

DOI: 10.19650/j.cnki.cjsi.J2210032

基于改进小脑模型的 sEMG 下肢关节力矩预测*

姜海燕^{1,2}, 李竹韵^{1,2}, 陈艳^{1,2}

(1. 福州大学电气工程与自动化学院 福州 350108; 2. 福建省医疗器械和医药技术重点实验室 福州 350108)

摘要: 关节力矩预测在康复医学、临床医学和运动训练等领域有着重要作用, 对力矩连续、实时地预测可以使人机交互设备更好地反馈、复刻人体运动意图。为了给患者提供一个安全、主动、舒适的康复训练环境, 提升人机交互设备的柔顺性, 提出了一种改进型递归小脑模型神经网络模型关节力矩预测方法。该方法采用肌肉协同分析对采集的相关肌肉的表面肌电信号(sEMG)进行降维, 将降维后的 sEMG 特征向量与关节角速度、关节角度作为输入信号, 并在小脑模型神经网络中加入递归单元和模糊逻辑规则, 以小波函数作为隶属度函数, 对非疲劳、过渡疲劳及疲劳这 3 种状态下的踝关节背屈跖屈运动的动态力矩进行连续预测。力矩预测值与实际值之间的平均皮尔逊相关系数和平均标准均方根误差分别为 0.933 5 和 0.159 8, 实验结果验证了该方法对下肢关节力矩连续预测的准确性和有效性。

关键词: 关节力矩预测; 表面肌电信号; 小脑模型神经网络; 肌肉协同分析

中图分类号: TH772 **文献标识码:** A **国家标准学科分类代码:** 510.40

Joint torque prediction of lower limb of sEMG signals based on improved cerebellar model

Jiang Haiyan^{1,2}, Li Zhuyun^{1,2}, Chen Yan^{1,2}

(1. College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, China;

2. Fujian Provincial Key Laboratory of Medical Instrument and Pharmaceutical Technology, Fuzhou 350108, China)

Abstract: The joint torque prediction plays an important role in rehabilitation medicine, clinical medicine, sports training and other fields. The continuous and real-time torque prediction can make the human-computer interaction equipment better feedback and reproduce the intention of human motion. To provide a safe, active and comfortable rehabilitation training environment for patients and enhance the compliance of the human-computer interaction equipment, a novel method of joint torque prediction is proposed, which is based on an improved recursive cerebellar model neural network. In this method, muscle synergy analysis is used to reduce the dimensionality of surface electromyographic (sEMG) signals. Then, the reduced-dimension sEMG feature vector, joint angular velocity and joint angle are used as the input data of the prediction model. In addition, recursive unit and fuzzy logic rules are introduced into the cerebellar model neural network, while the wavelet function is used as membership function. Hence, the generalization ability of the network is optimized. The RWFCMNN model realizes the time series prediction of the dynamic torque of ankle dorsiflexion and plantarflexion in three states, non-fatigue, transitional fatigue and fatigue. The average Pearson correlation coefficient and the average normalized root mean square error between the predicted torque and the actual torque are 0.933 5 and 0.159 8, respectively. These numerical values verify the accuracy and effectiveness of this method for continuous prediction of lower limb joint torque.

Keywords: joint torque prediction; surface electromyography; cerebellar model neural network; muscle synergy analysis

0 引言

人机交互技术已经展现出了巨大的研究价值和广泛

的应用前景,促进了智能化机器与人类力量的结合^[1]。关节力矩预测是人机交互技术的重要组成部分^[2],对于肢体定量康复、外骨骼机器人、运动训练评估等多个领域^[3-4]的发展具有极其重要的意义,尤其是在具有生物反

馈功能的机器设备中,需要对力矩变化进行连续、实时的预测才能达到实际应用的目的。

表面肌电信号 (surface electromyography, sEMG) 是人体运动神经链路中执行单元骨骼肌收缩时产生的电信号^[5]。sEMG 蕴含肌肉活动强度^[6-7]、活动时间^[8]等与运动相关的信息,被认为是应用于运动学、生物医学的最佳生物反馈信号。因此,通过表面肌电信号实现对力矩的预测逐渐成为研究热点。张小栋等^[9]利用 sEMG 快速识别人体步态事件、连续解码人体下肢关节运动角度,并实现了人体下肢主动关节力矩的定量预测,对下肢康复机器人的未来研究方向与内容做出展望。

通过掌握关节力矩与其控制肌群 sEMG 之间的定量关系,以 sEMG 作为输入,关节力矩等信息作为输出,需要一个模型来关联肌肉激活度和关节力矩。基于逆动力学提出的神经肌肉骨骼 (neuromusculoskeletal, NMS) 模型和改进的 Hill 肌肉模型已经被广泛的应用^[10],熊保平等^[11]提出了一种 Hill 模型结合人体几何学的力矩预测方法,对同一受试者不同速度下的关节力矩进行预测。但由于该方法是根据肌肉收缩时的肌纤维长度、收缩速度等各类生理学参数建立的力矩预测模型,需要测量的参数较多,所以仅适用于实验室研究的场合。目前,人工神经网络 (artificial neural network, ANN) 已经广泛应用于分类、预测、识别和优化问题,在很多领域展示了力量,这种方法建模直接简单,不需要考虑人体复杂的生理机制,并且模型的泛化性较强、对于不同个体的适应性较好。Zhang 等^[10]对比分析了 NMS 和 ANN 这两种模型在快走、慢走、自选快走和等速行走等 7 种运动任务中预测关节力矩的结果,并总结了两种模型的优缺点,当涉及到高肌肉激活度的情况下,NMS 模型的预测效果更好,但在大量不同情况下的试验训练中,ANN 模型对于脚踝力矩的预测鲁棒性更高。Lam 等^[12]首先通过前馈 ANN 估计地面反作用力和相应的压力中心,然后利用逆动力学和混合建模预测下肢矢状关节力矩。Jali 等^[13]使用 3 层 ANN 网络模型预测肘关节弯曲运动期间的关节力矩,并用于手臂康复装置的力矩控制,在数据采集时通过受试者举起哑铃来完成动作,就可能出现举不动哑铃的情况,导致实验条件受限。此外,学者们为了获得较高的力矩预测准确率,通常在肌体非疲劳状态下进行 sEMG 的采集。而在实际康复训练过程中,肌体可能会存在非疲劳、过渡到疲劳和疲劳 3 个不同的状态,因此根据肌体的疲劳状态提出一种符合实际力矩预测的方法具有重要的研究价值。

