器组合方案

为探讨更有效的传感器组合方案,本文以正常行走为例,使用不同的可穿戴传感器组合方案,分别通过 MLP 和双层 LSTM 模型预测行走过程中胫骨力,并与 OpenSim 仿真得到的参考值进行对比分析。不同可穿戴设备采集的数据可以反映运动过程中不同的生物力学信息,传感器的选择和组合方式影响了胫骨力预测的精度和模型性能表现。在实验中,本文测试了多种传感器组合,包括单独使用足底压力鞋垫、单独使用 IMU、足底压力鞋垫与 IMU 组合等 5 种方式。随后分别通过 MLP 和双层 LSTM 模型对每种组合数据进行训练与测试,通过多次迭代计算模型预测值与实验参考值之间的平均绝对误差及其标准差,以评估不同组合方案性能。

表 2 和表 3 分别为 MLP 和双层 LSTM 模型在不同传感器组合下的预测误差分析。结果显示,无论是使用 MLP 还是双层 LSTM 模型,本文提出的完整的可穿戴监测设备配置方案预测误差最低。然而,在过去的研究中,许多基于实验室的运动分析试图通过直接监测地面反作用力来得到下肢胫骨力^[21]。上述研究认为 GRF 指标的增加反映了胫骨内部负荷的增加。通过这种原理进行监测的实验设备包括体重秤、测力板和生物反馈装置等。为了进一步验证和分析 GRF 与轴向胫骨力之间的关系,本文计算了 GRF 与

轴向胫骨力之间的 Person 相关系数. 表 4 展示了 6 名受试者在 4 种步行方式下, 用测力台测量得到的垂直 GRF 与 OpenSim 仿真得到的胫骨力真实值之间的 Person 相关系数. 并利用 Fisher 的 z 变换计算受试者间相关系数的平均值和标准差.

表 2 使用不同传感器组合结合 MLP 模型预测正常行走过程中的胫骨力的误差

Tab.2 Error in tibial-force prediction during normal walking using the MLP model with various sensor combinations

传感器组合方案	e_{MA} (均值 $\pm$ 标准差)/BW
鞋垫 + 足部 IMU + 小腿 IMU	0.13 ± 0.06
鞋垫 + 足部 IMU	0.15 ± 0.03
足底压力鞋垫	0.18 ± 0.05
足部 IMU + 小腿 IMU	0.27 ± 0.04
足部 IMU	0.26 ± 0.05

表 3 使用不同传感器组合结合 LSTM 模型预测正常行走过程中的胫骨力的误差

Tab.3 Error in tibial-force prediction during normal walking using the LSTM model with various sensor combinations


传感器组合方案	e_{MA} (均值 $\pm$ 标准差)/BW
鞋垫 + 足部 IMU + 小腿 IMU	0.08 ± 0.05
鞋垫 + 足部 IMU	0.13 ± 0.04
足底压力鞋垫	0.14 ± 0.03
足部 IMU + 小腿 IMU	0.23 ± 0.04
足部 IMU	0.24 ± 0.06

表 4 胫骨力与垂直 GRF 之间的 Pearson 相关系数


Tab.4 Pearson correlation coefficient between tibial force and vertical GRF

受试者	FWB	75% FWB	59% FWB	25% FWB
1	0.59	0.62	0.64	0.69
2	0.67	0.69	0.72	0.76
3	0.60	0.57	0.62	0.68
4	0.61	0.64	0.65	0.72
5	0.55	0.59	0.61	0.65
6	0.61	0.58	0.59	0.62
均值 $\pm$ 标准差	0.61 ± 0.06	0.62 ± 0.07	0.64 ± 0.08	0.68 ± 0.10


结果显示, 垂直 GRF 与轴向胫骨力的相关系数在 0.61 ~ 0.69 之间, 表明二者并不具备强相关性. 实际上运动过程中, 大部分胫骨力是由肌肉收缩引起, 胫骨力的变化受到其他因素的影响, 不仅仅由 GRF 的变化决定. 如图 11 所示, 结合某位受试者在 4 种 PWB 情况下数据, 以正常行走为例, 测力板测得的峰值 GRF 约为体重的 1.0 倍, 而通过 OpenSim 仿真得到的峰值胫骨力约为体重的 4.1 倍. 这表明行走过程中胫骨上的负荷通常比 GRF 大得多. 且 GRF 峰值通常在时间上与胫骨力峰值不一致, GRF 峰值出现在运动周期前期, 胫骨力峰值则通常在运动周期后期.




