

惯性测量单元结合机器学习预测纵跳时下肢关节力矩

李 博,毛励芝,柯 余,高婧瑜,阮棉芳

(温州大学 体育与健康学院,浙江 温州 325000)

摘 要: **目的** 旨在利用惯性测量单元结合机器学习预测纵跳时的下肢关节力矩。**方法** 光学红外动作捕捉系统、三维测力台与惯性传感器同步完成数据采集。随后,在 Visual 3D 软件中进行建模,并运用逆向动力学算法计算下肢三关节力矩。ML 模型在 Matlab 中建立,以 IMU 获取的四元素、加速度和角度等信息为特征向量,下肢关节力矩数据为输出目标值进行训练与预测。**结果** 下蹲跳下肢矢状面关节力矩预测结果为:髋关节 $CCF=0.960\ 4$, $RMSE=0.270\ 6$, $R^2=0.920\ 4$;膝关节 $CCF=0.992\ 5$, $RMSE=0.181\ 7$, $R^2=0.979\ 4$;踝关节: $CCF=0.965\ 3$, $RMSE=0.151\ 0$, $R^2=0.910\ 9$ 。蹲跳下肢矢状面关节力矩预测结果为:髋关节 $CCF=0.921\ 7$, $RMSE=0.310\ 9$, $R^2=0.825\ 1$;膝关节 $CCF=0.984\ 6$, $RMSE=0.232\ 4$, $R^2=0.966\ 0$;踝关节 $CCF=0.919\ 3$, $RMSE=0.211\ 2$, $R^2=0.825\ 7$ 。**结论** 单枚惯性测量单元结合机器学习的方法能够准确地预测下蹲跳和蹲跳下肢矢状面关节力矩,为监测运动训练、优化技术动作及预防运动损伤提供新方法与新思路。

关键词: 惯性测量单元;机器学习;纵跳;动力学;关节力矩

中图分类号: G804.63 文献标识码: A 文章编号: 1003-983X(2025)02-0054-06

DOI: 10.20185/j.cnki.1003-983X.2025.02.010

Inertial Measurement Unit Combined with Machine Learning to Predict Lower Limb Joint Moments During Vertical Jumping

LI Bo, MAO Lizhi, KE Yu, GAO Jingyu, RUAN Mianfang

(Wenzhou University, School of Physical Education & Health, Wenzhou Zhejiang, 32500)

Abstract: **Objective** This study aims to utilize an inertial measurement unit (IMU) in conjunction with machine learning (ML) to predict lower limb joint moments during vertical jumps. **Methods** Data collection was performed synchronously using an optical infrared motion capture system, a three-dimensional force plate, and an inertial sensor. Subsequently, the data were modeled in Visual3D software, and the joint moments of the lower limb were calculated employing inverse dynamics algorithms. A machine learning model was established in MATLAB, using the four elements, acceleration, and angular information obtained from the IMU as feature vectors, while the lower limb joint moment data served as target output values for training and prediction. **Results** The prediction results for the counter-movement jump lower limb sagittal plane joint moments were as follows: hip joint ($CCF=0.960\ 4$, $RMSE=0.270\ 6$, $R^2=0.920\ 4$), knee joint ($CCF=0.992\ 5$, $RMSE=0.181\ 7$, $R^2=0.979\ 4$), ankle joint ($CCF=0.965\ 3$, $RMSE=0.151\ 0$, $R^2=0.910\ 9$). For the squat jump lower limb sagittal plane joint moment predictions, the results were: hip joint ($CCF=0.921\ 7$, $RMSE=0.310\ 9$, $R^2=0.825\ 1$), knee joint ($CCF=0.984\ 6$, $RMSE=0.232\ 4$, $R^2=0.966\ 0$), ankle joint ($CCF=0.919\ 3$, $RMSE=0.211\ 2$, $R^2=0.825\ 7$). **Conclusion** The method of combining a single IMU with machine learning can accurately predict the sagittal plane joint moments of both counter-movement jumps and squat jumps. This approach provides new methods and ideas for monitoring sports training, optimizing technical movements, and preventing sports injuries.