相关研究表明,当肢体进行连续运动时,仅凭单块肌肉收缩是无法完成动作的,需要多块肌肉协同完成^[14]。因此在进行动态力矩预测时,要采集多块肌肉的 sEMG,但这样就会造成数据冗余。肌肉协同理论是神经系统通过模块化肌肉群收缩控制,以减少由冗余控制问题引起

的计算成本^[15],它可以很好地解释中枢神经系统对肌肉活动的控制机制,对于数据降维有很好的效果。

小脑模型神经网络 (cerebellar model neural network, CMNN)^[16]是根据人类小脑的生物功能和神经细胞感知方式提出的一种感知网络,具有局部泛化、快速收敛的优势,在分类和控制预测方面都有很好的表现^[17]。然而,传统的 CMNN 采用逻辑基函数作为输入传感器,网络输出不连续^[18]。为了实现动态力矩的连续预测,同时考虑到预测问题与时间序列的关系,本文将模糊理论与 CMNN 相结合,将小波函数作为模型隶属函数,并在模型中加入递归单元来改进 CMNN,以提高全局收敛速度和网络泛化性^[19]。

综上所述,本文提出了一种采用肌肉协同分析方法对 sEMG 进行降维处理,将改进型递归小脑模型神经网络 (recurrent wavelet fuzzy cerebellar model neural network, RWFCMNN) 作为预测模型进行下肢踝关节力矩连续预测的方法。

1 材料与方法

1.1 预测流程

RWFCMNN 模型的关节力矩预测流程框图如图 1 所示。力矩预测流程主要包括数据采集、数据预处理、特征提取及预测模型训练 4 个部分。

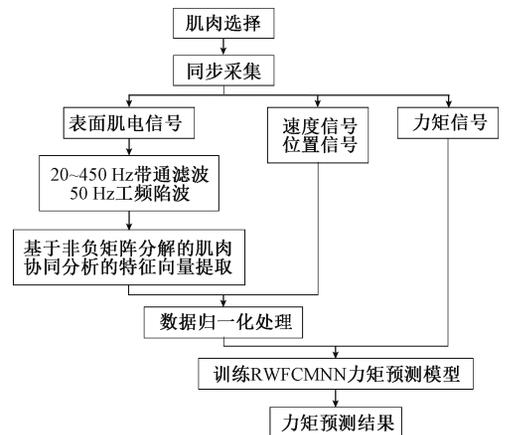


图 1 基于 RWFCMNN 的力矩预测流程

Fig. 1 Flow chart of torque prediction based on RWFCMNN

1.2 数据获取

1) 肌肉选择

本文进行力矩预测的部位为下肢的踝关节,采集时令受试者执行连续背屈和跖屈动作。选择与该动作相关的肌肉进行信号采集,5 块肌肉分别为踇长伸肌、胫骨前肌、趾长伸肌、腓骨长肌和腓肠肌,肌肉位置分布如图 2 所示。



图2 肌肉分布

Fig. 2 Distribution of muscles

2) 数据采集

肌电信号采集系统为 Delsys Trigno Wireless System, 力矩采集系统为 BIODEX System 4 Pro Strength Testing System。在 BIODEX 系统上执行动作, 获得肌肉的表面肌电信号、速度及位置等信息。

采集前, 受试者根据 Borg 自感用力度等级量表进行培训, 判断自己所处疲劳程度, 获取受试者在非疲劳、过渡疲劳及疲劳状态下的数据。采集时, 让受试者根据指令在自己踝关节可屈伸范围内做等速背屈跖屈运动。图3与4所示为采集的某一受试者的信号, 图3(a)~(e)依次为腓肠肌、胫骨前肌、腓骨长肌、趾长伸肌、踇长伸肌的表面肌电信号; 图4(a)~(c)依次为力矩、角速度、关节角度信号。

1.3 基于非负矩阵分解的肌肉协同分析

当肌体执行动作时, 是由中央神经系统控制一个相对较小维数的参数集合来完成。这些肌肉的激活状态通过相应的肌肉协同元与肌肉激活系数表示^[20]为:

$$\mathbf{V}_{N \times T} = \mathbf{W}_{N \times K} \times \mathbf{H}_{K \times T} = [\mathbf{W}_1 \quad \mathbf{W}_2 \quad \cdots \quad \mathbf{W}_K] \times \begin{bmatrix} \mathbf{H}_1 \\ \mathbf{H}_2 \\ \vdots \\ \mathbf{H}_K \end{bmatrix} = \sum_{i=1}^K \mathbf{W}_i \mathbf{H}_i \quad (1)$$

式中: $\mathbf{V}_{N \times T}$ 表示肌肉激活度矩阵; $\mathbf{W}_{N \times K}$ 表示 $\mathbf{V}_{N \times T}$ 经过分解后的肌肉协同矩阵; $\mathbf{H}_{K \times T}$ 表示 $\mathbf{V}_{N \times T}$ 经过分解后的肌肉激活系数矩阵; N 为肌肉的数目; T 为肌肉的样本点数量; K 为分解后的协同元数量。一般情况下每个独立的动作有且只有一个协同元作用^[21], 针对实验中两个独立的运动, $K=2$ 。

肌肉协同分析常用的分解算法为非负矩阵分解算法 (non-negative matrix factorization, NMF), 此算法只要求其输入值为非负性即可。具体分解公式如下:

$$\mathbf{V} = \mathbf{W}\mathbf{H} + \mathbf{E}, \mathbf{V} \in \mathbf{R}^{N \times T}, \mathbf{W} \in \mathbf{R}^{N \times K}, \mathbf{H} \in \mathbf{R}^{K \times T}, \mathbf{V}, \mathbf{W}, \mathbf{H} \geq 0 \quad (2)$$

