

## 基于 VMD-ELMAN 的肌电信号对下肢关节角度预测

汪文淼

引用本文

汪文淼. 基于 VMD-ELMAN 的肌电信号对下肢关节角度预测[J]. 计算机科学, 2024, 51(3): 257-264.

WANG Wenmiao. Prediction of Lower Limb Joint Angle Based on VMD-ELMAN Electromyographic Signals [J]. Computer Science, 2024, 51(3): 257-264.

---

### 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于全局与局部特征的二阶段文档图像可见水印去除模型](#)

Two-stage Visible Watermark Removal Model Based on Global and Local Features for Document Images

计算机科学, 2024, 51(2): 172-181. <https://doi.org/10.11896/jsjcx.230600144>

[基于注意力机制和ConvLSTM的船舶交通流量预测算法](#)

Ship Traffic Flow Prediction Algorithm Based on Attention Mechanism and ConvLSTM

计算机科学, 2023, 50(11A): 230800067-7. <https://doi.org/10.11896/jsjcx.230800067>

[基于子图特征的节点排序算法](#)

Node Ranking Algorithm Based on Subgraph Features

计算机科学, 2023, 50(11A): 230100122-7. <https://doi.org/10.11896/jsjcx.230100122>

[基于改进D2Det尺度自适应目标检测算法研究](#)

Study on Scale Adaptive Target Detection Algorithm Based on Improved D2Det

计算机科学, 2023, 50(11A): 221100247-9. <https://doi.org/10.11896/jsjcx.221100247>

[基于核鲁棒流形非负矩阵分解和融合特征的柴油机故障诊断](#)

Diesel Engine Fault Diagnosis Based on Kernel Robust Manifold Nonnegative Matrix Factorization and Fusion Features

计算机科学, 2023, 50(6A): 220400128-8. <https://doi.org/10.11896/jsjcx.220400128>

# 基于 VMD-ELMAN 的肌电信号对下肢关节角度预测

汪文森

弗吉尼亚理工学院暨州立大学 弗吉尼亚州黑堡镇 24061

**摘要** 表面肌电信号(Surface Electromyography,sEMG)提前于人体动作产生,常用于预测人体行为运动意图。但由于其自身的非平稳性与时变特性,因此难以较为准确地预测人体下肢关节角度变化。文中研究人体下肢肌肉针对正常行走、上下楼梯这3种动作进行的肌肉选取,提出了一种VMD-ELMAN角度拟合算法,提高了表面肌电信号角度预测精度,增强了角度预测的实时性,为提升人与外骨骼设备人机融合度提供了有效的解决方案。实验结果表明,相比常见角度拟合算法,所提算法的时间耗时较短,在3种常见动作中,髋关节角度预测值RMSE的最高精度达0.5789,膝关节角度预测值RMSE均在0.2以内,预测精度均优于常见模型,模型鲁棒性强。

**关键词:** 人机融合; sEMG; 特征提取; 角度预测; elman神经网络

**中图分类号** TN911.72

## Prediction of Lower Limb Joint Angle Based on VMD-ELMAN Electromyographic Signals

WANG Wenmiao

Virginia Tech and State University School of Engineering, Blackburg, Virginia 24061, USA

**Abstract** Surface electromyography(sEMG) signals are generated in advance of human movements and are commonly used to predict human behavior and motor intentions. However, due to its inherent non-stationary and time-varying characteristics, it is difficult to accurately predict changes in the angle of human lower limb. This paper presents a VMD-ELMAN angle fitting algorithm for muscle selection of human lower limb muscles for three movements: normal walking, ascending stairs and descending stairs. This algorithm improves the accuracy of surface electromyography signal angle prediction, enhances the real-time performance of angle prediction, and provides an effective solution for improving human-machine integration with exoskeleton devices. The Experimental results show that compared to common angle fitting algorithms, the proposed algorithm is less time-consuming. Among the three common movements, the highest accuracy of the hip joint angle prediction value RMSE is 0.5789, and the knee joint angle prediction value RMSE is within 0.2. Its prediction accuracy is superior to common models, and the model has strong robustness.

**Keywords** Human-Machine fusion, sEMG, Feature extraction, Angle prediction, Elman neural network

表面肌电(Surface Electromyography, sEMG)是动作电位(Motor Unit Action Potential, MUAP)在肌肉纤维和细胞组织中传导叠加的综合结果<sup>[1]</sup>。表面肌电信号采集因具有无创伤性,已经成为目前广泛运用于人体肌电信号采集的接口技术<sup>[2]</sup>。同时由于其提前于人体动作约150ms产生的生理特性,相比滞后于人体动作行为的惯性运动单元信号(Inertial Motionunit, IMU)信号,具有更强的实时性,因此常作为控制信号,实现对人体辅助外骨骼设备的运动控制<sup>[3-6]</sup>。

在制造业、物流业等领域内,助力外骨骼机器人受到国家各部委的广泛关注,成为了科技创新规划方向之一<sup>[7]</sup>。助力外骨骼机器人区别于医疗康复外骨骼机器人,其更加注重人机协同融合度,否则易威胁到人身安全与财产损失。因此,如何准确估计人体运动意图,实现连续关节角度预测成为提升助理外骨骼机器人的关键难点问题。

