

融合人工鱼群和随机森林算法的膝关节接触力预测

卢巍¹, 朱业安², 徐唯祎²

1. 江西省人民医院康复医学科, 江西 南昌 330006; 2. 华东交通大学交通运输与物流学院, 江西 南昌 330013

【摘要】针对膝关节接触力的测量问题提出融合人工鱼群和随机森林算法的膝关节接触力预测方法。首先,运用混沌变换构造均匀分布的种群,并引入自适应视野范围策略和自适应步长策略,获得改进的人工鱼群算法。然后,将干预前所有受试者的步态参数和膝关节接触力数据划分为训练集(70%)和验证集(30%),利用随机森林算法对训练集进行训练,并使用改进的人工鱼群算法优化随机森林模型的主要参数,获得步态参数和膝关节接触力的非线性关系,利用验证集进行验证。最后,以干预后单个受试者的步态参数和膝关节接触力对预测模型进行测试。结果表明模型在验证集和测试集上都有很高的准确性,模型在验证集上的误差表明模型能准确地学习输入和输出之间的因果关系;在测试集上的误差表明训练后的模型能够准确地将这种因果关系推广到新的输入中。

【关键词】人工鱼群算法;随机森林算法;膝关节置换;接触力预测

【中图分类号】R318.01;TP273

【文献标志码】A

【文章编号】1005-202X(2020)04-0502-07

Knee joint contact force prediction using artificial fish swarm and random forest algorithm

LU Wei¹, ZHU Ye'an², XU Weiyi²

1. Department of Rehabilitation Medicine, Jiangxi Provincial People's Hospital, Nanchang 330006, China; 2. School of Transportation and Logistics, East China Jiaotong University, Nanchang 330013, China

Abstract: A knee joint contact force prediction method combining artificial fish swarm and random forest algorithm is proposed to measure the contact force of the knee joint. Firstly, chaos transformation is used to construct an uniformly distributed population, and the adaptive vision range strategy and adaptive step strategy are introduced to obtain the improved artificial fish swarm algorithm. Then the gait parameters and knee contact force data of all subjects before intervention are divided into training set (70%) and validation set (30%). The training set is trained by random forest algorithm, and the main parameters of random forest model are optimized by improved artificial fish swarm algorithm. The obtained nonlinear relationship between gait parameters and knee joint contact force is validated by validation set. Finally, the gait parameters and knee contact force of each subject after intervention are used to test the prediction model. The results show that the model has high accuracy in both validation set and test set. The error of the model in validation set indicates that the model can accurately learn the causality between inputs and outputs; while the error of the model in test set indicates that the trained model can precisely generalize the causality to new inputs.

Keywords: artificial fish swarm algorithm; random forest algorithm; knee replacement; contact force prediction

前言

步态矫正策略对膝关节置换术的术后康复有着重要的影响,好的策略可以加快病情恢复、增强关节功能、降低步态不对称性、延长膝关节假体的使用寿命,因此通过调整患者的步态模式来减轻膝关节负

载是术后康复的主要目的之一^[1-3]。而研究膝关节接触力与步态模式的关系是设计康复方案的重要基础,所以准确测量膝关节接触力就成为了评估康复方案和康复效果的关键所在^[4-5]。

目前测量膝关节接触力的方法主要有两种,一种是使用装有传感器的膝关节假体对活体内的膝关节接触力进行实验测量^[6]。这种测量方法的信效度高,但实施具有侵入性且成本高。另一种是基于多体动力学方法进行计算,该方法利用运动捕捉系统捕获的患者运动轨迹作为输入,然后基于逆向动力学模型来预测患者在整个步态周期内的动力学参数^[7-9]。其预测结果高度依赖于控制方程的精度、问

【收稿日期】2019-11-10

【基金项目】国家自然科学基金(51765019);江西省科技厅重点研发计划(20192BBG70011)

【作者简介】卢巍,主任医师,主要研究方向:步态障碍的康复治疗,E-mail: 13006209911@163.com

题简化的假设、输入参数和模型的自由度。另外,这种方法的计算耗时长,不适用于实时分析,更重要的是这种方法并不能直接计算膝关节接触力的分布^[10-11]。鉴于以上方法的局限性,探寻新的方法来解决膝关节接触力的测量问题是有必要的。