式中: \mathbf{V} 矩阵表示的是需要进行求解的矩阵; 分解得到 \mathbf{W}

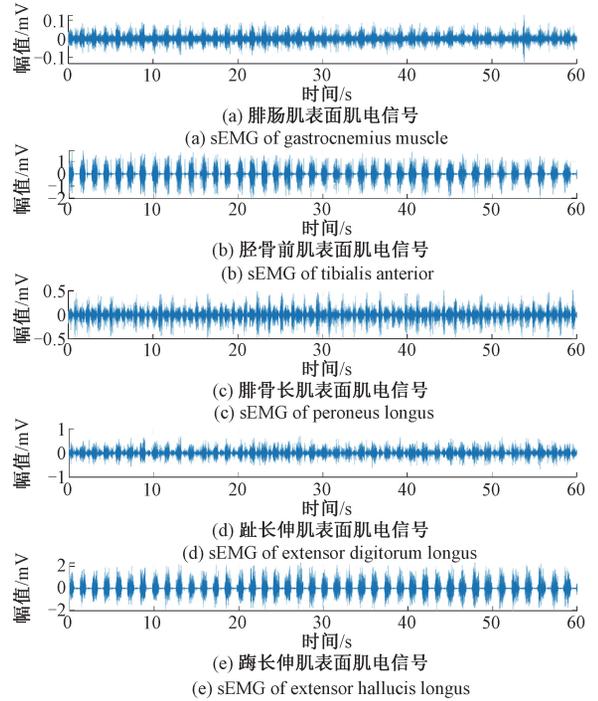


图3 5块肌肉的表面肌电信号

Fig. 3 sEMG signals from five muscles

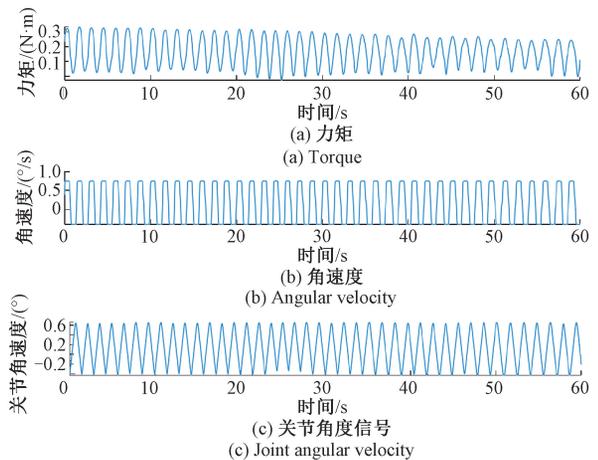


图4 力矩、角速度、关节角度信号

Fig. 4 Torque, angular velocity and joint angle signals

和 \mathbf{H} 矩阵; \mathbf{E} 代表的是经过分解后的逼近误差。

根据已知的 \mathbf{V} 矩阵, 让 $\|\mathbf{E}\| = \|\mathbf{V} - \mathbf{W}\mathbf{H}\|$ 尽可能小, 其本质就是求式(2)的最大似然解, 具体公式如下:

$$\{\mathbf{W}, \mathbf{H}\} = \operatorname{argmax}_{\mathbf{W}, \mathbf{H}} p(\mathbf{V} | \mathbf{W}, \mathbf{H}) = \operatorname{argmin} [-\log p(\mathbf{V} | \mathbf{W}, \mathbf{H})] \quad (3)$$

本文使用对初始值敏感的基于 K-L 散度的乘性迭代算法求取矩阵 \mathbf{W} 和 \mathbf{H} , 之后采用收敛性好、计算速度快的交替最小二乘法寻找最优结果。

1.4 RWFCMNN

本文在小脑模型神经网络中加入模糊推理规则,采用小波函数作为模糊隶属函数,实现联想记忆层的输入输出映射,并加入反映前一时间对当前时刻影响的递归单元,以更好地处理力矩预测问题。

1) RWFCMNN 规则

改进的递归小脑模型神经网络模型的模糊推理映射规则如下:

R^A : 如果 x_1 是 r_{1k} , x_2 是 r_{2k} , \dots , x_m 是 r_{mk} , $i = 1, 2, \dots, m$, 则 $w_k = x_k, k = 1, 2, \dots, n$ 。

其中, x_i 为第 i 个输入值; r_{ik} 为第 i 个输入、第 k 层的模糊集; w_k 为后续模糊输出的权重; m 为输入维度; n 为每个输入维度的层数, 即模糊规则的个数。

模糊推理的隶属度函数选用高斯型小波函数:

$$r_{ik} = -\left(\frac{x_{ik} - b_{ik}}{a_{ik}}\right) \exp\left(-\frac{1}{2}\left(\frac{x_{ik} - b_{ik}}{a_{ik}}\right)^2\right) \quad (4)$$

式中: b_{ik} 为平移参数; a_{ik} 为扩张参数。

2) RWFCMNN 模型结构

RWFCMNN 模型结构如图 5 所示。网络结构包括输入层、联想记忆层、接受域层、权值记忆层及输出层。

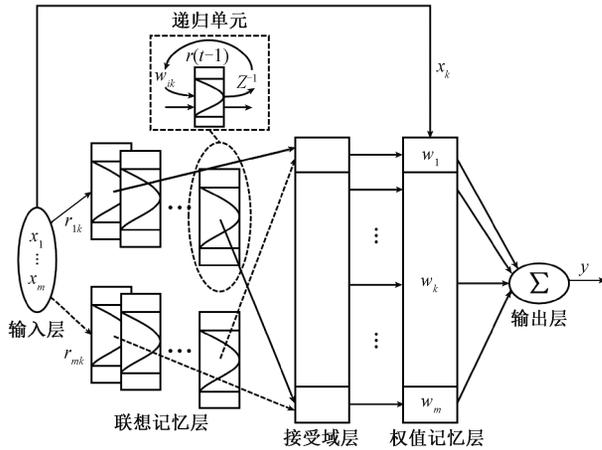


图 5 RWFCMNN 模型结构

Fig. 5 Model structure of RWFCMNN

输入层: 输入层是用来接受输入变量的空间。该层节点数跟输入数据的维度相等。这些节点是用来分配输入信号的, 输入信号为 $x_i, i = 1, 2, \dots, m$ 。