Keywords: interial measurement unit; machine learning; vertical jump; kinetic; joint moment

运动员的纵跳能力于体育运动中的地位不言而喻,在运

动科学的研究中,纵跳时的地面反作用力(Ground Reaction Force,GRF)往往被用来评估运动员的下肢爆发力,其水平的高低对某些项目的运动成绩有着举足轻重的影响,如篮球抢篮板、排球拦网、三级跳远等。在各式各样的体育项目中,纵跳存在着多种多样的形式,不同的纵跳形式,下肢肌肉参与程度与参与肌肉工作类型也不尽相同。1995年,Bosco等学者^[1]对蹲跳(Squat Jump,SJ)、下蹲跳(Counter-Movement Jump,CMJ)

收稿日期:2024-10-15

基金项目:温州大学研究生科研创新基金资助(3162024003024)。

第一作者简介:李 博(1997~),男,陕西西安人,在读硕士,研究方向:运动生物力学,E-mail:1845801737@qq.com。

和连续蹲跳(Continues Jump,CJ)这3种纵跳形式的地面反作用力进行了直接测量,进而提出了一种量化评估运动员下肢肌力和爆发力的检测方法。然而,地面反作用力只能综合反映运动员下肢肌肉力量和爆发力,而无法揭示下肢各关节的肌肉力矩和控制情况。

从运动生物力学的角度来看,人体肢体的运动主要受关节肌肉力矩(Joint Moment, JM)的控制^[1],这一参数能够提供人体运动时神经肌肉控制的相关信息^[2]。在人体运动过程中,肌肉通过收缩产生力量,这些力量作用于关节,从而产生了关节力矩。关节力矩可以决定关节的运动方向和速度,其大小取决于肌肉的力量、长度和角速度等因素。虽然,利用运动生物力学方法获取的关节肌肉力矩是主动肌与拮抗肌在某一关节共同作用的合力矩,但它在一定程度上反映了人体关节和肌肉所承受的负荷^[3]。因此,在运动科学研究中,分析关节肌肉力矩有助于理解关节的稳定性、运动控制和力量传递,是一个极具价值且广泛应用的生物力学参数,可为预防运动损伤和提高运动成绩提供重要帮助。

在过去几十年中,运动生物力学研究主要依赖于实验环境下的数据采集。通过红外高清摄像头记录受试者身上反光标志点的运动轨迹,从而精准还原其动作姿态。其效果卓越,数据采集精度通常能控制在2 mm左右^[4],被视为动作捕捉领域的黄金标准^[5]。尽管其测量精度高,但在应用过程中仍面临一些挑战。首先,光学动作捕捉系统的设备昂贵,需要特定的空间环境以及专业的操作人员。此外,数据处理也需要花费大量时间。更重要的是,光学动作捕捉系统对光线、遮挡物和反光物等外部条件较为敏感,使其只能在室内实验室环境下使用,限制了其应用的广泛性。对于活动范围广泛、环境复杂多变的户外运动,光学动作捕捉系统在便捷性和实时性方面显得捉襟见肘。

随着智能科技的飞速发展,大数据、人工智能等新一代信息技术为人体运动分析打开了新的大门^[6]。刘宇等人^[7]曾将测力台上直接测量CMJ与SJ的GRF数据作为输入,逆向动力学算法推算出下肢关节力矩作为输出,成功构建了“5-10-3”结构的人工神经网络模型。该模型所估计的下肢各关节力矩极值相对误差均小于6%,与实测值的相关系数高达0.95以上,显示了其高度的准确性和可靠性。然而,三维测力台仍属于价格昂贵、操作繁琐且高度依赖实验环境的范畴,限制了其网络模型广泛应用的可能性。鉴于光学红外标记点动作捕捉系统的诸多限制,研究者们开始更多地关注使用可穿戴惯性测量单元进行运动分析。惯性测量单元(Inertial Measurement Unit, IMU)是一种经济、便捷的传感单元,由加速度计、陀螺仪和磁力计组成,能够获取单个肢体节段的惯性运动和三维方向数据^[8-9]。相比传统的光学动作捕捉系统,IMU更加经济实惠、便于携带,且易于操作。IMU可以在体育场或复杂环境中灵活地追踪人体的运动姿势,获取所需的运动学数据^[10]。Setuain等人^[11]将IMU放置于腰部位置,用IMU获取人体的运动学参数对人体的纵跳GRF进行估计,并将其与测力板数据进行对比。他们的研究结果显示,IMU所采集的力曲线模式与测力板提供的力曲线模式具有较高的一致性,表明IMU可直接用于纵跳的生物力学评估。