此前,已有研究者提出将人工神经网络(ANN)引入到生物力学的数据挖掘中,对复杂的输入输出关系进行建模。这类方法通过对训练集进行学习,从而建立一个从输入空间 X 到输出空间 Y 的映射关系,当这个映射关系被应用到新的实例时,就可以根据该实例的属性特征来预测该实例的输出。Favre等^[12]提出一种利用前馈神经网络预测膝关节内收力矩的方法。Oh等^[13]提取14个身体节点的运动轨迹和加速度参数作为输入,利用前馈神经网络预测三维地面反作用力和关节力矩。Ardestani等^[14]将地面反作用力和肌电图信号等信息作为输入,建立小波神经网络以预测下肢关节力矩。De Vries等^[15]输入手臂运动学参数和肌电图信号,通过经训练的ANN得到肩关节接触力的输出,并证实其预测性能优于多体动力学分析法。Kipp等^[16]就举重运动进行研究,训练一个可利用杠铃质量和运动数据来预测下肢净关节力矩的神经网络模型,预测精度为0.79~0.95。这些研究主要集中在关节力矩的预测上,很少研究膝关节接触力的预测问题,对其它性能较好的机器学习算法考虑也较少。另外,ANN在样本数据量较少时容易过拟合,且泛化能力较弱^[17]。因此,本文提出融合人工鱼群和随机森林算法的膝关节接触力预测方法。随机森林算法具有不易过拟合、训练速度快、适合处理高维数据的优点,由于随机森林算法自身无法优化其参数,本文引入人工鱼群算法对随机森林模型参数进行优化。首先,运用混沌变换构造均匀分布的种群,并引入自适应视野范围策略和自适应步长策略^[18],获得改进的人工鱼群算法。然后,将干预前所有受试者的步态参数和膝关节接触力数据划分为训练集(70%)和验证集(30%),利用随机森林算法对训练集进行训练,并使用改进的人工鱼群算法优化随机森林模型的主要参数,获得步态参数和膝关节接触力的非线性关系,并利用验证集进行验证。最后,以干预后单个受试者的步态参数和膝关节接触力对预测模型进行测试,这样做可以进一步检验模型的通用性。

1 材料与方法

1.1 试验数据来源

试验数据采用Fregly等^[6]发布的公开数据集(网址:<https://simtk.org/home/kneeloads>)。数据集中包含3例接受单侧膝关节假体置换的受试者,其中,男2例,女1例;身高(168.2±2.6) cm,体质量(69.1±6.2) kg。3例受试者分别在3种不同的试验范式下进行测试,试验范式包含1种康复前的步态模式和2种干预步态模式。在同一试验范式下,受试者会以相同的步态模式和自主选择的步速进行5次行走试验。每次行走试验会包含多个完整的步态周期,本文只从中提取2个完整步态周期的试验数据。因此,本文数据集包含90个示例(3例受试者×3种试验范式×5次地面行走试验×2个完整步态周期)。

在每次步行试验中,受试者的肌电图(Electromyography, EMG)、地面反作用力(Ground Reaction Forces, GRFs)、运动轨迹(Marker Trajectories, MT)和膝关节负荷数据会被同时采集,并用垂直GRFs数据进行同步化处理。试验中使用表面肌电记录仪(Delsys Corp., Boston, MA)采集置换侧14处下肢肌肉的EMG信号;使用10个摄像头的运动捕捉系统(Motion Analysis Corp., Santa Rosa, CA)收集受试者的MT数据;利用3个力板(AMTI Corp., Watertown, MA)测量GRFs;利用植入体内的4个单轴负荷测压元件获得膝关节负荷,然后将膝关节负荷值代入经验证的回归方程计算得到内侧和外侧的膝关节接触力。

1.2 试验数据预处理

本文以受试者一侧下肢完成从足落地到再次落地的时间为一个步态周期提取试验数据,由于EMG和GRFs数据的采集频率高(1 000~1 200 Hz),膝关节接触力和MT的采集频率低(100~120 Hz),所以在训练模型前需要对数据做如下预处理:(1)将一个完整的步态周期上划分成100个区间,据此对膝关节接触力和MT信号进行100次重采样;(2)采用均方根(Root Mean Square, RMS)来处理高频的EMG信号,将EMG信号以50 ms为一个区间进行划分,根据式(1)计算EMG信号的均方根:

$$\text{RMS} = \sqrt{\frac{1}{20} \sum_{n=1}^{20} (\text{EMG}(n))^2} \quad (1)$$

然后利用截止频率为1 Hz的10阶Butterworth滤波器对RMS特征进行过滤,最后在一个完整的步态周期下对预处理后的EMG信号进行100次重采样;(3)根据低频率的MT数据对GRFs进行降采样,然后在一个完整的步态周期下,利用最近邻插值法对GRFs重新采样100次。同时按体质量对GRFs的振幅进行归一化处理。