联想记忆层: 输入数据从原先的 m 维数据量转化成 n 个离散区域, 其中 n 的值为网络设置的分辨率。联想记忆层的层数与该分辨率值相等, 都为 n 。通过模糊推理规则对输入信号进行映射, 映射规则如 RWFCMNN 规则。

递归单元函数如下:

$$x_{ik}(t) = x_i(t) + w_{ik}r_{ik}(t-1) \quad (5)$$

式中: t 是时间序列; w_{ik} 是递归单元的权重, 代表上一时刻的输出结果对这一时刻的影响; $r_{ik}(t-1)$ 表示上一时刻的输出结果。

接收域层: 该层的层数为 n , 每一层的输出是其对应的 m 个联想记忆层的输出乘积。联想记忆层的数目对应于模糊规则的数目。利用与运算实现模糊乘积推理, 具体计算公式如下:

$$c_k = \prod_{i=1}^m r_{ik} \quad i = 1, 2, \dots, m; k = 1, 2, \dots, n \quad (6)$$

权值记忆层: 每个规则的各自权重存储在该空间, 具体公式如下:

$$w = [w_1, \dots, w_k, \dots, w_n]^T \quad (7)$$

输出层: 本文神经网络用于预测问题, 则不需要对输出值进行限制。输出结果为接收域层跟权值记忆层相乘的代数和, 同时去模糊化, 输出节点数为 1, 具体公式如下:

$$y = \sum_{k=1}^n (w_k \cdot c_k) \quad (8)$$

3) RWFCMNN 反向传递算法

本文使用梯度下降算法对该神经网络参数进行更新调整。误差函数定义为:

$$E = \frac{1}{2}(y_0 - y)^2 = \frac{1}{2}e^2 \quad (9)$$

式中: y_0 为给定数据的输出值; y 为 RWFCMNN 的输出值; e 为神经网络的输出误差。

需要更新的参数公式如下:

$$V(t+1) = V(t) + \Delta V = V(t) + \eta \frac{-\partial E(T)}{\partial R} \quad (10)$$

式中: V 分别代表参数 b_{ik} 、 a_{ik} 、 w_{ik} 、 w_k ; η 为参数对应的学习率, 分别表示为 $\eta_{b_{ik}}$ 、 $\eta_{a_{ik}}$ 、 $\eta_{w_{ik}}$ 、 η_{w_k} 。

误差函数对参数的偏导数用链式法, 具体计算公式如下:

$$\Delta w_k = -\eta_{w_k} \frac{\partial E}{\partial w_k} = -\eta_{w_k} \frac{\partial E}{\partial y} \frac{\partial y}{\partial w_k} = \eta_{w_k} (y_0 - y) c_k \quad (11)$$

$$\Delta b_{ik} = -\eta_{b_{ik}} \frac{\partial E}{\partial b_{ik}} = -\eta_{b_{ik}} \frac{\partial E}{\partial y} \frac{\partial y}{\partial c_k} \frac{\partial c_k}{\partial r_{ik}} \frac{\partial r_{ik}}{\partial b_{ik}} = \eta_{b_{ik}} (y_0 - y) w_k c_k \frac{\left(\frac{x_{ik} - b_{ik}}{a_{ik}}\right)^2 - 1}{\left(\frac{x_{ik} - b_{ik}}{a_{ik}}\right) a_{ik}} \quad (12)$$

$$\Delta a_{ik} = -\eta_{a_{ik}} \frac{\partial E}{\partial a_{ik}} = -\eta_{a_{ik}} \frac{\partial E}{\partial y} \frac{\partial y}{\partial c_k} \frac{\partial c_k}{\partial r_{ik}} \frac{\partial r_{ik}}{\partial a_{ik}} = \eta_{a_{ik}} (y_0 - y) w_k c_k \frac{\left(\frac{x_{ik} - b_{ik}}{a_{ik}}\right)^2 - 1}{a_{ik}} \quad (13)$$

$$\Delta w_{ik} = -\eta_{w_{ik}} \frac{\partial E}{\partial w_{ik}} = -\eta_{w_{ik}} \frac{\partial E}{\partial y} \frac{\partial y}{\partial c_k} \frac{\partial c_k}{\partial r_{ik}} \frac{\partial r_{ik}}{\partial w_{ik}} =$$

$$1 - \left(\frac{x_{ik} - b_{ik}}{a_{ik}} \right)^2 \quad (14)$$

$$\eta_{w_{ik}} (y_0 - y) w_k c_k \frac{1 - \left(\frac{x_{ik} - b_{ik}}{a_{ik}} \right)^2}{\left(\frac{x_{ik} - b_{ik}}{a_{ik}} \right) a_{ik}} r_{ik}(t-1)$$

4) 收敛性分析

为了保证 RWFCMNN 算法输出误差的收敛性,需要对各个参数设定合适的学习率。 R 分别表示参数 b_{ik} 、 a_{ik} 、 w_{ik} 、 w_k 、 η 为参数对应的学习率,分别表示为 $\eta_{b_{ik}}$ 、 $\eta_{a_{ik}}$ 、 $\eta_{w_{ik}}$ 、 η_{w_k} 。