机器学习(Machine Learning, ML)是通过构建数学模型来揭示数据的内在规律,进而实现预测和决策。随机森林算法

(Random Forest, RF)是Bagging集成方法中极具代表性的一种,它将Bagging集成学习理论^[12]与随机子空间方法^[13]巧妙结合,形成一种独特的机器学习算法。Jiang等人^[14]利用机器学习算法结合IMU估算行走时踝关节功率,两枚IMU被放置在受试者的小腿和脚面并于测力跑台上连续行走以收集数据,经数据处理后的IMU数据作为随机森林模型的输入,运动捕捉系统和测力台作为模型的参考值以评价模型的性能。研究结果表明,该方法的精度较高,相关系数为0.98,预测峰值功率值与真实峰值功率值的差值分别为0.01 w/kg和0.14 w/kg,为日常活动中实时监测踝关节功率提供了有力支撑。Mundt等人^[15]在对步态运动学与动力学进行研究时,使用光学红外动作系统和三维测力台作为运动数据捕获设备,由五个传感器构成的定制IMU系统与金标准系统同步采集,随后将IMU采集数据导入全连接前馈神经网络中进行预测分析。结果表明关节角的平均相关系数为0.85,关节力矩为0.95,为此方法在步态分析中提供了有力支持。

因IMU可高效、便捷、准确地获取人体运动数据的特点,目前已受到越来越多学者的关注。通过IMU数据结合计算机ML技术,便可实现对个体运动进行智能分析和预测,从而为运动技能优化和运动损伤防治提供实用的解决方案。由此,本研究提出基于IMU与ML结合以获取纵跳时下肢关节力矩的新思路。受试者佩戴2枚IMU分别置于骨盆(腰5骶1之间)和小腿(胫骨前肌中部),IMU数据经卡尔曼滤波处理后,将作为ML的输入特征向量。随机森林模型在Matlab数学建模软件中建立,输出目标值为髋、膝和踝3关节的矢状面力矩,以常规实验方法即光学动作捕捉系统结合三维测力台所获取的数据作为参考值,对模型预测结果进行检验并评估模型性能,并进一步分析不同IMU放置位置对预测结果准确性的影响。希望通过本研究,为非实验环境下获取人体运动数据提供依据,为运动训练计划的科学制定和实时监控提供思路与方法。

1 研究方法

1.1 研究对象

本研究招募16名男性体育学院大学生,年龄为 23.4 ± 2.01 岁,身高为 176.3 ± 3.43 cm,体重为 76 ± 4.47 kg。受试者纳入标准:1)年龄20~30岁;2)身体健康,无心血管系统疾病,身体机能状态良好,且近半年内无下肢运动损伤;3)具有长期的运动训练经历。测试前,详细告知受试者研究目的、测试流程以及相关的注意事项,并由受试者自愿签署知情同意书参加实验测试。

1.2 数据采集

受试者来到实验室后,先告知其实验流程,再测量记录年龄、身高、体重等基本参数,随后上跑步机自选速度热身5 min。热身结束后,由操作人员指导受试者进行蹲跳和下蹲跳练习,使其快速熟悉动作模式。

实验开始前,为方便黏贴反光标记点,受试者需上身赤裸,下身穿着紧身裤。全身上下共黏贴43枚反光标记点与佩戴2枚IMU(WT9011DCL, 200 Hz),三维测力台放置于场地中央(Kistler, 1 200 Hz),由周围15镜头的NOKOV光学三维动作捕捉系统(Mars 4H, 240 Hz)完成数据采集工作。

在实验开始时,每位受试者被要求站在测力台的中央。操

作人员在喊出“开始”的口令,设备开始同步记录,受试者调整自身状态后随时开始,自然完成纵跳动作,过程中尽全力跳到最高。数据采集将在受试者落地后的 2 s 后停止,并将结果保存在电脑中。每位受试者需完成 SJ 和 CMJ 各 3 次,每次纵跳之间有 20 s 的休息间隔。

实验过程中,若受试者出现身体不适、反光标记点或 IMU 掉落等情况,测试将立即停止。同时,为确保数据的有效性,受试者的起跳和落地必须确保踩在测力台上,任何一次落地超出测力台范围均视为无效。