1.3 改进的人工鱼群算法

人工鱼群算法是李晓磊等^[19]基于自然界中的鱼群及其觅食行为而提出来的群体智能优化算法,该算法在鲁棒性、全局搜索能力、收敛速度等方面性能突出,适合作为一种搜索策略。人工鱼群算法以人工鱼代表目标函数的输入参数,通过迭代搜索最优解,在每次迭代中,人工鱼通过觅食、聚群、追尾和随机行为来更新自身位置,从而实现寻优,其行为描述如下。

设 X_i 为人工鱼的当前状态,自适应函数为 $Y=f(X)$, $Visual$ 表示其视野范围, $Step$ 表示人工鱼在一次寻优行为中能达到的最大步长, δ 为鱼群的拥挤程度。

(1)觅食行为:当前状态的人工鱼 X_i 在 $Visual$ 范围内,随机选取任一状态 X_j ,如果 X_j 的适应值满足 $Y_j>Y_i$ (在求极大值中),则在 $Step$ 的约束下,向 X_j 方向移动;否则在最大尝试次数内重新+选择状态 X_j ,若超过最大尝试次数仍找不到符合条件的 X_j 则执行随机游动。

(2)聚群行为:当前状态的人工鱼 X_i 在 $Visual$ 范围内,搜索出该范围内伙伴的个数 n_p 并找出伙伴的中心位置 X_c ,计算该位置的适应值 Y_c ,如果 $Y_c>Y_i$ (在求极大值中)并且 $Y_c/n_p<\delta Y_i$,则在 $Step$ 的约束下,向 X_c 方向移动,否则执行觅食行为。

(3)追尾行为:当前状态的人工鱼 X_i 在 $Visual$ 范围内,找到状态最优的伙伴,设其为 X_{max} ,计算该位置的适应值 Y_{max} ,如果 $Y_{max}>Y_i$ (在求极大值中)并且 $Y_{max}/n_p<\delta Y_i$,则在 $Step$ 的约束下,向 X_{max} 方向移动,否则执行觅食行为。

(4)随机行为:当前状态的人工鱼 X_i 在 $Step$ 的限制下,随意向其他方向移动。

随着对算法研究的深入,学者们发现人工鱼群算法存在前期收敛速度快而后期收敛速度慢、求解精度不高等缺点。针对上述缺点,本文采用混沌变换来初始化鱼群个体位置,相对于随机初始化鱼群,使用混沌变换产生的种群分布更均匀稳定、人工鱼更具多样性,利于算法的全局收敛、能有效避免陷入局部最优。

另外有研究表明^[20],在寻优过程中,当视野范围较大时,聚集和追尾行为较为突出,越可能找到全局最优解,但会影响算法后期的收敛速度;当视野范围较小时,觅食行为和随机行为较为突出,容易陷入局部最优。因此本文满足柯西分布的Lorentzian函数作为自适应算子来优化人工鱼群的视域,使视域随迭代次数的增加而逐渐减小,视域自适应更新如式(2)所示。这样在迭代初期,较大的视域可以让人工

鱼在更大的范围内进行粗略搜索,在提高收敛速度的同时增加全局最优值的搜索能力;在迭代后期,较小的视野范围可以提高局部的搜索能力和最优解精度。

$$Visual_{i+1}=Visual_i \times [2 \times (\text{gen}/\text{gen_max})^2 + 1]^{-1} \quad (2)$$

其中, gen 为当前迭代次数, gen_max 为最大迭代次数, $Visual_i$ 为当前视域, $Visual_{i+1}$ 为下一步视域。同时本文还引入满足正态分布的函数 $g(x)=e^{-x^2}$ 作为自适应算子来改进移动步长,从而平衡迭代速度和精度。步长自适应更新如式(3)所示:

$$Step_{i+1}=Step_i \times e^{-\pi (\text{gen}/\text{gen_max})^2} \quad (3)$$

其中, gen 为当前迭代次数, gen_max 为最大迭代次数, $Step_i$ 为当前移动步长, $Step_{i+1}$ 为下一步移动步长。这样在算法的迭代初期,相对于线性算子,正太分布算子有利于加快迭代次数,在算法的迭代后期,相对于柯西算子,正太分布算子有利于提高算法的搜索精度。