首先定义李雅普诺夫函数为:

$$V(N) = \frac{1}{2} e(N)^2 \quad (15)$$

式中: N 为迭代次数, $e(N) = y_0 - y(N)$ 。

上述函数的变化量具体计算公式如下:

$$\Delta V(N) = V(N+1) - V(N) = \frac{1}{2} (e(N+1))^2 -$$

$$e(N)^2 = \frac{1}{2} (e(N+1) + e(N)) \cdot \Delta e(N) \quad (16)$$

根据 Taylor 公式及链式法则可表示为:

$$\Delta e(N) = \frac{\partial e(N)}{\partial R} \cdot \Delta R \quad (17)$$

$$\frac{\partial e(N)}{\partial R} = \frac{\partial e(N)}{\partial y(N)} \frac{\partial y(N)}{\partial R} = -\frac{\partial y(N)}{\partial R} \quad (18)$$

$$\Delta R = -\eta \frac{\partial V(N)}{\partial R} = -\eta \cdot \left(-e(N) \cdot \frac{\partial y(N)}{\partial R} \right) =$$

$$\eta \cdot e(N) \cdot \frac{\partial y(N)}{\partial R} \quad (19)$$

将式(18)和(19)代入式(17)得:

$$\Delta e(N) = \frac{\partial e(N)}{\partial R} \cdot \Delta R = \left(-\frac{\partial y(N)}{\partial R} \right) \cdot \eta \cdot e(N) \cdot$$

$$\frac{\partial y(N)}{\partial R} = -\eta \cdot e(N) \cdot \left(\frac{\partial y(N)}{\partial R} \right)^2 \quad (20)$$

将式(20)代入式(16)得:

$$\Delta V(N) = \frac{1}{2} (e(N+1) + e(N)) \cdot \Delta e(N) =$$

$$\frac{1}{2} \eta e(N)^2 \left(\frac{\partial y(N)}{\partial R} \right)^2 \left(\eta \left(\frac{\partial y(N)}{\partial R} \right)^2 - 2 \right) \quad (21)$$

当 η 满足式(22)的条件时, $\Delta V(N) < 0$, 此时函数为单调递减函数。

$$0 < \eta < \frac{2}{\left(\frac{\partial y(N)}{\partial R} \right)^2} \quad (22)$$

易证当 $0 \leq y_0(N) \leq 1$, $0 \leq y(N) \leq 1$, 有 $V(N) \geq 0$ 。所以当 $\Delta V(N) < 0$ 和 $V(N) \geq 0$, 根据李雅普诺夫稳定性证明了 RWFCMNN 网络的误差是收敛的。

1.5 评价指标

为了将预测模型的踝关节力矩输出结果与实际踝关节力矩结果进行对比,对模型性能进行评价。本文采用皮尔逊相关系数(Pearson correlation coefficient, PCC)以及标准均方根误差(normalized root mean square error, NRMSE)这两个相对指标作为模型的评价指标,分析预测结果的线性度和相对误差。其计算公式如下:

$$PCC = \frac{Cov(X, Y)}{\sigma_X \sigma_Y} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (23)$$

$$NRMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - Y_i)^2}{\sum_{i=1}^n X_i^2}} \quad (24)$$

式中: X 为神经网络预测的抓取力; Y 为实际抓取力; σ_X 和 σ_Y 为标准差; \bar{X} 和 \bar{Y} 为平均值; n 为样本数。

2 结果

2.1 特征选择

本文采用肌肉协同系数矩阵作为特征向量输入力矩预测模型,并将预测结果与采用原始表面肌电信号及肌电均方根值(root mean square, RMS)作为模型输入特征向量的预测结果进行对比。力矩预测模型采用 RWFCMNN。

图6~8所示分别为同一位受试者采用原始数据、RMS特征及NMF特征作为模型输入的特征力矩预测结果,表1为力矩预测结果的PCC和NRMSE数据对比。

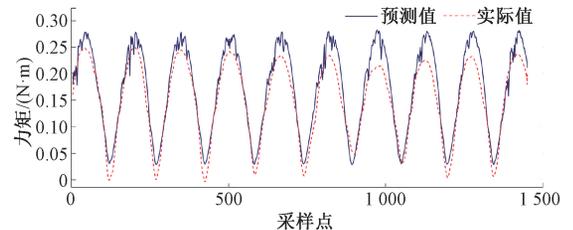


图6 原始数据力矩预测结果

Fig. 6 Torque prediction results using raw data as input data

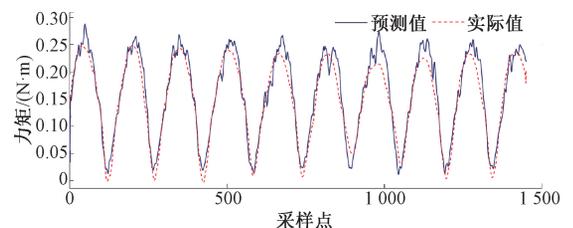


图7 RMS力矩预测结果

Fig. 7 Torque prediction results using the root mean square feature vector as input data

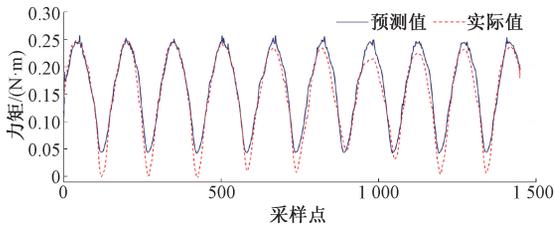


图 8 NMF 力矩预测结果

Fig. 8 Torque prediction results using the non-negative matrix factorization feature vector as input data

对比图 6~8 可知,使用原始数据和 RMS 特征进行预测的输出波形存在大幅度震荡,使用 NMF 的震荡现象减弱。

从表 1 的数据可以更直观地看出,NMF 特征的输出结果较原始数据和 RMS 特征的输出结果相比最好。

表 1 预测结果对比

Table 1 Comparison of prediction results

评价指标	原始数据	RMS	NMF
PCC	0.966 4	0.969 3	0.979 5
NRMSE	0.184 3	0.120 8	0.107 8

为了验证该方法的实用性,将上述 3 种特征参量作为输入数据的模型预测时间对比,结果如表 2 所示。

表 2 平均预测时间对比

Table 2 Comparison of average prediction time

输入特征	原始数据	RMS	NMF
时间/s	0.007 0	0.007 8	0.004 5

从表 2 可得,数据经过 NMF 方法降维,整体数据量降低,所需的运行时间最短。而原始的表面肌电信号和时域特征 RMS 特征的数据冗余、维度高导致模型运算时间较长。