表面肌电信号具有非平稳性、时变等特点,且sEMG

信号能够优先于人体动作行为产生,有效解决了IMU信号的滞后性问题,因此成为了当今外骨骼控制信号的研究热点。但由于sEMG信号作为生理信号,易受到人体当前状态等多因素的影响,无法准确构建表面肌电信号与人体行为意图映射解码数学模型<sup>[8]</sup>,因此在该领域中常采取神经网络回归模型来进行人体运动意图预测<sup>[9-12]</sup>。

在特征提取方面,大部分研究团队主要采取时频域分析方法。Cai等<sup>[13]</sup>通过提取RMS、VAR等时域信号对表面肌电信号进行特征提取,并进行动作分类,其分类准确率为94.18%。Babita等<sup>[14]</sup>通过小波包对sEMG信号进行特征提取,采取线性SVM进行动作分类,分类准确率为91.1%。

在角度预测方面,Chen等<sup>[15]</sup>基于Hill肌肉模型建立了sEMG与膝关节运动力矩关系模型,能够初步实现膝关节运动力矩有效解码,但由于模型涉及参数较多,且部分参数涉及到微观运动力学特性,而微观动力学特性参数难以量化,影响

结果的鲁棒性。近年来,机器学习等算法在角度预测中取得了不错的效果。Wang 等<sup>[16]</sup>采用下肢表面肌电信号与加速度信号进行多模融合作为输入,运用 GA-Elman 模型预测下肢关节角度,但是在人体运动速度较慢时才能取得较高的预测精度。Wang 等<sup>[17]</sup>提出了一种 GA-GRNN 神经网络进行膝关节角度预测,该方法可以解决人工随机超参数导致角度预测精度偏移的问题。Deng 等<sup>[18]</sup>提出了主成分分析(PCA)与正则化极限学习机(RLEM)的连续运动估计模型,其均方根误差(RMSE)为 8.478。Wang 等<sup>[19]</sup>提出了一种小波包分解的特征提取方法,并通过 RLEM 模型进行预测,预测精度达 96.23%。Tang 等<sup>[20]</sup>提出了一种基于一阶微分信号滑动窗能量值法进行特征提取,采取 BP 神经网络进行角度估计,膝关节角度误差为 3.25%~11.65%。Xi 等<sup>[21]</sup>通过提取表面肌电信号的活跃段,运用主成分分析的方法进行关节运动解耦,建立高阶多项式对关节进行运动意图预测。

然而,为达到更好的人机融合效果,需在保证角度预测精度的情况下,借助表面肌电信号提前于人体 150ms 产生的生理特性,尽可能地实现关节角度预测。

本文提出了 VMD-ELMAN 肌电信号下肢关节角度预测模型,运用肌电信号提前于人体动作作为产生的特性,实现高精度人体关节角度解码。在平地行走、上下楼梯 3 种常见行为动作中,本文算法髌关节角度预测值 RMSE 最高精度达 0.5789,膝关节角度预测值 RMSE 均在 0.2 以内,预测精度均优于常见模型,模型鲁棒性强。

## 1 数据预处理

### 1.1 数据采集

本文采用英国 Biometrics 公司研发的 Biometrics Ltd. 表面肌电信号采集系统对 10 位受试者进行表面肌电信号采集,采样频率为 500 Hz,10 名受试者均为成年男性,年龄在 21~28 岁之间,体脂率为 16±3% 左右。关节角度采用英国 Biometrics 公司研发的 W150 蓝牙角度传感器,传输时延小于 3ms,采样频率为 500 Hz。

本实验选取 12 块肌电信号传感器对受试者进行采集,如图 1 所示。其中 12 块肌肉分别为:缝匠肌(SR)、股直肌(RF)、股外侧肌(VL)、股内侧肌(VM)、股薄肌(GC)、股二头肌(BF)、半腱肌(ST)、半膜肌(SM)、外侧腓肠肌(LG)以及内侧腓肠肌(MG)。




图 1 肌电信号位置示意图

Fig. 1 Schematic diagram of myoelectric signal location

### 1.2 实验设计

为尽可能减少实验者生理因素等情况的干扰,受试者在

实验之前经过了一段时间佩戴传感器适应性训练,以保证数据采集的有效性。

同时为了保证实验的泛化性,避免因为长时间数据采集导致受试者出现疲劳与心理疲惫等对结果造成的干扰,针对平地行走、上楼梯、下楼梯 3 种动作,每天每个动作采样次数为 30 次,每次采样时间不超过 1h,一共采样 10 天,得到 3000 组样本数据进行训练。

## 2 数据特征提取

### 2.1 变分模态分解原理

表面肌电信号具有非线性、非平稳性的特性,变分模态分解(Variational Mode Decomposition, VMD)是一种自适应完全递归的模态切分与信号处理的方法,可以有效降低复杂度、非线性强的时间序列的非平稳性<sup>[22]</sup>,通过模态分解得到不同频率尺度的子序列。VMD 将原始肌电信号分解成为  $K$  个调幅和调频信号,目标是使每个模态的估计带宽之和最小。