1.4 随机回归森林算法

随机森林回归(Random Forest Regression, RFR)算法是一种流行的集成学习方法^[21]。集成学习把 k 个学习得到的模型(或基学习器) M_1, M_2, \dots, M_k 组合在一起,旨在创建一个改进的复合模型 M^* 。使用给定的数据集 D 创建 k 个训练集 D_1, D_2, \dots, D_k ,其中 D_i 用于创建基学习器 M_i 。给定一个待预测的数据元组,每个基学习器返回各自的预测结果,集成学习器基于基学习器预测结果的均值返回最终预测值。

随机森林回归中的每个学习器都是一颗决策回归树,随机森林可以使用袋装与随机属性选择的结合来构建,其结构如图1所示。给定 d 个元组的训练集 D ,为组合分类器产生 k 棵决策树的一般过程如下。对于每次迭代 $i(i=1, 2, \dots, k)$,使用有放回抽样,由 D 产生 d 个元组的训练集 D_i 。也就是说,每个 D_i 都是 D 的一个自助样本,使得某些元组可能在 D_i 出现多次,而另一些可能不出现,未被采样的训练样本则用来估计分类器的泛化能力。设 F 是用来在每个结点决定划分的属性数,其中 F 远小于可用属性。为了构造决策树分类器 M_i ,在每个结点随机选择 F 个属性作为该结点划分的候选属性。使用CART算法的方法来增长树,树增长到最大规模,并且不剪枝^[22],结构如图1所示,最小二乘回归树生成算法建模过程和机理如下:

输入:训练数据集 D ;输出:回归树 $f(x)$ 。在训练数据集所在的输入空间中,递归地将每个区域划分为两个子区域并决定每个子区域上的输出值,构建二叉决策树:




图1 随机森林算法结构示意图

Fig.1 Structural diagram of random forest algorithm

(1) 选择最优切分变量 j 与切分点 s , 求解:

$$E = \min_{j,s} \left[\min_{c_1} \sum_{x_i \in R_1(j,s)} (y_i - c_1)^2 + \min_{c_2} \sum_{x_i \in R_2(j,s)} (y_i - c_2)^2 \right] \quad (4)$$

遍历变量 j , 对固定的切分量 j 扫描切分点 s , 选择式(4)达到最小的值对 (j,s) 。

(2) 用选定的对 (j,s) 划分区域并决定相应的输出值:

$$R_1(j,s) = \{x | x^{(j)} \leq s\}, R_2(j,s) = \{x | x^{(j)} > s\} \quad (5)$$

$$\hat{c}_m = \frac{1}{N_m} \sum_{x_i \in R_m(j,s)} y_i, x \in R_m, m = 1, 2 \quad (6)$$

(3) 继续对两个子区域调用步骤(1)和步骤(2), 直至满足停止条件。

(4) 将输入空间划分为 M 个区域 R_1, R_2, \dots, R_M , 生成决策树:

$$f(x) = \sum_{m=1}^M \hat{c}_m I(x \in R_m) \quad (7)$$

随机森林简单、容易实现、计算开销小, 在很多现实任务中展现出强大的性能。随机森林中基学器的多样性不仅来自样本扰动, 还来自属性扰动, 这就使得最终集成的泛化性能可通过个体学习器之间差异度的增加而进一步提升。另外, 随着森林中树的个数增加, 随机森林通常会收敛到一个更低的泛化误差, 能有效降低过拟合的风险。

1.5 构建预测模型

随机森林算法已广泛应用于各种分类和回归问

题, 在应用过程中影响随机森林回归预测性能的主要参数有决策树的个数 n_{tree} 和树节点预选的分裂变量个数 m_{try} 。针对参数 n_{tree} 和 m_{try} 的合理取值问题, 目前多采用经验尝试法来解决, 但这难以确保随机森林性能最佳, 因此本文使用人工鱼群算法优化其参数。在基于混沌变换初始化的人工鱼群中, 每条人工鱼表示一个 $(n_{\text{tree}}, m_{\text{try}})$ 参数组合, 人工鱼根据位置更新策略进行寻优, 以在验证集样本上的分类准确率为目标函数, 搜索到的全局最优解即为随机森林模型的最优参数组合 $(n_{\text{tree}}, m_{\text{try}})$ 。流程如图2所示。