2.2 平滑处理

在进行力矩预测时,模型的输出结果会出现震荡情况,为了解决这个问题,本文在预测结果加入平滑处理以减少震荡。

Smooth 函数有平滑滤波的作用,计算公式为:

$$f(t) = \frac{f(t-n) + \dots + f(t) + \dots + f(t+n)}{2n+1} \quad (25)$$

式中: $f(t)$ 为 t 时刻的数据点; n 为常数。

由于 Smooth 函数需要当前时刻之后的数据参与计算,不符合预测问题的条件。因此本文平滑处理仅使用当前时间点之前的结果进行平滑,如式(26)所示。

$$f(t) = c_1 f(t) + c_2 f(t-1) + c_3 f(t-2) \quad (26)$$

式中: $c_1 = 0.5, c_2 = 0.3, c_3 = 0.2$ 。

平滑前后的神经网络输出结果对比如图 9 所示。

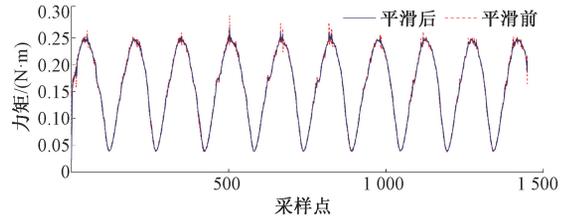


图 9 平滑前后力矩预测结果对比

Fig. 9 Comparison of torque prediction results before and after smoothing

如图 9 所示,平滑处理后的结果相比于平滑前的输出减少了震荡频率和震荡幅度,优化了输出结果与实际结果的拟合程度,可以更平稳地进行踝关节力矩输出。模型的评价指标 PCC 和 NRMSE 都有改善,具体数据如表 3 所示。

表 3 预测结果平滑前后数据对比

Table 3 Comparison of prediction results before and after smoothing

评价指标	平滑前	平滑后
PCC	0.969 4	0.979 5
NRMSE	0.123 7	0.107 8

2.3 实验结果与分析

受试者在进行踝关节连续背屈跖屈动作时,会存在非疲劳状态、过渡到疲劳状态和疲劳状态 3 种状态,图 10~12 所示分别为同一位受试者训练过程中 3 种状态下的力矩采集图。

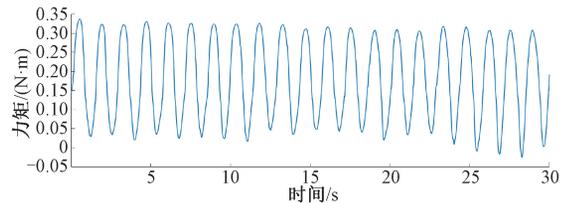


图 10 某位受试者非疲劳状态的力矩波形

Fig. 10 Torque waveform of a subject in the non-fatigue state

从图 10~12 可以看出,受试者在非疲劳状态下执行动作的力矩较为稳定,波形基本没有抖动;过渡到疲劳状态时的力矩幅值逐渐变小并出现震荡;而在疲劳状态时受试者无法完全执行已设定的动作,此时的力矩会出现剧烈震荡、波形变化大及变化不规则等特点。后两种疲劳状态将会给动态力矩预测增加难度,导致预测结果准确度降低。

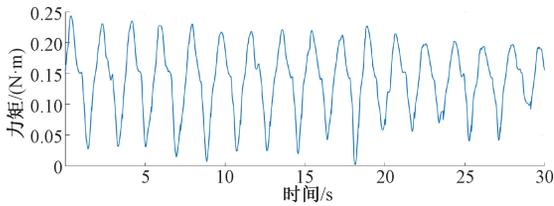


图 11 某位受试者过渡疲劳状态的力矩波形
Fig. 11 Torque waveform of a subject under the transitional fatigue state

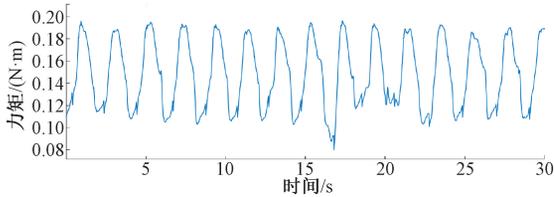


图 12 某位受试者疲劳状态的力矩波形
Fig. 12 Torque waveform of a subject under the fatigue state

为了验证 RWFCMNN 在力矩预测方面的优越性,将结果与 BP、CMNN 和 RCMNN 这 3 个神经网络的预测结果进行对比,对比结果如表 4 所示。

从表 4 数据可以得出,非疲劳状态下,4 种方法的 PCC 都高于 0.9, RWFCMNN 的 PCC 为 0.978 0, NRMSE 为 0.111 1, 预测结果优于其他 3 种方法。过渡到疲劳状

表 4 预测结果对比

Table 4 Comparison of prediction results of four methods

受试者状态	评价指标	BP	CMNN	RCMNN	RWFCMNN
非疲劳状态	PCC	0.934 1	0.927 5	0.944 0	0.978 0
	NRMSE	0.205 4	0.195 1	0.177 0	0.111 1
过渡疲劳状态	PCC	0.910 3	0.927 8	0.941 0	0.968 2
	NRMSE	0.246 1	0.200 3	0.234 2	0.090 9
疲劳状态	PCC	0.729 8	0.877 5	0.884 8	0.939 1
	NRMSE	0.159 7	0.165 5	0.180 1	0.074 7