(a) FWB 实验



(b) 75%PWB 实验



(c) 50%PWB 实验



(d) 25%PWB 实验

图 11 4 种 PWB 实验下胫骨力与 GRF 代表性示例

Fig.11 Representative examples of tibial force and GRF under four loading conditions

胫骨力的增加可在 GRF 未增加时发生, 二者动态变化并非完全一致. 因此, 仅通过 GRF 来推测胫骨力的变化存在局限性, 需要结合更全面的运动学信息进行胫骨负荷的准确预测, 这也进一步验证了本文未单独依靠足底压力鞋垫进行胫骨力监测的合理性.

因此,本文引入 IMU 进行同步监测。足底压力鞋垫主要捕捉了地面反作用力相关信息,而 IMU 则提供步态运动中身体的动态特征和运动学数据。二者有效结合弥补单一传感器数据局限性,能够更全面反映胫骨力的动态变化特征。表 2 与表 3 结果验证了可穿戴监测设备配置方案的有效性。此外,从模型性能来看,双层 LSTM 模型在传感器组合下的预测误差均低于 MLP 模型。再一次验证了 LSTM 模型处理步态相关的时间序列数据方面的优势。

综上所述,实验结果表明,本文提出的可穿戴监测设备配置方案能够显著提高胫骨力预测结果,是一种有效的组合方案,为未来开发便携高效的可穿戴监测系统提供参考,对推动个性化康复训练具有重要价值。

6 结 语

胫骨骨折患者在 PWB 康复过程中,骨骼负荷的精准控制是避免愈合延迟或二次损伤的关键。现有监测设备存在无法实时反馈或预测精度不足的问题,难以满足动态康复评估需求。针对这一挑战,本文提出并实现了一套智能化可穿戴监测系统。该系统由惯性测量单元与柔性足底压力鞋垫组成,可实现下肢运动学(关节加速度/角速度/角度)与动力学(压力分布)数据的实时同步采集。基于可穿戴监测系统构建逆动力学模型、MLP 模型及双层 LSTM 模型 3 种胫骨力预测方法,通过 4 种 PWB 实验验证模型预测性能。结果表明,LSTM 模型不仅能够有效克服逆动力学模型的系统性偏差,还能更精确提取胫骨力相关的动态时序特征,显示更优的预测性能。可穿戴监测系统的多模态传感器方案与 LSTM 动态时序建模的协同效应,为胫骨力的精准预测提供了一种高效可靠的解决方案。

然而,本文目前基于健康受试者模拟 PWB 行走的实验数据构建预测模型,尽管该数据为方法验证提供基础支撑,但其与真实患者步态特征仍存在一定差异。未来研究将进一步使用可穿戴监测系统采集术后患者实际康复训练数据,并引入表面肌电信号捕捉下肢关键肌群的活动特征,以提升预测算法对代偿步态的解析能力,优化胫骨力预测性能。此外,本文受限于样本规模($n=6$)和测试场景(平地行走),未来将扩大受试者群体覆盖不同年龄、体重的胫骨骨折患者,并增加复杂运动场景(如上、下楼梯、坡道行走)下的实验验证,以进一步提升模型临床普适性与环境

适应性。针对模型泛化能力验证需求,后续需测试数据集外的患者运动数据并进行分析。

参考文献:

- [1] Shen F Y, Chen B L, Guo Q S, et al. Augmented reality patient-specific reconstruction plate design for pelvic and acetabular fracture surgery[J]. International Journal of Computer Assisted Radiology and Surgery, 2013, 8: 169-179.
- [2] Hurkmans H L, Bussmann J B, Benda E, et al. Effectiveness of audio feedback for partial weight-bearing in and outside the hospital: A randomized controlled trial[J]. Archives of Physical Medicine and Rehabilitation, 2012, 93(4): 565-570.
- [3] Hustedt J W, Blizzard D J, Baumgaertner M R, et al. Current advances in training orthopaedic patients to comply with partial weight-bearing instructions[J]. The Yale Journal of Biology and Medicine, 2012, 85(1): 119-125.
- [4] Houben I B, Raaben M, van Basten Batenburg M, et al. Delay in weight bearing in surgically treated tibial shaft fractures is associated with impaired healing: A cohort analysis of 166 tibial fractures[J]. European Journal of Orthopaedic Surgery & Traumatology, 2018, 28: 1429-1436.
- [5] Mavčič B, Antolič V. Optimal mechanical environment of the healing bone fracture/osteotomy[J]. International Orthopaedics, 2012, 36: 689-695.
- [6] Komi P V. Relevance of *in vivo* force measurements to human biomechanics[J]. Journal of Biomechanics, 1990, 23: 23-34.
- [7] Tveit M, Kärrholm J. Low effectiveness of prescribed partial weight bearing: Continuous recording of vertical loads using a new pressure-sensitive insole[J]. Journal of Rehabilitation Medicine, 2001, 33(1): 42-46.
- [8] Raaben M, Holtslag H R, Leenen L P H, et al. Real-time visual biofeedback during weight bearing improves therapy compliance in patients following lower extremity fractures[J]. Gait & Posture, 2018, 59: 206-210.
- [9] Matijevich E S, Branscombe L M, Scott L R, et al. Ground reaction force metrics are not strongly correlated with tibial bone load when running across speeds and slopes: Implications for science, sport and wearable tech[J]. PLOS One, 2019, 14(1): e0210000.
- [10] Elstob L J, Nurse C A, Grohowski L M, et al. Tibial bone forces can be monitored using shoe-worn wearable

- sensors during running[J]. *Journal of Sports Sciences*, 2022, 40(15): 1741-1749.
- [11] Dorschky E, Nitschke M, Martindale C F, et al. CNN-based estimation of sagittal plane walking and running biomechanics from measured and simulated inertial sensor data[J]. *Frontiers in Bioengineering and Biotechnology*, 2020, 8: 604.
- [12] Ma T, Xu X, Chai Z W, et al. A wearable biofeedback device for monitoring tibial load during partial weight-bearing walking[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2023, 31: 3428-3436.
- [13] Matijevich E S, Scott L R, Volgyesi P, et al. Combining wearable sensor signals, machine learning and biomechanics to estimate tibial bone force and damage during running[J]. *Human Movement Science*, 2020, 74: 102690.
- [14] Liu J X, Wang M F, Wang P, et al. Cost-efficient flexible supercapacitive tactile sensor with superior sensitivity and high spatial resolution for human-robot interaction[J]. *IEEE Access*, 2020, 8: 64836-64845.
- [15] Rüedi T P, Murphy W M, Colton C L, et al. *AO Principles of Fracture Management*[M]. Stuttgart : Thieme, 2000.
- [16] Wehner T, Claes L, Simon U. Internal loads in the human tibia during gait[J]. *Clinical Biomechanics*, 2009, 24(3): 299-302.
- [17] Romani W A, Gieck J H, Perrin D H, et al. Mechanisms and management of stress fractures in physically active persons[J]. *Journal of Athletic Training*, 2002, 37(3): 306-314.
- [18] Farris D J, Sawicki G S. Human medial gastrocnemius force-velocity behavior shifts with locomotion speed and gait[J]. *Proceedings of the National Academy of Sciences*, 2012, 109(3): 977-982.
- [19] Hochreiter S, Schmidhuber J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [20] Zadpoor A A, Nikooyan A A. The relationship between lower-extremity stress fractures and the ground reaction force: A systematic review[J]. *Clinical Biomechanics*, 2011, 26(1): 23-28.
- [21] van der Worp H, Vrielink J W, Bredeweg S W. Do runners who suffer injuries have higher vertical ground reaction forces than those who remain injury-free? A systematic review and meta-analysis[J]. *British Journal of Sports Medicine*, 2016, 50(8): 450-457

(责任编辑: 王晓燕)