1) 原始信号  $x(t)$  可以直接定义为:

$$x(t) = \sum_{k=1}^K u_k(t) \quad (1)$$

2) 对于每一个模式函数,通过 Hilbert 变换,可以得到分析信号的单边频谱。

$$\left[ \delta(t) + \frac{j}{\pi t} \right] u_k(t) \quad (2)$$

其中,  $\delta(t)$  为狄拉克函数;  $k$  为需要分解的模态个数。

3) 对于每一个模式函数  $u_k(t)$ ,通过混叠模式函数  $u_k(t)$  的中心频率  $\omega_k$  的指数项  $e^{-j\omega_k t}$ ,可以得到每个模态频谱调制后的基本频带。

$$\left\{ \left[ \delta(t) + \frac{j}{\pi t} \right] u_k(t) \right\} e^{-j\omega_k t} \quad (3)$$

使用高斯平滑的方法估计每个模式信号的带宽,解决了约束条件下的变分问题,目标函数为:

$$\begin{cases} \min_{\{u_k, \omega_k\}} \left\{ \sum_k \|\partial_t \left\{ \left[ \delta(t) + \frac{j}{\pi t} \right] u_k(t) \right\} e^{-j\omega_k t} \right\|^2 \right. \\ \left. \text{s. t. } \sum_k u_k = f \right. \end{cases} \quad (4)$$

其中,  $\{u_k\} = \{u_1, \dots, u_k\}$ ;  $\{\omega_k\} = \{\omega_1, \dots, \omega_k\}$ ;  $\partial_t$  为对  $t$  求偏导;  $f$  为分解前的原始复信号。

对于上述变分问题,求解过程如下:

二次惩罚因子  $\alpha$  和拉格朗日乘法算子  $\lambda(t)$  引入式(4),将约束变分问题转换为非约束变分问题。其中超参数惩罚因子  $\alpha$  主要保证信号的重构精度,而  $\lambda(t)$  则保持了约束条件的严格性,因此将式(4)扩充成为拉格朗日表达式,具体如下:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \|\partial_t \left\{ \left[ \delta(t) + \frac{j}{\pi t} \right] u_k(t) \right\} e^{-j\omega_k t} \|^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (5)$$

使用乘法器的交替方向来计算式(5),通过交替迭代更新  $u_k^{n+1}, \omega_k^{n+1}, \lambda_k^{n+1}$  来不断地进行优化,从而得到式(5)的最优解。其中,通过傅里叶变换可以将  $u_k^{n+1}$  变换到频域,得到:

$$\hat{u}_k^{n+1}(\omega) = \arg \min_{\hat{u}_k, \omega_k \in X} \left\{ \alpha \left\| j\omega \left[ [1 + \text{sgn}(\omega + \omega_k)] \right] \cdot \hat{u}_k(\omega + \omega_k) \right\|^2 + \left\| f(\omega) - \sum_i \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2} \right\|^2 \right\} \quad (6)$$

其中,  $X$  为  $\hat{u}_k$  和  $u_k$  的约束条件, 即  $\sum_k u_k = f$ ; 二次惩罚因子  $\alpha$  的主要目的是降低高斯噪声的信号干扰;  $\hat{\lambda}(\omega)$  作为整个噪声信号的容忍度, 主要用于保证分解之后的信号不失真;  $\hat{f}(\omega)$  作为  $f(\omega)$  的傅里叶变换;  $\hat{u}_i(\omega)$  作为  $u_k(t)$  的傅里叶变换。

通过傅里叶变换可以将式(6)变换到频域, 进而可以求得  $\hat{u}_k^{n+1}(\omega)$  的解为:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_i \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (7)$$

按照相同的过程, 得到中心频率的更新方法。

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_i(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_i(\omega)|^2 d\omega} \quad (8)$$

其中,  $\hat{u}_k^{n+1}(\omega)$  为  $\hat{f}(\omega) - \sum_i \hat{u}_i(\omega)$  的维纳滤波器;  $\omega_k^{n+1}$  为电流模式函数下的功率谱重心。

## 2.2 PSO 粒子群优化算法

粒子群优化算法 (Particle Swarm Optimization, PSO) 属于一种进化算法, 从随机解出发, 通过迭代寻求最优解。在搜索过程中, 粒子群会保留环境历史记忆信息, 即位置、速度以及当前情况下的最优解。在每次迭代过程中, 通过粒子所在位置与速度来进行迭代计算, 其中速度对粒子的影响权重最大。

标准 PSO 的速度和位置的计算式如下:

$$v_i^{(t+1)} = \omega_1 v_i^{(t)} + c_1 r_1 [p_{\text{best}} - x_i^{(t)}] + c_2 r_2 [g_{\text{best}} - x_i^{(t)}] \quad (9)$$

$$x_i^{(t+1)} = x_i^{(t)} + v_i^{(t)} \quad (10)$$

其中,  $\omega_1, c_1, c_2$  均为控制参数,  $c_1, c_2$  为加速系数,  $\omega_1$  为惯性权重;  $v_i^{(t)}$  为当前迭代批次中第  $i$  个粒子的速度;  $p_{\text{best}}$  为粒子最佳位置;  $g_{\text{best}}$  为群体最佳的位置;  $x_i^{(t)}$  为第  $i$  个粒子的位置信息;  $r_1, r_2$  为  $[0, 1]$  随机变量。

在 VMD 算法中, 由于  $K$  值需要手动设置, 而且  $K$  值的大小对 VMD 滤波降噪效果的影响较大, 因此采取 PSO 算法, 以排列熵为 PSO 的适应度函数。

$$H(m) = - \sum_{j=1}^K P_j \ln P_j \quad (11)$$

排列熵表征时间序列的复杂度, 复杂度越高, 熵值越大。

因此, 在 PSO 寻找最优解时, 选择排列熵作为适应度函数, 目标函数为搜寻排列熵最小的  $K$  与  $\alpha$  的取值, 肌电信号滤波的具体流程如图 2 所示。