态时,采集到的数据幅值开始减小并出现震荡, BP、CMNN 和 RCMNN 的 PCC 均增至 0.2 以上,而 RWFCMNN 的预测结果 PCC 为 0.968 2, NRMSE 为 0.090 9。疲劳状态时,采集的数据出现严重震荡,导致预测难度加大,神经网络预测的准确度整体下降,其中 BP 神经网络下降程度最大, PCC 降至 0.739 8。但 RWFCMNN 的预测结果仍然较好, PCC 保持在 0.9 以上, NRMSE 也小于 0.1, 预测准确度没有像其他网络一样出现大幅度下降。从上述结果分析可知,改进的递归小脑模型神经网络在 3 种状态下进行力矩预测的效果最好,所以本文提出使用 RWFCMNN 进行动态力矩连续预测是有效的方法。

为了进一步验证模型的有效性,分别对 5 位受试者的 3 组数据进行验证,计算所有受试者 NRMSE 和 PCC 的平均值和标准差,如表 5 所示。

表 5 5 名受试者 PCC 和 NRMSE 的平均值和标准差

Table 5 Mean and standard deviation of PCC and NRMSE for 5 subjects

神经网络	评价指标	S1	S2	S3	S4	S5
RWFCMNN	PCC	0.935 9±0.014 1	0.951 5±0.010 6	0.943 3±0.036 0	0.929 0±0.007 3	0.907 6±0.076 2
	NRMSE	0.163 0±0.055 0	0.167 2±0.053 7	0.119 8±0.014 3	0.203 1±0.003 2	0.146 0±0.079 3
BP	PCC	0.911 9±0.018 4	0.953 5±0.009 9	0.917 7±0.005 4	0.904 0±0.006 4	0.858 7±0.105 3
	NRMSE	0.215 7±0.050 5	0.303 4±0.028 4	0.228 9±0.063 8	0.311 7±0.108 0	0.208 9±0.066 8
CMNN	PCC	0.893 5±0.017 9	0.946 5±0.016 8	0.907 5±0.028 7	0.880 8±0.056 7	0.827 8±0.120 9
	NRMSE	0.253 3±0.047 6	0.258 3±0.086 8	0.310 8±0.207 4	0.431 3±0.179 0	0.222 6±0.158 8
RCMNN	PCC	0.914 2±0.032 9	0.926 6±0.013 1	0.918 8±0.024 3	0.874 1±0.045 5	0.755 8±0.219 5
	NRMSE	0.212 5±0.037 2	0.343 6±0.143 6	0.328 1±0.147 4	0.317 7±0.111 7	0.271 2±0.189 4

由表 5 可知, RWFCMNN 神经网络的预测值和实际输出之间的平均 PCC 可以达到 0.933 5, 平均 NRMSE 可以达到 0.159 8; BP 神经网络预测得到的平均 PCC 为 0.909 1, 其平均 NRMSE 为 0.253 7; CMNN 神经网络预测得到的平均 PCC 为 0.891 2, 平均 NRMSE 为 0.295 2;

RCMNN 神经网络预测得到的平均 PCC 为 0.877 9, 平均 NRMSE 为 0.294 6。根据评价指标的结果可知, RWFCMNN 神经网络对 5 位受试者的预测结果最好, 无论是对个体内还是不同个体间, 都能够较为准确地进行动态力矩连续预测。

3 结 论

本文采用肌肉协同分析对 sEMG 提取 NMF 特征,构建 RWFCMNN 作为力矩预测模型,在非疲劳、过渡到疲劳及疲劳这 3 种状态下对下肢踝关节的动态力矩进行连续预测的方法。

实验将 RWFCMNN 神经网络与 BP、CMNN、RCMNN 3 种神经网络在 3 种状态下的预测结果进行对比。实验结果表明,RWFCMNN 的预测结果是最稳定的,即使在预测难度最大的疲劳状态下,PCC 和 NRMSE 也可以达到 0.939 1 和 0.074 7。实验还对比了采用肌肉协同分析方法提取的 NMF 特征、原始信号特征和传统时域 RMS 特征作为输入信号的预测结果,结果表明使用 NMF 特征作为输入信号的预测效果最好,并且由于肌肉协同分析方法的降维效果,采用 NMF 特征输入 RWFCMNN 模型的预测时间也最短,早于人体运动时间,具有实际应用价值。最后详细列举了 5 位受试者 3 组数据预测结果的平均值和均方差,RWFCMNN 的预测值和实际输出之间的平均 PCC 和平均 NRMSE 分别为 0.933 5 和 0.159 8。证明了该方法对动态力矩连续预测的准确性和实用性,方法可以应用于外骨骼机器人、康复训练评估等人机交互设备中。

参考文献

- [1] 徐瑞,李志才,王雯婕,等. 基于肌电的人机交互控制策略及其应用与挑战[J]. 电子测量与仪器学报, 2020,34(2):1-11.
XU R, LI ZH C, WANG W J, et al. Human-computer interaction control strategies based on electromyography and their applications and challenges [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(2):1-11.
- [2] SOSELIA D, WANG R, GUTIERREZ-FAREWIK E M. Lower-limb joint torque prediction using LSTM neural networks and transfer learning[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2022, 30: 600-609.
- [3] 石欣,范智瑞,张杰毅,等. 基于 LMS-随机森林的肌电信号下肢动作快速分类[J]. 仪器仪表学报, 2020, 41(6):218-224.
SHI X, FAN ZH R, ZHANG J Y, et al. Rapid classification of lower limb movements of EMG signals based on LMS-random forest [J]. Chinese Journal of Scientific Instrument, 2020,41(6):218-224.
- [4] CHAI Y, LIU K, LI C, et al. A novel method based on long short term memory network and discrete-time zeroing

neural algorithm for upper-limb continuous estimation using sEMG signals [J]. Biomedical Signal Processing and Control, 2021, 67: 102416.

