

文章编号: 1004-7220(2025)02-0255-08

· 专家论坛 ·

# 肌骨系统多体动力学仿真新进展： 从数据驱动到数据-物理耦合驱动

陈文轩, 任韦燕, 姚杰\*, 蒲放\*

(生物力学与力生物学教育部重点实验室; 高端医疗装备与器械创新及转化工业和信息化部重点实验室; 国家医学攻关(医工结合方向) 高端医疗装备与器械产教融合创新平台; 北京航空航天大学 生物与医学工程学院, 北京 100191)

**摘要:** 肌骨系统多体动力学仿真是解析人体运动生物力学机制的重要工具, 其发展正从传统物理模型驱动向数据驱动、物理-数据混合驱动转变, 本文对相关的新进展进行综述。传统的基于物理模型的肌骨系统多体动力学仿真已经在仿真度、优化方法、软件工具等方面发展非常充分, 但由于依赖复杂实验数据与高计算量的微分方程求解, 实际应用仍有很大限制。近年来, 随着深度学习技术的快速发展, 基于数据驱动的肌骨系统多体动力学仿真, 已经在关节角度、位姿、地面反作用力、关节力矩、肌力的高效预测, 以及外骨骼的控制算法等方面展现出了巨大优势, 显著降低了参数测量复杂度。然而, 纯数据驱动模型存在泛化性不足与生物力学规律失真的问题。为此, 物理-数据耦合驱动模型通过嵌入牛顿-欧拉方程、肌肉本构方程等物理约束, 结合物理信息神经网络等混合架构, 在提升预测精度的同时保障解的生物合理性。当前研究仍面临跨尺度物理方程整合不足、多关节协同建模困难等挑战。未来需进一步优化模型架构, 融合运动学无标记捕捉技术, 并探索多尺度物理规律与个性化参数反演, 以推动智能康复、运动评估等领域的应用转化。

**关键词:** 肌骨系统; 多体动力学; 数据驱动模型; 物理信息神经网络; 生物力学建模

中图分类号: R 318.01 文献标志码: A

DOI: 10.16156/j.1004-7220.2025.02.001

## New Advances in Multibody Dynamics Simulation of the Musculoskeletal System: From Data-Driven to Data-Physics Hybrid Approaches

CHEN Wenxuan, REN Weiyan, YAO Jie\*, PU Fang\*

(Key Laboratory of Biomechanics and Mechanobiology, Ministry of Education; Key Laboratory of Innovation and Transformation of Advanced Medical Devices, Ministry of Industry and Information Technology; National Medical Innovation Platform for Industry-Education Integration in Advanced Medical Devices; School of Biological Science and Medical Engineering, Beihang University, Beijing 100191, China)

**Abstract:** Multibody dynamics simulation of the musculoskeletal system is an essential tool for analyzing the biomechanical mechanisms underlying human motion. Recent research trends have shifted from traditional physics-based models toward data-driven or data-physics hybrid frameworks. This review presents the latest

收稿日期: 2025-02-28; 修回日期: 2025-03-03

基金项目: 国家重点研发计划项目(2023YFC3604503), 国家自然科学基金项目(12072019)

通信作者: 蒲放, 教授, E-mail: pufangbme@buaa.edu.cn; 姚杰, 副教授, E-mail: yaojie@buaa.edu.cn

\* 为共同通信作者

developments in these areas. Physics-based multibody dynamics simulations have undergone significant progress in terms of simulation fidelity, optimization algorithms, and software tools. However, their practical implementation remains constrained by the need for complex experimental data and the computational expense of solving differential equations. Conversely, data-driven methods bolstered by advancements in deep learning have demonstrated remarkable efficiency in predicting joint angles, postures, ground reaction forces, joint torques, and muscle forces, as well as developing control algorithms for exoskeletons. However, despite these advantages, data-driven approaches face challenges such as limited generalizability and potential violation of biomechanical principles. To address these limitations, data-physics hybrid approaches (e.g., physics-informed neural network, PINN) which integrate physical constraints (e.g., Newton-Euler equations, muscle constitutive laws) with data-driven architectures have been developed. This synergy enhances prediction accuracy while preserving the biological plausibility of solutions. Nevertheless, critical challenges persist, including the integration of multi-scale physical equations and the modeling of multi-joint coordination dynamics. Future research should prioritize: optimizing hybrid model architectures to balance computational efficiency and mechanistic accuracy, incorporating markerless motion capture techniques to improve real-world applicability, exploiting multi-scale physics and personalized parameter inversion to advance precision rehabilitation and motion analysis. These efforts will foster innovations in intelligent rehabilitation systems, clinical motion assessment, and related translational fields.