1.3 数据处理

在本研究中,将光学红外动作捕捉系统与三维测力台采集的数据导入 Visual 3D 软件进行建模。通过对人体各关节的标定,建立一个精确的下肢三维模型。利用逆向动力学算法,计算下肢关节(髌、膝、踝)的力矩,关节力矩值经体重标准化后导出备用。

IMU 采集的数据包括四元数、三轴加速度以及三轴倾斜角度。这些数据在导出时经过 WT9011DCL IMU 硬件内置的卡尔曼滤波算法处理,有效抑制了传感器数据中的高频噪声,从而使输出数据更加平滑和稳定。同时,为确保数据的一致性,在 Matlab 2022a 软件中利用降采样法将光学动捕系统获取的动力学数据 240 Hz 降至 200 Hz,以匹配 IMU 数据的采样频率。同时,为确保捕捉到完整的纵跳动作细节,从起跳开始至落地前后各延长 1 s,由此每份数据的时间长度约为 3~4 s。

最终,IMU 获取的四元数、加速度、倾斜角度、受试者身高、体重作为模型的输入参数,经逆向动力学算法获取的矢状面下肢关节力矩作为输出目标。生成了 12 列输入特征向量和 3 列输出目标值的数据文件,CMJ 数据文件每份约 800 时间步,SJ 数据文件每份约 700 时间步,将其导入 ML 模型进行学习与预测。训练集、验证集、测试集按照 6:2:2 进行划分,并应用移动平均滤波算法,以 10 为窗口滑动尺寸,对预测数据集进行平滑处理,进一步有效减少噪声对结果的影响。

1.4 构建随机森林模型

随机森林机器学习模型在 Matlab 2022a 中建立。随机森林算法设计的原则是“随机化”,即在数据子集和决策变量子集上引入随机性。数据子集的随机性是通过自助法(bootstrap)有放回抽样从原始数据集中选择样本来实现的。由于这种抽样方式,样本可以重复出现,因此每个样本都有可能多次被选中,进而被包含在不同的子集中。

Bootstrap 采样:设原始数据集为 D , 包含 N 个样本,则 Bootstrap 采样得到的样本子集 D_i 为

$$D_i = \{(x_{i1}, y_{i1}), (x_{i2}, y_{i2}), \dots, (x_{in}, y_{in})\} \quad (1)$$

决策变量子集的随机性是通过随机选择部分特征来实现的,这种方法通常被称为随机子空间方法。随机森林的训练过程包括构建多棵决策树,直到达到预设的最大树深度或满足停止标准为止。这些停止标准包括叶子节点数量、节点的最小样本数、分裂阈值和误差率等。

为了实现决策树的充分随机化,随机森林算法引入了一种样本和特征选择的方法,其具体步骤如下:

- 1) 随机选择包含 n 个样本的样本子集;
- 2) 随机选择包含 k 个特征的特征子集,其中 k 远小于 m (m 为原始数据中的特征总数);

3) 使用选定的样本和特征构建一棵决策树,在每个节点处选择一个最佳特征进行分裂,以最大化信息增益。该过程持续进行,直到每个叶子节点仅包含一个样本或达到停止标准。

随机特征选择:从原始数据集的 m 个特征中随机选择 k 个特征,形成特征子集 F_i ,其中, $k \ll m$;

$$F_i = \{F_{i1}, F_{i2}, \dots, F_{ik}\} \quad (2)$$

决策树是一种简单且易于解释的算法,其基于 If-Then-Else 规则进行有监督学习,符合人类的直观思维方式(见图 1)。




图 1 决策树示意图

随机森林则通过集成多棵相互独立的决策树,构建一个强大的预测模型,如图 2 和 3。在处理回归任务时,随机森林中的每棵决策树会对输入样本分别进行预测,并生成各自的回归值。最终,随机森林将所有决策树的预测结果进行平均,得到综合的预测值。通过这种方式,随机森林不仅减少了单棵决策树可能产生的过拟合问题,还显著提升了模型的泛化性能。