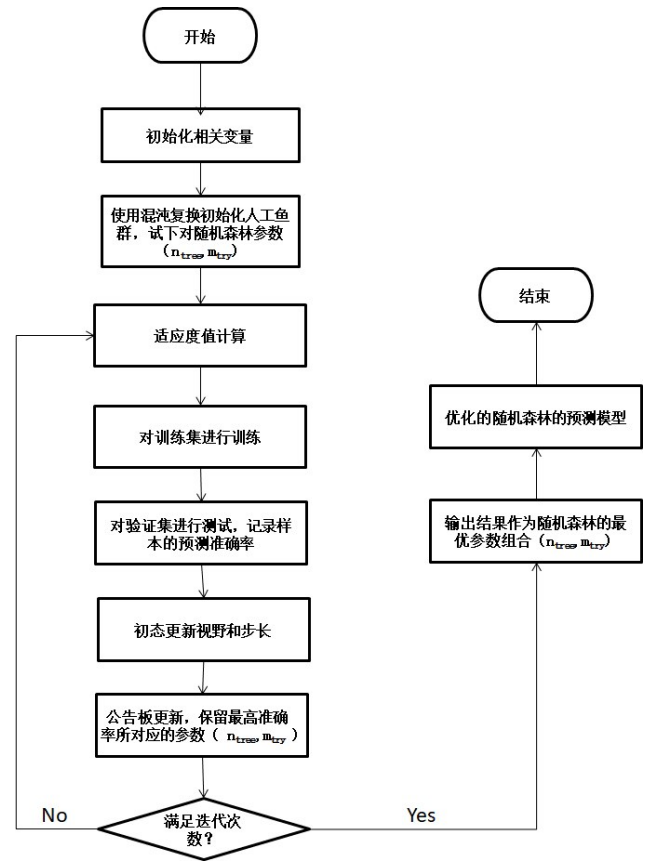


图2 优化流程图

Fig.2 Flowchart of optimization

2 结果

本文将采用均方根误差 (δ_{RMSE})、平均绝对误差 (δ_{MAE}) 和平方相关系数 (R^2) 评价预测模型的效果, 评价指标的计算公式如下:

$$\delta_{\text{RMSE}} = \frac{1}{n} \sqrt{\sum_{t=1}^n (y(t) - \hat{y}(t))^2} \quad (8)$$

$$\delta_{\text{MAE}} = \frac{1}{n} \sum_{t=1}^n |y(t) - \hat{y}(t)| \quad (9)$$

$$R^2 = \frac{\sum (\hat{y}(t) - \bar{y})^2}{\sum (y(t) - \bar{y})^2} \quad (10)$$

2.1 模型性能分析

为了说明寻优后的随机森林回归(Enhanced Random Forest Regression, ERFR)所具有的良好性能,将最优参数下的ERFR($n_{\text{tree}}=131, m_{\text{try}}=10$)的拟合结果同经验参数下的RFR($n_{\text{tree}}=200, m_{\text{try}}=5$)、ANN、SVM的拟合结果进行对比,结果如表1所示,需要说明的是,表中结果为模型在3例受试者的2个测试集上的平均效果。由于篇幅限制,本文从测试集中随机抽取一个完整步态周期的数据进行拟合效果展示,结果如图3所示。由表1可知,利用改进人工鱼群算法优化后的随机森林模型的 R^2 值均高于其他模型,说明BRFR预测的有效性,在算法的稳定性方面,BRFR的误差低于其他模型,说明BRFR预

测的稳定性。因此在总体上,BRFR 优于其他3种方法。

表1 4种方法在一个步态周期上的预测结果
Tab.1 Prediction results of 4 different methods on one gait cycle

模型	评价指标		
	δ_{MAE}	δ_{RMSE}	R^2
FRF	0.165	0.044	0.954
ERFR	0.138	0.033	0.970
ANN	0.170	0.046	0.965
SVM	0.204	0.075	0.948