**Key words:** musculoskeletal system; multibody dynamics; data-driven models; physics-informed neural network; biomechanical modeling

肌骨系统多体动力学模型是理解和分析人体运动的重要工具。通过整合解剖学、力学和多体系统理论,量化骨骼、关节和肌肉的力学特性,该模型能够解析运动中的载荷传递、能量消耗及损伤机制<sup>[1]</sup>,已经在分析肌骨系统病变原因和术后预期效果<sup>[2]</sup>、优化运动技术来提高运动表现并减少损伤风险、评估士兵在高负荷训练中的关节负荷等应用中发挥了重要作用。

肌骨系统多体动力学建模可追溯至20世纪70年代。在模型仿真度方面,其发展历程经历了从初期基于简单关节和肌肉假设的二维平面单关节模型<sup>[3]</sup>,到1980年代通过引入定量解剖学数据及肌肉结构实验逐步提升精度<sup>[4]</sup>,从多刚体模型逐步转变为多柔体模型,最终演进为包含700块肌肉的复杂全身模型<sup>[5]</sup>。在分析方法层面,研究从传统的静态优化、动态优化和计算肌肉控制等肌力分配算法,逐渐发展为融合肌电(electromyography, EMG)信号约束的目标函数构建<sup>[6]</sup>,并开始探索基于肌肉协同理论和多级神经控制的肌力分配新范式<sup>[7]</sup>。在仿真工具方面,从最初的手工公式推导到如今的Opensim、Anybody、SIMM、LifeMOD、HBM和MuJoCo等仿真平台,使得研究者能够更便捷地共享模型资

源并模拟复杂的运动过程<sup>[8]</sup>。然而,传统的肌骨动力学模型的构建和验证通常依赖于完整的实验数据,包括关节运动学数据、地面反作用力(ground reaction force, GRF)、EMG信号。这些数据的获取过程复杂,往往需借助昂贵的仪器设备和专业的实验室环境,限制了模型的普及和在临床应用中的可行性<sup>[9]</sup>。同时,传统的动力学仿真方法需要迭代求解复杂的微分方程组,单次步态周期的计算肌肉控制过程耗时可达数十分钟。这种高计算复杂度严重制约了模型在实时分析、临床诊断和交互式康复训练等场景的应用。

近年来,随着深度学习技术的突破性进展,肌骨系统生物力学建模逐步向数据驱动、数据-物理耦合驱动的方向发展,不仅突破了传统全参数测量的技术限制,更通过构建高效预测模型显著简化了逆向动力学分析流程,为临床步态分析、运动康复工程等领域开辟了新的技术路径。

## 1 基于数据驱动的肌骨系统动力学仿真

数据驱动方法是基于大数据和机器学习等技术,通过挖掘数据间的高维关联特性,直接建立输入与输出之间的映射关系,而无需依赖传统建模中

复杂的物理假设和数学求解过程。相比于基于理论模型的方法,数据驱动方法具有建模速度快、灵活性高、适应复杂非线性系统等优势,特别适用于解决传统方法难以处理的高维、多变量耦合问题。在肌骨系统动力学建模中,这类方法已被成功用于探索人体足底局部压力与整体 GRF、运动学与动力学数据、EMG 信号与肌力等关键指标之间的复杂关联。在有限测量参数条件下,研究者可以利用数据驱动技术能够快速预测 GRF、关节力矩及肌肉激活等关键生物力学指标,为简化肌骨系统建模复杂性提供了高效的解决方案。

### 1.1 人体关节角度和位姿预测模型

人体关节角度和位姿分析是评价运动表现、识别功能障碍、优化康复训练和设计人体工程学产品的关键基础。传统的关节角度和人体位姿数据基于多个的反射标记点对关节角度和坐标进行拟合,为了简化这一流程,Cao 等<sup>[10]</sup>开发了基于视频的开源人体姿态估计框架 OpenPose,通过卷积神经网络生成每个关节的二维坐标以及关节之间的关联;Nakano 等<sup>[11]</sup>进一步利用多摄像机实现三维姿态的估计,80%的关节位置估计误差小于 30 mm。除了基于视频的运动捕获,EMG 数据也被用来进行关节角度的预测。在基于 EMG 数据的研究中,Shrirao 等<sup>[12]</sup>基于人工神经网络利用 EMG 信号对手指关节角度进行预测,相对均方根误差为 10%~15%;Pan 等<sup>[13]</sup>提出了一种切换机制,包括一个线性判别分析分类器和 14 个状态空间模型,用于不同手腕运动下的手指关节角度的连续估计,平均估计  $R^2$  达到 0.843。这些研究很好地拓展了人体关节角度与位姿分析的应用场景。