回归任务平均公式如下:

$$\hat{y} = \frac{1}{B} \sum_{i=1}^B h_i(x) \quad (3)$$




图 2 随机森林流程图




图 3 随机森林示意图

在本研究中,随机森林模型的超参数设置在提高预测性能方面发挥了关键作用。模型中设定了 200 棵决策树,这一数量是基于试验与验证得出的最佳平衡点,旨在有效捕捉数据中的复杂特征,同时避免过拟合现象。与决策树的数量相关的另一超参数是最小子数,将其设定为 5。这意味着每棵树的叶子节点至少需包含 5 个样本,从而增强模型的泛化能力,避免在训练集上的过度拟合。

在模型训练阶段,启用了袋外预测(Out-Of-Bag Prediction)功能,旨在利用未被采样的数据评估模型的效果。这一做法不仅优化了模型的评估过程,还为后续分析提供了额外的信息。对于模型建立的回归方法,选择了线性回归法,以适应本研究中连续输出变量的特性。这些超参数的设置保证了模型在准确性和稳定性之间的较好平衡,为随后数据的预测与分析打下了坚实的基础。

1.5 模型性能评估指标

本研究采用交叉相关函数、均方根误差和决定系数作为 ML 的性能评估指标。

交叉相关函数(Cross-Correlation Function, CCF)是一种用于评估 2 条时间序列或信号之间相似性的统计方法,它通过计算 2 组数据在不同时间滞后后的相关性来确定它们的相似程度。当 $CCF < 0.25$ 时表示曲线间无相似度, $0.25 \leq CCF \leq 0.50$ 时表示低相似度, $0.50 < CCF \leq 0.75$ 时表示中相似度, $CCF > 0.75$ 时表示高相似度。因此,本研究选取 CCF 作为评估预测数据曲线与真实值曲线之间的相似性指标^[16-17],其公式如下:

$$R_{\psi}(\tau) = \frac{\sum_t [x(t) - \bar{x}] [y(t+\tau) - \bar{y}]}{\sqrt{\sum_t [x(t) - \bar{x}]^2 \sum_t [y(t+\tau) - \bar{y}]^2}} \quad (4)$$

均方根误差(Root Mean Square Error, RMSE)是一种常用的评估预测模型性能的统计指标。它衡量的是模型预测值与实际观测值之间的差异,提供了一种对误差的定量评估。RMSE 值越小,表示模型的预测效果越好。其公式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

决定系数(Coefficient of Determination)通常用 R^2 来表示,是用来衡量回归模型拟合数据的程度。它表示模型所解释的因变量方差的比例,即模型能够解释数据变异性的程度。在实际应用中, R^2 常用于评估回归模型的拟合优度,通过比较不同模型的 R^2 值,可以帮助确定哪个模型更适合解释数据。当 $R^2 = 1$ 时,表示模型可以完美解释因变量的变异,即所有观测值与模型预测值完全一致。当 $R^2 = 0$ 时,表示模型无法解释因变量的任何变异,即模型的预测值等于因变量的平均值。当 $0 < R^2 < 1$ 时,表示模型能够解释部分因变量的变异,数值越接近 1,模型解释力越强。

其公式如下:

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (6)$$

2 结果与讨论

2.1 CMJ 下肢三关节力矩预测结果




图 4 CMJ 髋关节矢状面力矩预测结果




图 5 CMJ 膝关节矢状面力矩预测结果




图 6 CMJ 踝关节矢状面力矩预测结果

表 1 CMJ 下肢矢状面关节力矩预测结果与真实值指标评估对比

关节类别	指标	随机森林模型	
		小腿IMU	骨盆IMU
髋关节	CCF	0.958 5	0.960 4
	RMSE	0.275 3	0.270 6
	R^2	0.917 6	0.920 4
膝关节	CCF	0.992 5	0.991 0
	RMSE	0.181 7	0.235 4
	R^2	0.979 4	0.965 4
踝关节	CCF	0.965 3	0.925 1
	RMSE	0.151 0	0.269 0
	R^2	0.910 9	0.717 2

上述数据展示了随机森林模型对 CMJ 髋、膝和踝关节矢状面力矩的预测结果,并对比了小腿 IMU 和骨盆 IMU 在各个关节的预测效果。

从 CMJ 髋关节力矩的结果对比来看,骨盆 IMU 的 CCF (0.960 4)和 R^2 (0.920 4)稍高于小腿 IMU 的 CCF (0.958 5)和 R^2 (0.917 6)。RMSE 方面,骨盆 IMU 的 0.270 6 略低于小腿 IMU 的 0.275 1。表明骨盆 IMU 对纵跳时髋关节力矩的预测更为精准。