FRF表示基础随机森林算法;ERFR表示增强随机森林算法;ANN表示人工神经网络算法;SVM表示支持向量机算法




图3 4种方法的预测效果
Fig.3 Prediction effects of 4 different methods

2.2 预测结果分析

本文利用干预前所有受试者的步态参数和膝关节接触力数据训练和验证模型,BRFR模型在验证集上的均方根误差为0.133,平均绝对误差为0.033,平方相关系数为0.70,表明模型能准确地学习输入和输出之间的因果关系。利用干预后单个受试者的步态参数和膝关节接触力数据测试模型,结果如表2所示,可以看出训练后的模型能够准确地将这种因果关系推广到新的输入中,具有较高的通用性。由于篇幅限制,本文从两种测试集中各随机抽取一个完整步态周期的数据进行拟合效果展示,结果如图4所示。

3 结 论

本文提出一种融合人工鱼群和随机森林算法的膝关节接触力预测方法。首先,将干预前所有受试者的步态参数和膝关节接触力数据划分为训练集(70%)和验证集(30%),利用随机森林算法对训练集

表2 BRFR模型在3例受试者数据上的拟合效果

Tab.2 Fitting effects of BRFR model on the data of 3 subjects

受试者	测试集1			测试集2		
	δ_{MAE}	δ_{RMSE}	R^2	δ_{MAE}	δ_{RMSE}	R^2
DM	0.120	0.023	0.977	0.131	0.027	0.972
JW	0.150	0.043	0.956	0.188	0.045	0.954
SC	0.112	0.033	0.982	0.128	0.031	0.979

DM、JW、SC是公开数据集里3例受试者的名称

进行训练,并利用改进的人工鱼群算法优化随机森林模型的主要参数,获得步态参数和膝关节接触力的非线性关系,并利用验证集进行验证。人工鱼群算法优化随机森林模型得到的主要参数为($n_{\text{tree}}=131, m_{\text{try}}=10$),ERFR模型在验证集上的均方根误差为0.138,平均绝对误差为0.033,平方相关系数为0.970,表明模型能准确地学习输入和输出之间的因果关系。然后,以干预后单个受试者的步态参数和