### 1.2 GRF 预测模型

GRF 作为表征人体运动动力学特征的核心指标,其三维力矢量与时间序列特征的精准预测能够直接反映步态稳定性、下肢负荷分布及能量传递效率。GRF 预测模型的数据一般采用足底压力或运动学数据。基于足底压力数据的研究从早期 Savelberg 等<sup>[14]</sup>采用人工神经网络 (artificial neural network, ANN) 与 25 个传感器预测垂直 GRF,后续研究者通过时间导数融合 (Choi 等<sup>[15]</sup>) 提升模型精度;而基于运动学数据的研究则突破接触式测量限制,Girka 等<sup>[16]</sup>利用人体特征点坐标,Hossain 等<sup>[17]</sup>

结合下肢惯性测量单元 (inertial measuring unit, IMU), Sugai 等<sup>[18]</sup>整合深度相机与长短时记忆 (long short-term memory, LSTM) 模型实现非接触预测。这些技术路径通过传感器精简、特征工程优化及深度学习应用,拓展了 GRF 评估在临床步态分析与可穿戴设备等场景的实用价值。

### 1.3 关节力矩预测模型

关节力矩是人体运动的动力学枢纽,其动态演变规律的解析能够量化评估关节载荷传递效率,并构建骨骼系统能量代谢与运动意图间的映射关系。关节力矩预测模型的数据一般采用足底压力、运动学数据和 EMG 数据。基于足底压力数据的模型 (如 Jacobs 等<sup>[19]</sup>) 聚焦踝关节力矩预测,在不同速度下实现误差小于 10%,但局限性在于不能预测足踝之外的关节;基于运动学数据的研究通过多模态整合突破单一数据的限制,如 Hossain 等<sup>[17]</sup>结合全连接、卷积、循环网络混合架构与 3 个 IMU 实现多种步行状态下下肢关节力矩高精度预测 (误差 < 5 N·m);基于 EMG 信号的研究则深入神经肌肉机制,Wang 等<sup>[20]</sup>利用 ANN 建立肘关节 EMG-力矩映射。3 类技术路径在误差控制、关节覆盖及临床适用性上形成梯度突破,为康复机器人及运动分析提供了多元化解决方案。

### 1.4 肌力预测模型

肌力分析作为人体运动系统生物力学输出的本源解析,构建了神经驱动信号向多关节动力学输出的本构关系,揭示了骨骼肌激活时序与收缩力向量空间分布的动态耦合规律。肌力预测模型的数据一般采用运动学数据和 EMG 数据。在运动学数据驱动方面,Dao 等<sup>[21]</sup>基于 LSTM 构建运动学-肌力时序映射模型,实现步态周期下肢主肌群激活模式动态解析 (均方根误差 < 10%),并通过迁移学习增强跨数据集适应性<sup>[21]</sup>;William 等<sup>[22]</sup>进一步融合身高、体重等多模态特征,利用循环神经网络提升膝关节动力学参数预测精度,凸显时序建模优势。基于 EMG 信号的研究则聚焦信号-力学关联突破:Liu<sup>[23]</sup>通过 ANN 建立动态收缩肌力的 EMG-力关系模型,Mokri 等<sup>[24]</sup>采用遗传算法优化支持向量回归,实现下肢肌肉力 98.67% 预测精度;Ao 等<sup>[7]</sup>创新性提出肌肉协同外推法,通过表面/深层 EMG 数据集与主成分分析,仅需 5~6 个协同成分即可预测深层

肌肉激活程度,为缺失关键EMG信号时的神经肌肉控制评估提供新范式。两类技术路径分别从运动学泛化能力提升与EMG信号深层解析维度,共同推进了康复评估与外骨骼控制等领域的精准化发展。