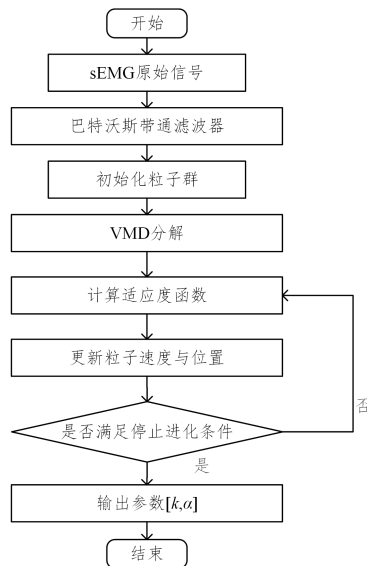


图 2 PSO 算法优化 VMD 参数的流程图

Fig. 2 Flowchart of VMD parameter optimization by PSO algorithm

## 2.3 Elman 神经网络原理

Elman 神经网络是一种局部动态回归神经网络, 它将一层连接层添加到前馈网络的隐含层中, 作为下一阶段的延迟值, 实现了对网络的存储性。反馈网络的动态学习特征, 使得神经网络具有较强的适应性, 可以直接反映系统动态学习过程。Elman 神经网络的输入层、隐含层、输出层的连接类似于前馈网络, 输出层单元用于传输信号, 隐含单元用于函数激活, 输出单元用于线性加权<sup>[22]</sup>进而确定权重。Elman 的承接层用于记忆前一个时刻隐含层的输出值, 并将其返回到网络输入, 从而增强了网络的动态处理能力, 能够以任意精度去逼近非线性映射。因此, 利用 Elman 神经网络可以实现基于 sEMG 信号的下肢关节角度预测。

Elman 神经网络在结构上较 BP 多了一个构成局部反馈的承接层, 因此整个网络具备了动态映射的能力, 从而让系统在预测时能够适应 sEMG 信号的非线性特征。Elman 神经网络的结构如图 3 所示。




图 3 Elman 神经网络结构图

Fig. 3 Diagram of Elman neural network structure

在图 3 中,有  $N$  个下肢表面肌电信号样本特征值,该模型的输入层向量数对应  $U_i$ ,隐含层节点数为  $L$ ,在网络计算时需要初始化网络各层的权重,其中隐含层的输入如式(12)所示:

$$net(t+1) = \sum_{i=1}^N \omega_i(t) \xi_i(t), \xi_i(t) = u_i(t) \quad (12)$$

其中,  $net(t)$  作为每层的输入函数,将输入层的输出传递到隐含层得到隐含层输出,如式(13)所示:

$$x_n(t+1) = f(net(t+1)) \quad (13)$$

而  $f(x)$  是中间层神经元的传递函数,  $f(x)$  如式(14)所示:

$$f(x) = \frac{1}{1+e^{-x}} \quad (14)$$

在得到隐含层的输出后,通过承接层将其关联到隐含层的输入,隐含层的上一个节点的输出将作为承接层的输入。 $x_c$  将作为  $n$  维反馈状态向量,实现隐含层与承接层的连接,如式(15)所示:

$$x_c(t) = f(net(t-1)) \quad (15)$$

进而可以通过式(16)得到输出层的输入,  $\omega_3$  为中间层到输出层的连接权重。

$$net(t+1) = \sum_{i=1}^N \omega_3(t+1) x_n(t+1) \quad (16)$$

最终可以根据前向传递的输入值得到输出层的输出,如式(17)所示:

$$y(t+1) = g(net(t+1)) \quad (17)$$

在得到一次网络输出后,需要根据误差函数式(18)计算出每次迭代的误差,然后更新权值,以达到输出误差最小化的目的误差函数如式(18)所示:

$$E(\omega) = \sum_{i=1}^N (y_k(\omega) - \tilde{y}_k(\omega))^2 \quad (18)$$

本文采用三层 Elman 神经网络构建角度预测模型,将 3 个肌肉通道对应的 sEMG 特征值作为输入向量,膝关节、髋关节角度作为输出向量分别构建基于 Elman 神经网络的髋关节、膝关节角度预测模型。

### 3 实验

#### 3.1 巴特沃斯带通滤波

人体 sEMG 信号具有低幅值与低频的特点,在传导过程中容易掺杂心电信号、部分无关肌肉信号,且在被电极检测到之前需要经过皮肤组织,容易造成信号的衰减与畸变,在检测过程中引入的 50 Hz 工频干扰也会对表面肌电信号造成影响。在实际的表面肌电信号采集过程中,sEMG 信号往往含有不同程度的心电噪声,若直接利用初始 sEMG 信号进行特征提取会对角度预测精度造成干扰,故需要通过滤波器将初始表面肌电信号的频率控制在 50~150 Hz 并过滤噪声点。由于在低频信号的平滑处理中,巴特沃斯滤波器具有较好的效果,其通带和阻带频率响应具有单调下降的特性,并且通带的频率特性曲线较为平滑。因此,根据表面肌电信号的低频特性,利用巴特沃斯滤波器可以实现 sEMG 信号的降噪滤波。基于巴特沃斯幅频特性和表面肌电信号频率的特点,本文设计的巴特沃斯滤波器通带频率设置为 50~150 Hz,阻带