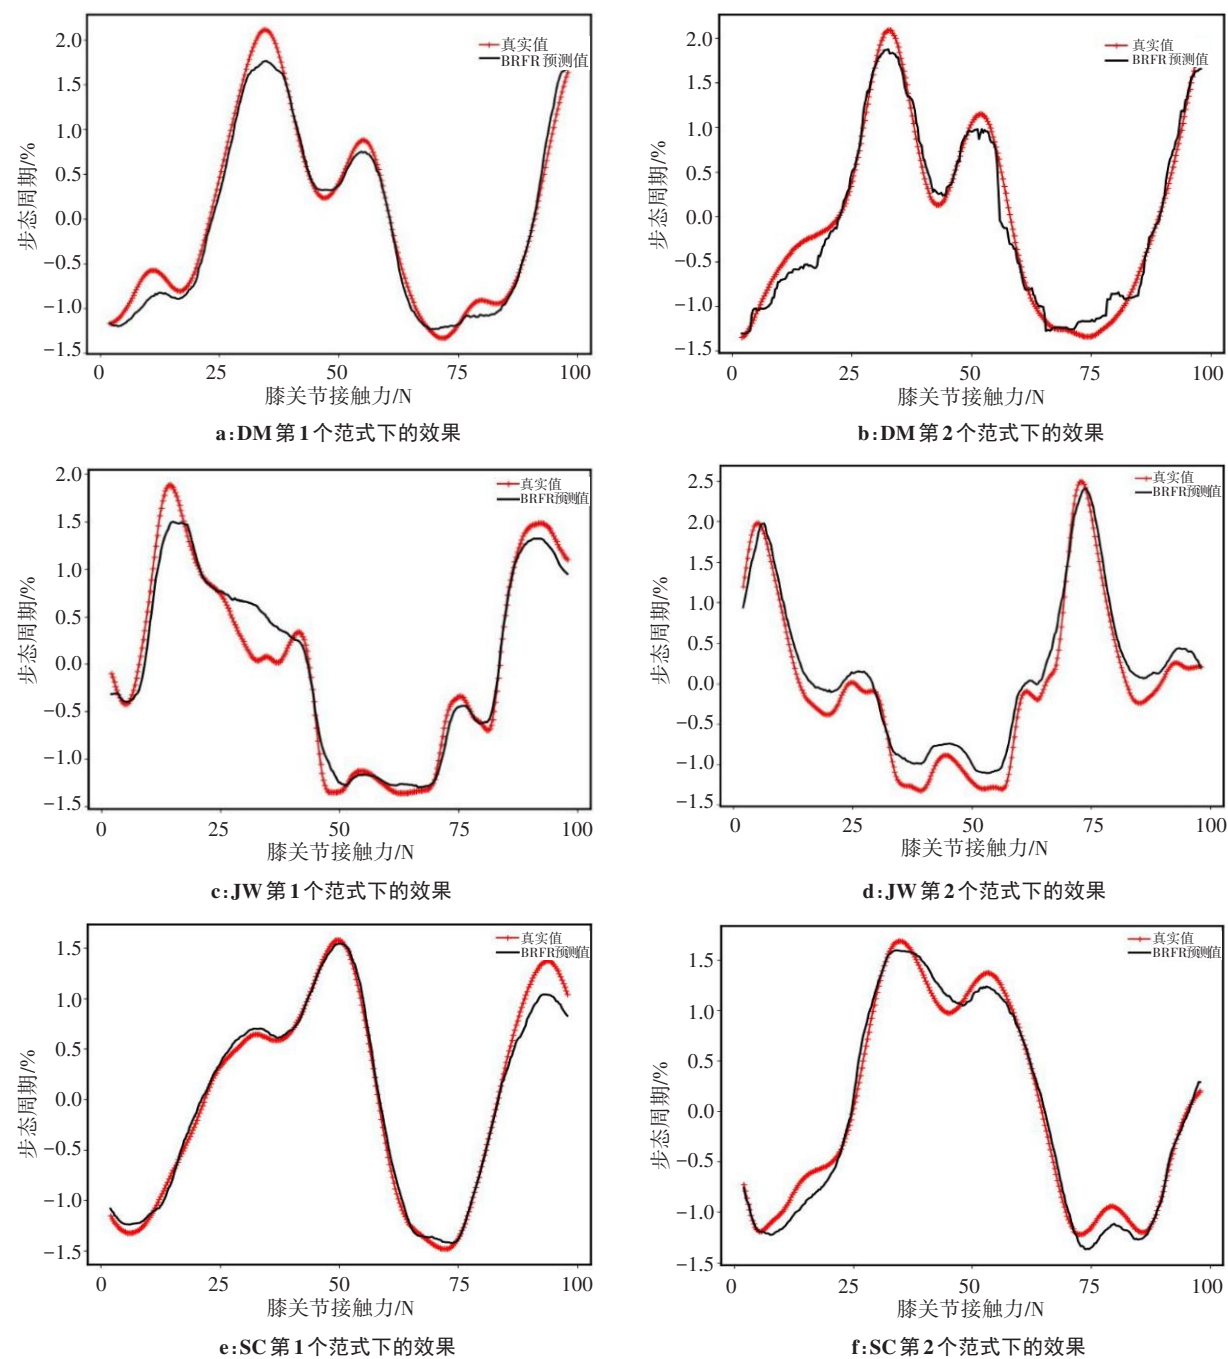


图4 不同康复训练范式下3例受试者的膝关节接触力预测效果

Fig.4 Keen contact force prediction of 3 subjects under different rehabilitation training patterns

膝关节接触力数据为预测模型进行测试,这样可以进一步检验模型的通用性,结果如表2所示,可以看出训练后的模型具有较高的通用性。未来的研究工作需要将已建立的模型同寻优算法相结合,以减轻关节负荷为目标函数,利用寻优算法求解最优的步态模式,从而为康复策略的制定提供参考。

【参考文献】

[1] FERRARELLO F, BIANCHI V A, BACCINI M, et al. Tools for observational gait analysis in patients with stroke: a systematic review [J]. Phys Ther, 2013, 93(12): 1673-1685.

[2] MARZIEH M A, CHEN Z X, WANG L, et al. Feed forward artificial neural network to predict contact force at medial knee joint: application to gait modification[J]. Neurocomputing, 2014, 139(2): 114-129.

[3] 王浩伦, 朱业安, 徐唯祎, 等. 步态识别特征的提取和重要性排序[J]. 中国医学物理学杂志, 2019, 36(7): 811-817.

WANG H L, ZHU Y A, XUE W Y, et al. Extraction and importance ranking of features for gait recognition[J]. Chinese Journal of Medical Physics, 2019, 36(7): 811-817.

[4] KINNEY A, BESIER T F, SILDER A, et al. Changes in *in vivo* knee contact forces through gait modification[J]. J Orthop Res, 2013, 31 (3): 434-440.