### 1.5 人体肌肉控制优化模型

人体肌肉控制分析对于理解动作机制、优化运动表现以及开发康复与机器人技术具有重要意义。传统的方法通过优化计算肌肉控制,尽管直接射击法和直接配点法能够在一定程度上实现优化,但由于计算量巨大且结果缺乏广泛适用性,这些方法的应用受到了限制。近年来,强化学习被引入以分析人体肌肉控制策略,基于人体的状态量(如关节角度、角速度、GRF)和深度学习网络来预测肌肉控制量。Song等<sup>[25]</sup>在OpenSim基础上推出专门的强化学习模块opensim RL,通过合适的奖励函数和强化学习算法(例如深度确定性策略梯度),使得虚拟人体模型能够具备正常人的行走、跑步和平衡能力,并能模拟异常步态。除了用于模拟人体运动,人体肌肉控制模型还被用于辅助设计外骨骼,显著提升了人-外骨骼协同工作的性能<sup>[26]</sup>。值得注意的是,当肌肉数量特别多时,肌肉控制计算可能会面临失效的风险。为此,Zuo等<sup>[5]</sup>结合人体多肌肉协同控制理论,提出了一种降维的控制策略,将人体中的700多块肌肉编码到低维空间,从而大大提升了肌肉控制的计算鲁棒性。

基于数据驱动的肌骨动力学代理模型虽能实现参数快速估计,然而面临一些局限性泛化性能约束:模型对训练数据覆盖范围的依赖性较强,当输入数据超出训练集表征的异质运动模式(如特殊步态、病理状态)时,预测可靠性显著下降;噪声敏感性问题:传感器采集噪声(如EMG信号串扰、运动学数据漂移)易通过数据驱动框架放大,导致力学参数估计偏差累积;生物力学规律失配:纯数据驱动的黑箱特性可能使预测结果违背关节力矩平衡、肌肉力-长度关系等基础生物力学约束,降低结果的生理合理性。

## 2 物理和数据耦合驱动的肌骨系统多体动力学仿真

为克服纯数据驱动模型在泛化能力和物理一

致性方面的局限性,物理和数据耦合驱动方法逐渐成为复杂动力学建模领域的研究热点之一<sup>[27]</sup>。该方法通过将物理规律(如牛顿-欧拉动力学方程、肌骨本构方程)以先验知识的形式融入数据驱动模型中,通常通过设计混合损失函数或物理约束网络架构,将物理方程与数据学习过程有机结合,既保留了数据驱动方法在处理高维、非线性问题中的灵活性,又利用物理约束提高了模型的稳定性、可解释性和对未见数据的泛化能力。在肌骨系统建模中,这种方法通过嵌入肌骨系统的力学特性和生物物理规律,可以有效解决纯数据驱动方法在小样本数据、物理一致性和复杂动力学行为建模中的不足。

### 2.1 基于物理信息神经网络的肌骨系统多体动力学仿真

物理信息神经网络(physics-informed neural network, PINN)作为物理和数据耦合驱动方法的典型代表,通过在训练过程中同时优化数据匹配项(实验观测数据残差)与物理正则项(控制方程残差、边界条件残差),通过反向传播算法对复合损失函数进行梯度计算,使模型参数更新过程受到物理定律的显式引导<sup>[28]</sup>。生物力学特性与运动学观测数据的协同建模通过物理守恒量的硬约束有效抑制了非物理解的出现,使得基于部分观测数据预测多项动力学数据成为可能,同时对肌骨模型参数进行优化。

EMG信号作为肌骨动力学模型中表征肌肉激活状态的关键参数,能够有效反映肌肉力量生成机制与神经运动控制特征。因此,大量PINN以EMG作为模型的输入。

Zhang等<sup>[29]</sup>以步态周期的表面EMG信号作为模型的输入,采用卷积神经网络进行特征提取,对关节角度和肌力进行预测后建立关节动力学方程,在关节角度和肌力的预测误差的基础上将关节动力学误差作为损失函数的一部分,以实现物理信息的整合,结果表明预测精度以及泛化能力优于传统模型。后续研究中,该团队进一步提出迁移学习框架,在新的受试者预测模型上固定卷积网络的参数,采用同样的物理约束,通过少量新数据微调与个性化相关的参数(全连接层的权重),进一步提升了模型的泛化能力<sup>[30]</sup>。