频率设置为 40~160 Hz,通带衰减设置为 4 dB,阻带衰减设置为 20 dB,以平地行走下的肱二头肌为例,得到如图 4 所示的降噪前后肌电信号时域图。




图 4 滤波前后 sEMG 信号时域对比结果

Fig. 4 Time domain comparison results of sEMG signals before and after filtering

通过对滤波前后的肌电信号进行傅里叶变换可以得到如图 5 所示的频谱图。

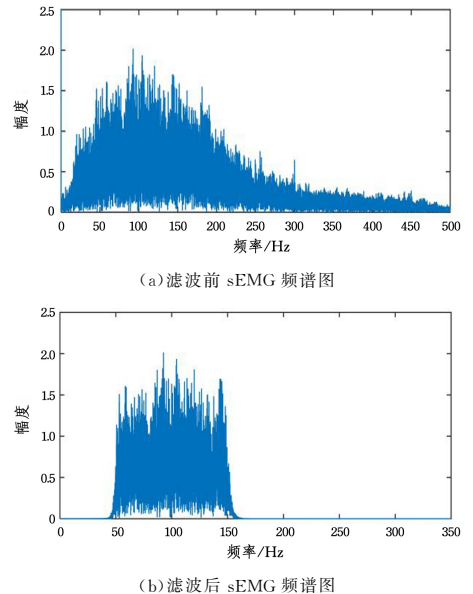


图 5 滤波前后 sEMG 信号频谱对比结果

Fig. 5 Comparison results of sEMG signal spectrum before and after filtering

根据图 5(a)可以看出,初始 sEMG 信号存在着较大的噪声干扰,导致 sEMG 信号的频率较大,并不能满足研究所需的频率要求。利用巴特沃斯滤波器实现对 sEMG 信号滤波降噪后,从图 5(b)可以看到,滤波后的 sEMG 信号频率将均匀分布在 50~150 Hz 之间,并且滤波后的肌电信号更加平滑。因此,采用巴特沃斯滤波器可以实现 sEMG 信号的降噪预处理,对滤波后的数据进行特征提取能够有效保证特征值与角度预测值的准确性。

#### 3.2 基于变分模态分解的 sEMG 特征提取

针对肌电信号非平稳、非线性的统计特征,常用的分析方法有时域分析、频域分析、时频域分析。而时频域的特征提取方法通过分析信号在时间和频率的联合分布来描述其在各个

时间段和频率下的特征值,通过时频分析可以得出 sEMG 信号在各个时刻的瞬时频率和信号幅值。VMD 分解可以对表面肌电信号的高频与低频能量进行有效分离,通过不断寻找分解出每个 IMF 分量的最优中心频率及带宽来实现自适应特征提取。利用 VMD 方法对选取出的动作肌肉块的 sEMG 肌电信号进行时域特征提取,输入的 sEMG 信号均需要经过巴特沃斯滤波器滤波降噪,以平地行走时的股二头肌的 sEMG 信号为例,经过 VMD 分解后波形如图 6 所示。




图 6 VMD 分解结果

Fig. 6 VMD decomposition results

通过对 VMD 分解后的肌电信号变分模态分量进行傅里叶变换,可以得到如图 7 所示的频谱图。

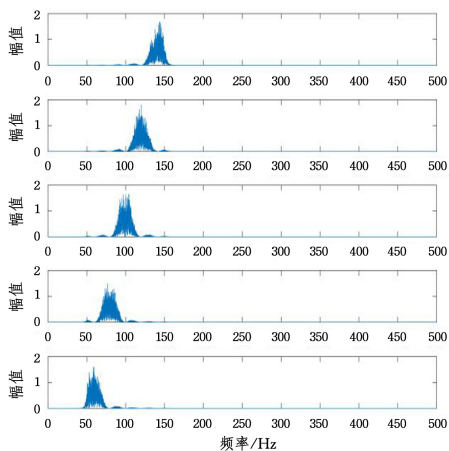


图 7 VMD 分量频谱结果

Fig. 7 VMD component spectrum results

通过图 6 和图 7 可以看出,VMD 算法经过参数寻优后可以将表面肌电信号分解为 5 个特征分量,且 5 个分量的频率均分布在 50~150 Hz 之间。由此可以看出,VMD 分解可以较好地保留高频信号,不仅可以有效地对高频分量进行特征提取,还可以自动保存与原始信号频率相同的分量,避免冗余信号的干扰。5 个 VMD 分量都较好地保留了肌电信号的频率特征,因此可以将 VMD 分解的 5 组分量作为角度预测特征量。

### 3.3 评价指标

仅根据预测曲线与实际曲线的拟合度无法准确评估模型

的准确性。为了定量评价模型的预测性能,本文采用均方根误差(Root Mean Square Error, RMSE)、平均绝对百分误差(Mean Absolute Percentage Error, MAPE)作为衡量预测模型精度的指标,相对误差作为 RMSE, MAPE 的计算式如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{R}(i) - R(i))^2} \quad (19)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|\hat{R}(i) - R(i)|}{R(i)} \times 100\% \quad (20)$$