而在 CMJ 膝关节力矩的结果对比中,两者的 CCF 值和 R^2 均处于很高的水平。小腿 IMU 的 $CCF(0.992\ 5)$, $R^2(0.979\ 7)$ 和骨盆 IMU 的 $CCF(0.991\ 0)$, $R^2(0.965\ 4)$,但在 $RMSE$ 方面,小腿 IMU 的 $0.181\ 7$ 要显著低于骨盆 IMU 的 $0.235\ 4$ 。表明小腿 IMU 对纵跳时膝关节力矩的预测表现更佳。

最后,是 CMJ 踝关节力矩的预测结果对比,不同 IMU 放置位置对精确度的影响有了显著的差异。小腿 IMU 的 $CCF(0.965\ 3)$ 、 $RMSE(0.151\ 0)$ 和 $R^2(0.910\ 9)$ 显著优于骨盆 IMU 的 $CCF(0.925\ 1)$ 、 $RMSE(0.269\ 0)$ 和 $R^2(0.717\ 2)$ 。表明小腿 IMU 对纵跳时踝关节力矩的预测更为精准。

2.2 SJ 下肢三关节力矩预测结果




图 7 SJ 髋关节矢状面力矩预测结果




图 8 SJ 膝关节矢状面力矩预测结果




图 9 SJ 踝关节矢状面力矩预测结果

表 2 SJ 下肢矢状面关节力矩预测结果与真实值指标评估对比

关节类别	指标	随机森林模型	
		小腿IMU	骨盆IMU
髋关节	CCF	0.916 2	0.921 7
	$RMSE$	0.316 5	0.310 9
	R^2	0.820 0	0.825 1
膝关节	CCF	0.980 8	0.984 6
	$RMSE$	0.255 7	0.232 4
	R^2	0.958 8	0.966 0
踝关节	CCF	0.904 1	0.919 3
	$RMSE$	0.233 4	0.211 2
	R^2	0.787 1	0.825 7

表 2 展示了 SJ 下肢三关节矢状面力矩预测结果与真实值的对比分析。首先,在 SJ 髋关节力矩的结果中,骨盆 IMU 的 $CCF(0.921\ 7)$ 和 $R^2(0.825\ 1)$,这些值略优于小腿 IMU 的 $CCF(0.916\ 2)$ 和 $R^2(0.820\ 0)$ 。在 $RMSE$ 方面,骨盆 IMU 的值为 $0.310\ 9$,微低于小腿 IMU 的 $0.316\ 5$ 。其次,在 SJ 膝关节力矩的结果对比中,骨盆 IMU 同样表现优异, CCF 为 $0.984\ 6$, $RMSE$ 为 $0.232\ 4$, R^2 为 $0.966\ 0$,相较之下,小腿 IMU 的 CCF 为 $0.980\ 8$, $RMSE$ 为 $0.255\ 7$, R^2 为 $0.958\ 8$ 。虽然两者之间的差距并不显著,但综合分析表明,骨盆 IMU 仍略占优势。最后,是 SJ 踝关节力矩的结果对比,同样显示出与髋、膝关节相似的趋势,骨盆 IMU 的 3 项评估指标均优于小腿 IMU。这表明在 SJ 下肢三关节力矩的预测中,骨盆 IMU 具有更高的适用性。

2.3 讨论

由上述预测结果可以看出,随机森林模型对 CMJ 和 SJ 下肢三关节力矩的预测非常理想。关节力矩—时间曲线形态的分析使研究人员能够判断纵跳各个阶段下肢各关节伸肌群与屈肌群的作用。从图 4 至图 9 所示的曲线可以看出,随机森林模型预测的关节力矩曲线与实测数据之间具有较高的一致性,二者在曲线形态和极值的出现时机均相对接近。同时,预测曲线的平滑性优于实测曲线,这表明该机器学习模型在曲线拟合方面具备较强的能力,进一步验证了人工神经网络在滤波和处理噪声方面的优越性^[18]。此外,表 1 和表 2 中提供的交叉相关函数(CCF)进一步支撑了这一结论,相关分析显示,各关节力矩的实测值与预测值之间的相关系数均高于 0.90 ,表明二者之间存在显著的高度相关性。