[5] RICHARDS R, ANDERSEN M S, HARLAAR J, et al. Relationship between knee joint contact forces and external knee joint moments in

- patients with medial knee osteoarthritis: effects of gait modifications [J]. *Osteoarthritis Cartilage*, 2018, 26(9): 1203-1214.
- [6] FREGLY B J, BESIER T F, LLOYD D G, et al. Grand challenge competition to predict *in vivo* knee loads[J]. *J Orthop Res*, 2012, 30(4): 503-513.
- [7] ROBERT T, CAUSSE J, MONNIER G, et al. Estimation of external contact loads using an inverse dynamics and optimization approach: general method and application to sit-to-stand maneuvers [J]. *J Biomech*, 2013, 46(13): 2220-2227.
- [8] CHEN Z, ZHANG Z, WANG L, et al. Evaluation of a subject-specific musculoskeletal modelling framework for load prediction in total knee arthroplasty[J]. *Med Eng Phys*, 2016, 38(8): 708-716.
- [9] DING Z, NOLTE D, TSANG C K, et al. *In vivo* knee contact force prediction using patient-specific musculoskeletal geometry in a segment-based computational model[J]. *J Biomech Eng-Trans ASME*, 2016, 138(2): 021018.
- [10] PARK S, LEE S, YOON J, et al. Finite element analysis of knee and ankle joint during gait based on motion analysis[J]. *Med Eng Phys*, 2019, 63(5): 33-41.
- [11] ACKLAND D C, LIN Y, PANDY M G, et al. Sensitivity of model predictions of muscle function to changes in moment arms and muscle-tendon properties: a Monte-Carlo analysis[J]. *J Biomech*, 2012, 45(8): 1463-1471.
- [12] FAVRE J, HAYOZ M, ERHARTHLEDIK J C, et al. A neural network model to predict knee adduction moment during walking based on ground reaction force and anthropometric measurements [J]. *J Biomech*, 2012, 45(4): 692-698.
- [13] OH S E, CHOI A, MUN J H, et al. Prediction of ground reaction forces during gait based on kinematics and a neural network model[J]. *J Biomech*, 2013, 46(14): 2372-2380.
- [14] ARDESTANI M M, ZHANG X, WANG L, et al. Human lower extremity joint moment prediction: a wavelet neural network approach [J]. *Expert Sys Appl*, 2014, 41(9): 4422-4433.
- [15] DE VRIES W H, VEEGER H E, BATEN C T, et al. Can shoulder joint reaction forces be estimated by neural networks[J]. *J Orthop Res*, 2016, 49(1): 73-79.
- [16] KIPP K, GIORDANELLI M D, GEISER C F, et al. Predicting net joint moments during a weightlifting exercise with a neural network model [J]. *J Biomech*, 2018, 74(6): 225-229.
- [17] LUO G L, ZHU Y A, WANG R, et al. Random forest-based classification and analysis of hemiplegia gait using low-cost depth cameras[J]. *Med Biol Eng Comput*, 2019, 58(2): 373-382.
- [18] ZHU X, NI Z, NI L, et al. Improved discrete artificial fish swarm algorithm combined with margin distance minimization for ensemble pruning[J]. *Comput Ind Eng*, 2019, 128(3): 32-46.
- [19] 李晓磊, 路飞, 田国会, 等. 组合优化问题的人工鱼群算法应用[J]. *山东大学学报(工学版)*, 2004, 34(5): 64-67.
- LI X L, LU F, TIAN G H, et al. Applications of artificial fish school algorithm in combinatorial optimization problems [J]. *Journal of Shandong University (Engineering Science)*, 2004, 34(5): 64-67.
- [20] 左姣姣, 倪志伟, 朱旭辉, 等. 融合协同进化人工鱼群算法和SVM的雾霾预测方法[J]. *模式识别与人工智能*, 2018, 31(8): 725-739.
- ZUO J J, NI Z W, ZHU X H, et al. Haze prediction method combining co-evolution artificial fish swarm algorithm and support vector machine[J]. *Pattern Recognition and Artificial Intelligence*, 2018, 31(8): 725-739.
- [21] AMIT Y, GEMAN D. Shape quantization and recognition with randomized trees[J]. *Neural Comput*, 1997, 9(7): 1545-1588.
- [22] STROBL C, BOULESTEIX A, AUGUSTIN T, et al. Unbiased split selection for classification trees based on the gini index[J]. *Comput Stat Data Anal*, 2007, 52(1): 483-501.

(编辑:陈丽霞)