### 3.4 VMD-ELMAN 模型预测结果

sEMG 信号可以通过 VMD 方法特征提取得到最优特征值,然后将特征值代入 ELMAN 神经网络进行角度预测,基于 sEMG 信号与角度数据最终可以得到如图 8—图 13 所示的角度预测图。通过对比 3 种动作下 VMD-ELMAN 模型的预测结果,可以直观得到预测值与实际值的变化趋势。在本文所有角度预测图中,蓝色曲线表示预测角度值,红色曲线表示实际角度值。

将平地行走、上楼梯以及下楼梯的肌肉通道的 sEMG 信号取 VMD 特征数据、髋关节和膝关节的角度值代入 ELMAN 预测模型,可以得到如图 8—图 10 所示的髋关节角度拟合结果。




图 8 平地行走髋关节角度拟合结果(电子版为彩图)

Fig. 8 Fitting results of hip joint angle during flat walking




图 9 上楼梯时髋关节角度拟合结果(电子版为彩图)

Fig. 9 Hip joint angle fitting results when ascending stairs




图 10 下楼梯时髋关节角度拟合结果(电子版为彩图)

Fig. 10 Fitting results of hip joint angle when descending stairs

从图 8—图 10 可以看出,基于 VMD 特征值与 ELMAN 神经网络得到的预测角度曲线变化趋势与实际角度变化趋势相符合。由于人体在完成平地行走、上楼梯、下楼梯时动作的变化会对角度有所影响,导致预测曲线在局部细节上与实际曲线存在偏差,但是整体可以保持对实际变化趋势的跟随,尤其是在上楼梯、下楼梯这类动作大幅度变化的情况下依然可以实现较好的角度跟随,其中在完成平地行走和下楼梯前半段动作时预测曲线与实际曲线的变化趋势整体上基本重叠,没有出现明显偏差。说明 VMD-ELMAN 不仅可以实现髋关节角度预测,而且在面对不同动作下的角度变化时展现了较好的适应性。

为了突出显示本文方法的精度,本文选取 3 种预测模型与本文方法进行对比,分别比较各类动作在不同模型下的关节角度预测 RMSE 值,其中 3 种分别选择 20 组数据进行实验,而每组数据将会重复 10 次实验取其预测结果的平均值计算该模型下 RMSE 值,得到如表 1 所列的髋关节角度预测 RMSE 结果。

表 1 基于 VMD 特征值的髋关节角度预测结果

Table 1 Hip joint angle prediction results based on VMD feature values

动作	预测模型	RMSE	MAPE/%
平地行走	VMD-BP	2.1084	4.67
	VMD-LSTM	1.9873	3.79
	VMD-ELM	2.0647	4.05
	VMD-ELMAN	1.7891	2.89
上楼梯	VMD-BP	1.7915	2.54
	VMD-LSTM	1.6255	1.81
	VMD-ELM	1.0682	1.36
	VMD-ELMAN	0.5789	0.67
下楼梯	VMD-BP	2.4838	3.32
	VMD-LSTM	1.9522	2.83
	VMD-ELM	1.2462	1.37
	VMD-ELMAN	0.6051	0.89

通过表 1 可以看出,4 组模型的 RMSE 均小于 2.5,说明以上模型的预测精度较高。在 4 组模型中基于 VMD-BP 模型的预测精度最低,而本文采用的 VMD-ELMAN 模型相比 VMD-BP, VMD-LSTM, VMD-ELM 的精度更高,在平地行走动作下 VMD-ELMAN 的 MAPE 较 VMD-BP 提升了 1.78%,在上楼梯动作下 VMD-ELMAN 模型相比 VMD-BP 的 MAPE 提升了 1.87%,在下楼梯动作下 VMD-ELMAN 模型相比 VMD-BP 的 MAPE 提升了 2.43%,预测精度远远高于另外 3 种模型,且面对动作幅度较大的上下楼梯时,VMD-ELMAN 模型的精度也优于另外 3 种模型,说明了本文方法的有效性。

由于下肢在运动过程中是多关节配合完成相应动作的,因此关节角度特征间存在差异。为了验证 VMD-ELMAN 预测模型的泛化性,本文将通过 sEMG 信号与膝关节角度数据对预测模型进行验证,得到如图 11—图 13 所示的 3 种动作下 VMD-ELMAN 预测角度的结果。




图 11 平地行走膝关节角度拟合结果(电子版为彩图)

Fig. 11 Fitting results of knee joint angle for walking on flat ground




图 12 上楼梯时膝关节角度拟合结果(电子版为彩图)

Fig. 12 Knee joint angle fitting results when climbing stairs




图 13 下楼梯时膝关节角度拟合结果(电子版为彩图)

Fig. 13 Knee joint angle fitting results when descending stairs

从图 10—图 13 可以看出,基于 VMD 特征值与 ELMAN 神经网络得到的膝关节预测角度曲线变化趋势与实际角度变化趋势相符合,说明 VMD-ELMAN 模型可以实现不同动作下的膝关节角度预测,在完成平地行走、上楼梯、下楼梯时,VMD-ELMAN 模型对不同动作下的角度变化有较好的适应性,由于膝关节和髋关节在运动时肌肉发力顺序不同,导致角度的变化有差异,膝关节的细节变化更为剧烈。由于膝关节在完成复杂运动时局部角度变化幅度较小,因此膝关节的角度预测容易陷入局部最小值,对模型的要求更高。而经过 VMD-ELMAN 预测模型后,3 种动作下的膝关节角度预测曲线与实际角度曲线间没有出现明显偏差,角度预测无滞后性,其中上楼梯后半段步态和下楼梯前半段步态处的角度预测存在明显震荡,但是整体能够保持有效精度的跟随,说明 VMD-ELMAN 不仅可以实现膝关节角度预测,而且在面对不同动作下的角度变化时展现了较好的适应性。