以往的研究已经证明,IMU 结合 ML 的方法在行走、跑步和上下楼梯等运动分析中取得了显著成效^[19-21],但对于活动幅度更大、复杂度更高的跳跃动作,相关研究仍有所欠缺。由此,这项研究是首次将 IMU 与 ML 相结合用于 CMJ 和 SJ 的下肢关节力矩分析,并进一步研究了不同 IMU 放置位置对预测结果准确性的影响。

在预测结果分析中,CMJ 与 SJ 髋关节力矩的最佳预测表现与骨盆 IMU 数据高度相关。这可能归因于髋关节在跳跃动作中承受核心负荷,而骨盆 IMU 位于身体中心,能够捕捉到整体运动的核心动态,从而提升力矩预测的准确性。膝关节力矩的最佳预测结果出现了分歧,CMJ 采用小腿 IMU 数据的效果最佳,可能是因为 CMJ 强调下肢肌肉的爆发力和垂直跳跃能力,而小腿 IMU 数据在捕捉到肢体动态变化方面更有优势。相反,SJ 采用骨盆 IMU 数据效果最佳,或许是因为 SJ 动作在准备时体位处于静蹲,之后全力垂直纵跳,而骨盆 IMU 提供了关于核心稳定性和整体身体运动的详细信息。踝关节力矩预测结果出现了与膝关节力矩同样的 IMU 位置分歧,CMJ 使用小腿 IMU 数据效果更佳,SJ 使用骨盆 IMU 数据效果更佳,背后的归因也可能同上所述。

就 2 种纵跳动作而言,CMJ 通常比 SJ 具有更大的动作变化和复杂性。CMJ 包括蹲下、起跳、腾空和落地,而 SJ 是从静蹲位起跳,缺少身体下蹲蓄力的过程。因此,两者在力矩预测中对 IMU 数据的依赖程度有所不同,也反映出不同聚焦点对准确性的影响。这些发现强调了选择合适的 IMU 数据来源以优化下肢关节力矩预测的重要性,为运动科学领域提供了有益的实证支持。

本研究的受试者均为体育学院的大学生,虽然具备良好的运动基础,但并非参与与纵跳高度直接相关的专业运动,例如篮球、排球和跳远。因此,若希望将此方法应用于高水平运动员的训练监测与损伤预防,仍需进一步深入研究和丰富数据。此外,值得注意的是,相较于传统的机器学习算法,深度学习模型可能具备更强的表达能力和泛化能力。这些模型基于机器学习的理论基础与算法支持,有望拓展性能的上限,进而实现更高级的学习与预测能力。因此,在未来的实践中,将惯性测量单元与深度学习相结合,可能为更复杂的运动技术分析提供新的视角和深度。

3 结论

通过本研究,结合单枚惯性测量单元与机器学习的方法,在下蹲跳和蹲跳中展现出卓越的关节力矩预测能力。此创新的研究方案为运动训练监测、技术动作优化以及运动损伤预防提供了新的视角与实践依据,进一步验证了在非实验环境中运用IMU与ML结合获取人体运动数据的潜力。

研究结果揭示了不同IMU放置位置对关节力矩预测准确性的显著影响。具体而言,骨盆IMU数据在髋关节力矩的预测中表现最佳,而在膝关节力矩和踝关节力矩的预测中,CMJ时小腿IMU数据更具有效性,而SJ时则以骨盆IMU数据为优,这或许与动作的特性、采集数据的特征密切相关。因此,在分析纵跳运动时,应根据不同动作特性的需求,选择合适的IMU的放置位置,以提升预测结果的准确性和运动分析的有效性。

综上所述,本研究强调了IMU与ML结合在运动科学研究中的重要潜力,丰富了运动技能优化与损伤防治的理论基础。未来的研究可以探讨不同运动方式、算法模型、受试者个体特征及多传感器组合对关节力矩预测的影响,从而推动这一领域的发展并拓宽其应用范围。

参考文献:

- [1] BOSCO C, BELLI A, ASTRUA M, et al. A dynamometer for evaluation of dynamic muscle work[J]. *European Journal of Applied Physiology and Occupational Physiology*, 1995, 70(5): 379-386.
- [2] ZERNICKE R F, SCHNEIDER K. Biomechanics and developmental neuromotor control[J]. *Child development*, 1993, 64(4): 982-1004.
- [3] BRÜGGEMANN G P. Chapter 26: Sport-Related Spinal Injuries and Their Prevention[M]//ZATSIORSKY V M. *Biomechanics in Sport: Performance Enhancement and Injury Prevention*. NY: Wiley, 2000: 550-576.
- [4] 刘程林,郝卫亚,霍波.运动生物力学发展现状及挑战[J].*力学进展*, 2023, 53(1): 198-238.
- [5] ENGELL M T, HERNLUND E, BYSTROM A, et al. Head, trunk and pelvic kinematics in the frontal plane in un-mounted horseback riders rocking a balance chair from side-to-side[J]. *Comparative Exercise Physiology*, 2018, 14(4): 249-259.
- [6] 李志远,段之洁.人工智能助推体育产业高质量发展的创新策略[J].*湖北体育科技*, 2023, 42(8): 744-747+752.
- [7] 刘宇,史世民,钟运健.神经网络模型预测纵跳时下肢关节内力矩[J].*体育科学*, 2008(7): 45-50+65.
- [8] MADGWICK S O H, HARRISON A J L, VAIDYANATHAN R. Estimation of IMU and MARG orientation using a gradient descent algorithm[C]//2011 IEEE international conference on rehabilitation robotics. IEEE, 2011: 1-7. DOI:10.1109/icorr.2011.5975346
- [9] BURNS A, GREENE B R, MCGRATH M J, et al. SHIMMER™-A wireless sensor platform for noninvasive biomedical research[J]. *IEEE Sensors Journal*, 2010, 10(9): 1527-1534.
- [10] MCGRATH D, GREENE B R, O'DONOVAN K J, et al. Gyroscope-based assessment of temporal gait parameters during treadmill walking and running[J]. *Sports Engineering*, 2012, 15: 207-213.
- [11] SETUAIN I, MARTINIKORENA J, GONZALEZIZAL M, et al. Vertical jumping biomechanical evaluation through the use of an inertial sensor-based technology[J]. *Journal of sports sciences*, 2016, 34(9): 843-851.
- [12] KWOK S W, CARTER C. Multiple decision trees[M]//*Machine intelligence and pattern recognition*. North-Holland, 1990, 9: 327-335.
- [13] HO T K. The random subspace method for constructing decision forests[J]. *IEEE transactions on pattern analysis and machine intelligence*, 1998, 20(8): 832-844.
- [14] JIANG X, GHOLAMI M, KHOSHNAME M, et al. Estimation of ankle joint power during walking using two inertial sensors[J]. *Sensors*, 2019, 19(12): 2796.
- [15] MUNDT M, KOEPPE A, DAVID S, et al. Estimation of gait mechanics based on simulated and measured IMU data using an artificial neural network[J]. *Frontiers in bioengineering and biotechnology*, 2020, 8: 41.
- [16] DERRICK T, THOMAS J. Time series analysis: the cross-correlation function[J]. 2004.
- [17] ZHANG Q, LI Z, YU L, et al. A Quantitative SNR Analysis for the Adjacent Cross Correlation Function[J]. *IEEE Signal Processing Letters*, 2023.
- [18] RICHARDSON R S, NOYSZEWSKI E A, KENDRICK K F, et al. Myoglobin O2 desaturation during exercise. Evidence of limited O2 transport[J]. *The Journal of clinical investigation*, 1995, 96(4): 1916-1926.
- [19] STETTER B J, KRAFFT F C, 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]. *Frontiers in bioengineering and biotechnology*, 2020, 8: 9.
- [20] ALTAI Z, BOUKHENNOUFA I, ZHAI X, et al. Performance of multiple neural networks in predicting lower limb joint moments using wearable sensors[J]. *Frontiers in Bioengineering and Biotechnology*, 2023, 11: 1215770. DOI:10.3389/fbioe.2023.1215770.
- [21] MUNDT M, JOHNSON W R, POTTHAST W, et al. A comparison of three neural network approaches for estimating joint angles and moments from inertial measurement units[J]. *Sensors*, 2021, 21(13): 4535.