- [5] LIU H, DONG W, LI Y, et al. An epidermal sEMG tattoo-like patch as a new human-machine interface for patients with loss of voice [J]. Microsystems & Nanoengineering, 2020, 6(1): 701-826.
- [6] XU H, XIONG A. Advances and disturbances in sEMG-based intentions and movements recognition: A review[J]. IEEE Sensors Journal, 2021, 21(12): 13019-13028.
- [7] SHI X, QIN P, ZHU J, et al. Feature extraction and classification of lower limb motion based on sEMG signals[J]. IEEE Access, 2020, 8: 132882-132892.
- [8] LIU Y, GUO S, YANG Z, et al. A home-based bilateral rehabilitation system with sEMG-based real-time variable stiffness[J]. IEEE Journal of Biomedical and Health Informatics, 2020, 25(5): 1529-1541.
- [9] 张小栋,陈江城,尹贵. 下肢康复机器人肌电感知与人机交互控制方法[J]. 振动. 测试与诊断, 2018, 38(4):649-657,866.
ZHANG X D, CHEN J CH, YIN G. An approach for human-robot interactive control of lower limb rehabilitation robot based on surface EMG perception[J]. Journal of Vibration, Measurement & Diagnosis, 2018,38(4):649-657,866.
- [10] ZHANG L, LI Z, HU Y, et al. Ankle joint torque estimation using an EMG-driven neuromusculoskeletal model and an artificial neural network model[J]. IEEE Transactions on Automation Science and Engineering, 2020, 18(2): 564-573.
- [11] 熊保平,史武翔,林昱,等. 基于 Hill 肌肉模型的人体关节力矩智能预测[J]. 北京生物医学工程, 2021, 40(1):11-23.
XIONG B P, SHI W X, LIN Y, et al. Human joint moment prediction based on artificial neural network[J]. Beijing Biomedical Engineering, 2021,40(1):11-23.
- [12] LAM S K, VUJAKLIJA I. Joint torque prediction via hybrid neuromusculoskeletal modelling during gait using statistical ground reaction estimates: An exploratory study[J]. Sensors, 2021, 21(19): 6597.
- [13] JALI M H, IZZUDDIN T A, BOHARI Z H, et al. Predicting EMG based elbow joint torque model using multiple input ANN neurons for arm rehabilitation[C]. 2014 UKSim-AMSS 16th International Conference on Computer Modelling and Simulation, IEEE, 2014: 189-194.

- [14] GHISLIERI M, AGOSTINI V, KNAFLITZ M. Muscle synergies extracted using principal activations: Improvement of robustness and interpretability[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2020, 28(2): 453-460.
- [15] 杨毅, 彭玉鑫, 郝增明, 等. 复杂人体运动冗余控制的肌肉协同理论研究进展与展望[J]. 体育科学, 2020, 40(12): 63-72.
- YANG Y, PENG Y X, HAO Z M, et al. Research progress and prospect of muscle synergies theory for redundancy control of complex human movement [J]. China Sport Science, 2020, 40(12): 63-72.
- [16] 乔俊飞, 董敬娇, 李文静. 改进的小脑模型神经网络及其在时间序列预测中的应用[J]. 北京工业大学学报, 2021, 47(6): 598-606.
- QIAO J F, DONG J J, LI W J. Improved cerebellar model neural network and its application in time series prediction [J]. Journal of Beijing University of Technology, 2021, 47(6): 598-606.
- [17] 万太平, 曾文华. 小脑模型神经网络研究和发展综述[J]. 杭州电子工业学院学报, 2003, 23(1): 75-79.
- WAN T P, ZENG W H. Research and development of CMAC: A survey [J]. Journal of Hangzhou Dianzi University, 2003, 23(1): 75-79.
- [18] LIN Q, CHEN S, LIN C M. An optimization method for the initial parameters selection of fuzzy cerebellar model neural networks in parametric fault diagnosis [J]. International Journal of Fuzzy Systems, 2020, 22(7): 2071-2082.
- [19] JIANG H Y, YU S Y, LIN C M, et al. Torque prediction of ankle joint from surface electromyographic using recurrent cerebellar model neural network[J]. Acta Polytechnica Hungarica, 2021, 18(8): 183-199.
- [20] 桂奇政, 孟明, 马玉良, 等. 基于肌肉协同激活模型的上肢关节运动连续估计[J]. 仪器仪表学报, 2016, 37(6): 1405-1412.
- GUI Q ZH, MENG M, MA Y L, et al. Continuous estimation for joint movements of upper limb based on

synergy activation model [J]. Chinese Journal of Scientific Instrument, 2016, 37(6): 1405-1412.

- [21] JIANG N, ENGLEHART K B, PARKER P A. Extracting simultaneous and proportional neural control information for multiple-DOF prostheses from the surface electromyographic signal [J]. IEEE Transactions on Biomedical Engineering, 2008, 56(4): 1070-1080.

作者简介



姜海燕(通信作者), 1998年于山东科技大学获得学士学位, 2005年于福州大学获得硕士学位, 2013年于福州大学获得博士学位, 现为福州大学副教授, 主要研究方向为生物医学信号检测与处理。

E-mail: jianghaiyan@fzu.edu.cn

Jiang Haiyan (Corresponding author) received her B. Sc. degree from Shandong University of Science and Technology in 1998, M. Sc. degree and Ph. D. degree both from Fuzhou University in 2005 and 2013, respectively. She is currently an associate professor at Fuzhou University. Her main research interests include biomedical signal detection and processing.



李竹韵, 2020年于沈阳建筑大学获得学士学位, 现为福州大学硕士研究生, 主要研究方向为智能检测与信号处理。

E-mail: 2207607708@qq.com

Li Zhuyun received her B. Sc. degree from Shenyang Jianzhu University in 2020. She is currently a M. Sc. candidate at Fuzhou University. Her main research interests include intelligent detection and signal processing.



陈艳, 2018年于厦门工学院获得学士学位, 2021年于福州大学获得硕士学位, 主要研究方向为生物医学检测与信号处理。

E-mail: 448046833@qq.com

Chen Yan received her B. Sc. degree from Xiamen Institute of Technology in 2018, and M. Sc. degree from Fuzhou University in 2021. Her main research interests include biomedical detection and signal processing.