同样地,为了比较基于 VMD-ELMAN 模型的膝关节角度预测精度,本文计算了 4 种模型下的 RMSE 与 MAPE,如表 2 所列。

表 2 基于 VMD 特征值的膝关节角度预测结果

Table 2 Knee joint angle prediction results based on VMD feature

		values	
动作	预测模型	RMSE	MAPE/%
平地行走	VMD-BP	0.4224	5.53
	VMD-LSTM	0.3972	5.04
	VMD-ELM	0.3662	4.26
	VMD-ELMAN	0.1857	2.84
上楼梯	VMD-BP	1.0915	5.54
	VMD-LSTM	1.0642	4.85
	VMD-ELM	0.8771	2.97
	VMD-ELMAN	0.1966	1.95
下楼梯	VMD-BP	0.4741	5.58
	VMD-LSTM	0.3946	4.26
	VMD-ELM	0.3358	3.97
	VMD-ELMAN	0.2199	2.13

为保证实验精度,本文采集 100 ms 的肌电信号数据,共测试 100 次,求取平均时间,算法总用时(包含 100 ms 数据采集时间的损耗)如图 14 所示。从图 14 中可以看出,本文提出的 VMD-ELMAN 算法耗时最短,且包含 100ms 采集后,总耗时仅为 115 ms,低于肌电信号超前于人体运动 150ms,具有较高的应用价值。




图 14 各模型角度拟合的时间损耗

Fig. 14 Time loss for fitting angles of each model

通过表 2 可以看出,4 组模型的 RMSE 均小于 1.5,且膝关节角度的精度结果小于髋关节角度的结果。在 4 组模型中本文采用的 VMD-ELMAN 模型精度优于 VMD-BP, VMD-LSTM 以及 VMD-ELM 模型,在平地行走动作下 VMD-ELMAN 的 MAPE 较 VMD-BP 提升了 2.69%,在上楼梯动作下 VMD-ELMAN 模型相比 VMD-BP 的 MAPE 提升了 3.59%,在下楼梯动作下 VMD-ELMAN 模型相比 VMD-BP 的 MAPE 提升了 3.45%。与髋关节角度结果一样,在面对动作幅度较大的上下楼梯时,VMD-ELMAN 模型的精度也优于另外 3 种模型,说明本文方法可以实现较高精度的角度预测。

VMD-ELMAN 预测结果验证了本文模型对时序性的角度信号具有很好的效果,适合进行人体下肢关节角度预测;且该模型具有较强的适应性,可以基于不同动作的肌电信号完成对应动作下的角度预测。

**结束语** 本文针对肌电信号提前于人体动作行为 30~150 ms 产生的物理特性,提出了一种 VMD-ELMAN 人体下肢关节角度拟合模型,相比常见的时序性角度拟合模型,本文算法在上下楼梯与平地行走 3 种常见动作中, RMSE 精度提升了接近一倍,实现了较高精度的角度预测。本文算法在应用过程中,仍受到人体生理个体差异性的影响,需进一步提升泛化性。同时,本文采集 100 ms 数据,算法总耗时为 115 ms,

可进一步优化缩短时间,为外骨骼控制留下更多的电机反应时间,从而达到更高的人机融合效果。

在未来的研究中,将进一步在肌肉选取与特征提取等方面进行研究,选取最小肌肉数量以降低数据量的输入,选择最优特征数据来提高模型的精度与时间,使得算法能够更加稳定地应用于康复助力外骨骼应用中。

## 参考文献

- [1] LUCA C J D, ADAM A, WOTIZ R, et al. Decomposition of Surface EMG Signals[J]. Journal of Neurophysiology, 2006, 96(3): 1646-1657.
- [2] SUBASI A. Diagnosis of Neuromuscular Disorders Using DT-CWT and Rotation Forest Ensemble Classifier[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(5): 1940-1947.
- [3] PASINETTI S, LANCINI M, BODINI I, et al. A Novel Algorithm for EMG Signal Processing and Muscle Timing Measurement[J]. IEEE Transactions on Instrumentation & Measurement, 2015, 64(11): 2995-3004.
- [4] ZHONG W J, FU X M, ZHANG M M. A Muscle Synergy-Driven ANFIS Approach to Predict Continuous Knee Joint Movement[J]. IEEE Transactions on Fuzzy Systems, 2022, 30(6): 1553-1563.
- [5] SUKUMAR N, TARAN S, BAJAJ V. Physical actions classification of surface EMG signals using VMD[C]// Proceedings of the 2018 IEEE International Conference on Communication and Signal Processing (ICCSPP). Adhiparasakthi Engn Coll. Melmaruvathur, INDIA, 2018: 705-709.
- [6] LU Y, WANG H, ZHOU B, et al. Continuous and simultaneous estimation of lower limb multi-joint angles from sEMG signals based on stacked convolutional and LSTM models[J]. Expert Systems with Application, 2022, 203: 117340.
- [7] YANG C, LIN S, LUO Z, et al. sEMG-MMG State-Space Model for the Continuous Estimation of Multijoint Angle[J]. Complexity, 2020, 2020: 1-12.
- [8] XIAO F, WANG Y, GAO Y, et al. Continuous estimation of joint angle from electromyography using multiple time-delayed features and random forests[J]. Biomedical Signal Processing and Control, 2018, 39: 303-311.
- [9] TRIWIYANTO T, WAHYUNGGORO O, NUGROHOH A, et al. Muscle fatigue compensation of the electromyography signal for elbow joint angle estimation using adaptive feature[J]. Computers & Electrical Engineering, 2018, 71: 284-293.
- [10] MA S, LV B, LIN C, et al. EMG Signal Filtering Based on Variational Mode Decomposition and Sub-Band Thresholding[C]// IEEE Journal of Biomedical and Health Informatics. 2021: 47-58.
- [11] GAO Y, LUO Y, ZHAO J, et al. sEMG-angle estimation using feature engineering techniques for least square support vector machine[J]. Technology and Health Care, 2019, 27: 31-46.
- [12] MALGHAN P G, HOTA M K. Grasshopper optimization algorithm based improved variational mode decomposition technique for muscle artifact removal in ECG using dynamic time war\*\*