为了进一步提取时间序列数据的特征,Shi

等<sup>[31]</sup>开发的融合卷积网络与 LSTM 的生成对抗网络框架,通过在生成器设计中联合使用判别器评分和关节动力学误差构建复合损失函数,以实现物理信息的整合,以实测运动学数据和物理建模肌力作为判别器训练基准,从而预测运动学与肌力数据。实验表明该网络预测精度优于传统卷积神经网络。

然而,这些研究的数据集的肌力数据标签均依赖复杂的物理学建模,并且在物理方程中忽略了肌肉模型的个性化差异。Ma 等<sup>[32]</sup>提出了无肌力标签的物理信息神经网络。该模型在损失函数中同时引入运动学均方误差、关节动力学误差和基于 Hill 肌肉模型的激活方程等物理约束,通过多物理方程耦合实现了肌力与运动学数据的联合预测。该方法不仅降低了数据集构建复杂度,还能同步反演个体化肌肉模型参数,为个性化生物力学建模提供了新思路。

一些研究还表明,传统的 PINN 在训练过程中可能陷入局部最小值,倾向于捕捉解的低频分量而忽略高频分量,从而导致较大的训练误差。为解决这一问题,研究者提出采用多分辨率特征提取的方法,该方法已被证实能够有效提升 PINN 对高频分量的学习能力,避免陷入局部最小值,从而显著改善网络的学习性能。Taneja 等<sup>[33]</sup>提出了特征编码的物理先验参数识别神经网络 (feature-encoded physics-informed parameter identification neural network, FEPI-PINN),将 EMG 信号和关节运动数据投影到由傅里叶和多项式基组成的低维空间上,然后使用神经网络来映射输入信号和目标输出信号之间的关系并重建关节运动,将关节动力学误差作为损失函数的一部分,以实现物理信息的整合。结果表明,该模型在预测关节运动轨迹的精度显著优于传统的 PINN。该研究团队后来还提出了多分辨率物理循环神经网络 (multi-resolution physics-informed recurrent neural network, MR PI-RNN),利用快速小波变换将混合频率输入表面 EMG 信号和输出的关节运动信号分解为嵌套的多分辨率信号,使用门控递归单元在较粗尺度的输入-输出信号上训练预测模型,并采用同样的物理约束<sup>[34]</sup>。结果表明,与单尺度训练的情况相比,该框架在肌骨系统的肘部屈伸运动预测方面具有更高的准确性。

然而值得注意的是,表面 EMG 信号质量易受

运动伪影(如电极与皮肤间相对位移)、环境电磁噪声以及皮肤表面状态(汗液、毛发、油脂分布)等因素的干扰,且传感器贴附过程存在操作复杂性问题。随着 Kinect、OpenPose 等无标记运动捕捉技术的突破性进展,基于运动学数据构建输入特征的方法展现出良好的应用前景。为了提升基于视频的运动捕捉的准确性,Rempe 等<sup>[35]</sup>提出了生成网络 HuMoR,损失函数不仅包含关节位置的数据误差,还包括基于人体模型和关节角度重建的关节位置误差以及接触点误差,确保关节位置、网格顶点和人体模型之间的一致性,并能更好地预测人体接触。Ma 等<sup>[36]</sup>采用双向门控循环单元神经网络基于关节运动学数据对肌肉激活程度以及肌力进行预测,将关节动力学误差、肌肉激活水平生理学约束、预测肌力与肌肉 Hill 模型计算肌力之间的误差等物理方程合并作为损失函数,无须任何的标签信息,该模型取得了很好的精度和鲁棒性。

## 2.2 数据-物理深度耦合的肌骨系统多体动力学仿真

尽管上述 PINN 框架通过物理约束嵌入建模的生理可信度,PINN 需要同时优化物理约束(如微分方程)和数据误差,这种多目标优化问题可能导致训练不稳定,同时复杂的边界条件使得 PINN 需要较长时间才能收敛。为了克服这些挑战,研究者们开始探索其他结合物理信息的深度学习方法,这些方法通过不同途径将物理规律融入模型。例如,利用物理启发的网络架构、数据驱动与物理约束的混合方法、与传统数值方法相结合的混合模型,展现出更好的灵活性和适应性。

在人体关节角度与位姿预测方面,为了提升基于视频运动捕捉的准确性,Ye 等<sup>[37]</sup>结合了基于图像的运动学推理和基于物理的动力学建模,利用人体的动态控制(例如关节扭矩),通过当前帧姿态估计预测下一帧的姿势估计,显著提升了三维姿态的预测精度。