- [J]. Biomedical Signal Processing and Control, 2022, 73: 103437.
- [13] CAI S Q, CHEN Y, HUANG S Y, et al. SVM-Based Classification of sEMG Signals for Upper-Limb Self-Rehabilitation Training[J]. Frontiers in Neurobotics, 2019, 13: 31.
- [14] BABIT A, KUMARI P, NARAYAN Y, et al. Binary movement classification of sEMG signal using linear SVM and wavelet packet transform[C]//2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES). 2016: 1-4.
- [15] CHEN J C, ZHANG X D, LI R, et al. A prediction model for dynamic joint torque of lower limbs using surface electromyography signals [J]. Journal of Xi'an Jiaotong University, 2015, 49(12): 26-33.
- [16] WANG L P. Research on continuous motion estimation of multiple joints based on electromyography and acceleration [D]. Hangzhou: Hangzhou University of Electronic Science and Technology, 2020.
- [17] WAN F, YIN T, LEI C, et al. Prediction of lower limb joint angle using sEMG based on GA-GRNN[C]//in Proc. IEEE Int. Conf. Cyber Technol. Autom., Control, Intell. Syst. (CYBER). 2015: 1894-1899.
- [18] DENG Y, GAO F, CHEN H. Angle estimation for knee joint movement based on PCA-RELM algorithm [J]. Symmetry, 2020, 12(1): 130.
- [19] WANG J, WANG L, XI X, et al. Estimation and correlation analysis of lower limb joint angles based on surface electromyography[J]. Electronics, 2020, 9(4): 556.
- [20] TANG G, WANG H, TIAN Y. SEMG-based estimation of knee joint angles and motion intention recognition[C]//in Proc. 9th Int. Conf. Intell. Hum.-Mach. Syst. Cybern. (IHMSC). 2017: 390-393.
- [21] XI X, JIANG W, HUA X, et al. Simultaneous and Continuous Estimation of Joint Angles Based on Surface Electromyography State-Space Model [J]. IEEE Sensors Journal, 2021, 21(6): 8089-8099.
- [22] LIU Y B, WANG G, CHAI Y Y, et al. Application of Elman neural network in continuous estimation of elbow joint angle using surface electromyography [J]. Journal of Robot Surgery (Chinese English), 2021, 2(4): 295-305.



**WANG Wenmiao**, born in 2001, bachelor. His main research interest is computer science.

(责任编辑:喻藜)

## FCES2024 第一次筹备会议于沈阳召开

计算机教育关乎计算机学科的发展和人才培养,提升我国计算机本科教育的质量并且保持可持续发展的专业竞争力,是 CCF 未来计算机教育峰会(FCES)在 2017 年应运召开的使命。FCES 至今已举办七届。会议面向全国高校计算机教育领域校领导、学院院长、副院长、系主任和专家学者,近年来每届峰会都有近四百人参会,已经成为了计算机教育领域一场高规格的专业盛会。

FCES2024 第一次筹备会议于 2 月 29 日在沈阳航空航天大学召开。CCF 秘书长唐卫清,CCF 教育工委主任、FCES2024 程序委员会主席、上海交通大学教授臧斌宇,FCES2024 组织委员会主席、CCF 副秘书长束庆山,FCES2024 组织委员会共同主席、沈阳航空航天大学教务处长兼计算机学院院长范纯龙,FCES2024 赞助委员会主席、CCF 助理秘书长陈国威和项目组成员参加本次会议。

经会议讨论,正式确定峰会将于 2024 年 7 月 25-27 日在辽宁省沈阳市召开。会议将聚焦教育数字化发展,由 CCF 副理事长、中国科学院院士、清华大学教授胡事民担任大会主席,共设置 5 个大会特邀报告、5 个观点报告及 14 个分论坛,从不同维度探讨教育数字化的建设与发展。除此以外,本届峰会还将讨论课程体系与软件工程教育认证、计算机拔尖人才培养、交叉学科人才培养、教育公平化、教育科研化、思政教学、产教融合等多个方面的内容,持续为教育数字化赋能助力。

峰会报名将于近日开启,敬请密切关注 CCF 公众号和官方网站。

据 CCF 微信公众号