在关节力矩预测方面,Lutter 等<sup>[38]</sup>首先开发了深度拉格朗日网络 (deep-Lagrangian-network, DLN),将机械臂关节运动学数据作为输入,将拉格朗日方程中的质量分布矩阵、重力张量作为网络的中间变量,并将关节力矩误差作为损失函数,实现

物理方程与神经网络的结合。实验结果表明,该模型不仅在学习速度上优于传统的前馈神经网络,而且对新的轨迹表现出更好的泛化能力。

在预测肌肉功能方面,Taneja 等<sup>[39]</sup>采用贝叶斯模型,将正向动力学仿真与运动捕捉数据的均方误差作为似然函数,通过自适应马尔可夫链蒙特卡罗采样策略在 250 次迭代抽样后即可收敛至目标参数分布,成功建立了从宏观运动学观测到微观肌肉-肌腱本构参数的概率映射关系。

在预测关节应力分布方面,Sajjadinia 等<sup>[40]</sup>提出了一种基于混合机器学习(hybrid machine learning, HML)的多保真建模方法,用于模拟软组织的生物力学行为和有限元分析。通过简化复杂多物理方程生成低保真数据,再结合机器学习模型提升结果精度至高保真水平。实验证明,与传统机器学习相比,HML 方法在小样本条件下具有更快的收敛速度和更高的预测性能,为复杂软组织生物力学问题的高效模拟提供了一种非破坏性且易于实现的解决方案。

### 2.3 数据-物理耦合的肌骨系统多体动力学仿真的发展趋势

从现有的研究可以看出,数据-物理耦合驱动建模是目前肌骨多体动力学建模的重要发展方向之一,它有利于在仿真效率与仿真精度之间取得平衡。但目前数据-物理耦合驱动的肌骨建模仍存在一些局限性:① 大多数研究以 EMG 数据作为输入,EMG 测量的鲁棒性以及便捷程度不如运动学数据,因此,未来可以基于其他的运动学或动力学数据进一步拓展。② 所考虑的物理方程通常只有关节动力学以及肌肉的 Hill 本构方程,对于肌骨系统的微观层面/跨尺度的物理方程考虑较少,考虑更多的物理方程将提高模型的泛化能力和鲁棒性。③ 这些模型大多只针对单一关节和少数肌肉,对于全身关节运动和复杂的肌肉协同还有待进一步研究。鉴于物理方程的复杂性,对于多关节的建模研究可能会影响计算效率,这是一个潜在的挑战。④ 缺乏对模型架构的选择研究,一些模型基于全连接架构,该架构适用于通用的机器学习任务;一些模型基于卷积神经网络或者循环神经网络架构,用于序列数据中的特征提取,尽管模型结合了物理信息,模型本身仍然是一个黑盒,不同的任务可能需要不

同的模型,因此,对于模型的可解释性也至关重要。

## 3 总结

随着智能技术的深度发展,肌骨系统多体动力学仿真正从传统物理模型驱动向数据驱动、物理-数据耦合驱动演进。通过深度解析人体运动系统中多源异构生物力学参数(包括足底压力分布、GRF、运动学特征、动力学参数、EMG 信号及其对应肌力输出)之间的高维非线性关联机制,可以建立基于有限测量参数的多模态融合预测框架,突破传统生物力学分析对全参数测量的依赖性,实现了从局部特征到全局动力学响应、从宏观运动表象到微观肌肉激活的跨尺度综合预测。这种融合智能算法的混合建模体系不仅可以显著提升逆向动力学分析的运算效率,更通过构建可解释的预测模型降低了复杂生物力学系统的解析维度,为个性化运动功能评估、智能康复设备研发及精准医疗干预策略制定提供了新的方法论支撑,具有重要的临床转化价值与工程应用前景。

利益冲突声明:无。

作者贡献声明:陈文轩、任韦燕负责文献搜集、整理与综述撰写;姚杰、蒲放负责论文设计、审核和定稿。

### 参考文献:

- [1] ROUPA I, DA SILVA MR, MARQUES F, *et al.* On the modeling of biomechanical systems for human movement analysis: A narrative review [J]. Arch Comput Methods Eng, 2022, 29(7): 4915-4958.
- [2] TAYLOR WR, HELLER MO, BERGMANN G, *et al.* Tibio-femoral loading during human gait and stair climbing [J]. J Orthop Res, 2004, 22(3): 625-632.
- [3] CHOW CK, JACOBSON DH. Studies of human locomotion via optimal programming [J]. Math Biosci, 1971, 10(3-4): 239-306.
- [4] BRAND RA. A model of lower extremity muscular anatomy [J]. J Biomech Eng, 1982, 104(4): 304.
- [5] ZUO C, HE K, SHAO J, *et al.* Self Model for embodied intelligence: Modeling full-body human musculoskeletal system and locomotion control with hierarchical low-dimensional representation [C]//Proceedings of 2024 IEEE International Conference on Robotics and Automation (ICRA). Yokohama: IEEE, 2024.
- [6] PIZZOLATO C, LLOYD DG, SARTORI M, *et al.*

- CEINMS: A toolbox to investigate the influence of different neural control solutions on the prediction of muscle excitation and joint moments during dynamic motor tasks [J]. *J Biomech*, 2015, 48(14): 3929-3936.
- [7] AO D, VEGA MM, SHOURIJEH MS, *et al.* EMG-driven musculoskeletal model calibration with estimation of unmeasured muscle excitations via synergy extrapolation [J]. *Front Bioeng Biotechnol*, 2022(10): 962959.
- [8] DELP SL, ANDERSON FC, ARNOLD AS, *et al.* OpenSim: Open-source software to create and analyze dynamic simulations of movement [J]. *IEEE Trans Biomed Eng*, 2007, 54(11): 1940-1950.
- [9] LLOYD D. The future of in-field sports biomechanics: Wearables plus modelling compute real-time *in vivo* tissue loading to prevent and repair musculoskeletal injuries [J]. *Sports Biomech*, 2024, 23(10): 1284-1312.
- [10] CAO Z, HIDALGO G, SIMON T, *et al.* OpenPose: Realtime multi-person 2D pose estimation using part affinity fields [J]. *IEEE Trans Pattern Anal Mach Intell*, 2018, 43(1): 172-186.
- [11] NAKANO N, SAKURA T, UEDA K, *et al.* Evaluation of 3D markerless motion capture accuracy using OpenPose with multiple video cameras [J]. *Front Sports Act Living*, 2020(2): 50.
- [12] SHRIRAO NA, REDDY NP, KOSURI DR. Neural network committees for finger joint angle estimation from surface EMG signals [J]. *BioMed Eng Online*, 2009(8): 2.
- [13] PAN L, ZHANG D, LIU J, *et al.* Continuous estimation of finger joint angles under different static wrist motions from surface EMG signals [J]. *Biomed Signal Process Control*, 2014(14): 265-271.
- [14] SAVELBERG H, LANGE A. Assessment of the horizontal, fore-aft component of the ground reaction force from insole pressure patterns by using artificial neural networks [J]. *Clin Biomech*, 1999, 14(8): 585-592.
- [15] CHOI H, LEE C, SHIM M, *et al.* Design of an artificial neural network algorithm for a low-cost insole sensor to estimate the ground reaction force (GRF) and Calibrate the center of pressure (CoP) [J]. *Sensors*, 2018, 18(12): 4349.
- [16] GIRKA A, KULMALA JP, YRM S. Deep learning approach for prediction of impact peak appearance at ground reaction force signal of running activity [J]. *Comput Methods Biomech Biomed Eng*, 2020, 23(14): 1052-1059.
- [17] HOSSAIN MSB, GUO Z, CHOI H. Estimation of lower extremity joint moments and 3D ground reaction forces using IMU sensors in multiple walking conditions: A deep learning approach [J]. *IEEE J Biomed Health Inform*, 2023, 27(6): 2829-2840.
- [18] SUGAI R, MAEDA S, SHIBUYA R, *et al.* LSTM network-based estimation of ground reaction forces during walking in stroke patients using markerless motion capture system [J]. *IEEE Trans Med Robot Bionics*, 2023, 5(4): 1016-1024.
- [19] JACOBS DA, FERRIS DP. Estimation of ground reaction forces and ankle moment with multiple, low-cost sensors [J]. *J Neuroeng Rehabil*, 2015(12): 90.
- [20] WANG L, BUCHANAN TS. Prediction of joint moments using a neural network model of muscle activations from EMG signals [J]. *IEEE Trans Neural Syst Rehabil Eng*, 2002, 10(1): 30-37.
- [21] DAO TT. From deep learning to transfer learning for the prediction of skeletal muscle forces [J]. *Med Biol Eng Comput*, 2019(57): 1049-1058.
- [22] BURTON WS, MYERS CA, RULLKOETTER PJ. Machine learning for rapid estimation of lower extremity muscle and joint loading during activities of daily living [J]. *J Biomech*, 2021(123): 110439.
- [23] LIU MM. Dynamic muscle force prediction from ENG signals using artificial neural networks [M]. Calgary: University of Calgary, 1997.
- [24] MOKRI C, BAMDAD M, ABOLGHASEMI V. Muscle force estimation from lower limb EMG signals using novel optimized machine learning techniques [J]. *Med Biol Eng Comput*, 2022, 60(3): 683-699.
- [25] SONG S, KIDZIŃSKI Ł, PENG XB, *et al.* Deep reinforcement learning for modeling human locomotion control in neuromechanical simulation [J]. *J Neuroeng Rehabil*, 2021, 18(1): 126.
- [26] LUO S, JIANG M, ZHANG S, *et al.* Experiment-free exoskeleton assistance via learning in simulation [J]. *Nature*, 2024, 630(8016): 353-359.
- [27] KARNIADAKIS GE, KEVREKIDIS IG, LU L, *et al.* Physics-informed machine learning [J]. *Nat Rev Phys*, 2021, 3(6): 422-440.
- [28] HERRMANN L, KOLLMANNBERGER S. Deep learning in computational mechanics: A review [J]. *Comput Mech*, 2024, 74(2): 281-331.
- [29] ZHANG J, ZHAO Y, SHONE F, *et al.* Physics-informed deep learning for musculoskeletal modeling: Predicting muscle forces and joint kinematics from surface EMG [J]. *IEEE Trans Neural Syst Rehabil Eng*, 2022(31): 484-493.
- [30] ZHANG J, ZHAO Y, BAO T, *et al.* Boosting personalized musculoskeletal modeling with physics-informed knowledge transfer [J]. *IEEE Trans Instrum Meas*, 2022(72): 1-11.
- [31] SHI Y, MA S, ZHAO Y, *et al.* A physics-informed low-shot adversarial learning for sEMG-based estimation of muscle force and joint kinematics [J]. *IEEE J Biomed*

- Health Inform, 2023, 28(3): 1309-1320.
- [32] MA S, ZHANG J, SHI C, *et al.* Physics-informed deep learning for muscle force prediction with unlabeled sEMG signals [J]. IEEE Trans Neural Syst Rehabil Eng, 2024 (32): 1246-1256.
- [33] TANEJA K, HE X, HE QZ, *et al.* A feature-encoded physics-informed parameter identification neural network for musculoskeletal systems [J]. J Biomech Eng, 2022, 144(12): 121006.
- [34] TANEJA K, HE X, HE QZ, *et al.* A multi-resolution physics-informed recurrent neural network: Formulation and application to musculoskeletal systems [J]. Comput Mech, 2024, 73(5): 1125-1145.
- [35] REMPE D, BIRDAL T, HERTZMANN A, *et al.* Humor: 3D human motion model for robust pose estimation [C]// Proceedings of the IEEE/CVF international conference on computer vision. Montreal; IEEE, 2021: 11488-11499.
- [36] MA S, CAO Y, ROBERTSON ID, *et al.* Knowledge-based deep learning for time-efficient inverse dynamics [J]. IEEE Trans Neural Syst Rehabil Eng, 2025(33): 522-531.
- [37] YUAN Y, WEI SE, SIMON T, *et al.* Simpoee: Simulated character control for 3D human pose estimation [C]// Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Montreal; IEEE, 2021: 7159-7169.
- [38] LUTTER M, RITTER C, PETERS J. Deep Lagrangian networks: Using physics as model prior for deep learning [J/OL]. arxiv preprint arxiv:1907.04490, 2019, <https://doi.org/10.48550/arXiv.1907.04490>.
- [39] TANEJA K. A Multi-scale multi-resolution bayesian digital twin for human musculoskeletal system applications [D]. San Diego: University of California, 2023.
- [40] SAJJADINIA SS, CARPENTIERI B, SHRIRAM D, *et al.* Multi-fidelity surrogate modeling through hybrid machine learning for biomechanical and finite element analysis of soft tissues [J]. Comput Biol Med, 2022(148): 105699.