

基于VMD复合神经网络模型的手势动作预测

赵炼, 吴扬东, 邓智方, 李丰硕, 袁庆霓, 张太华

引用本文

赵炼, 吴扬东, 邓智方, 李丰硕, 袁庆霓, 张太华. 基于VMD复合神经网络模型的手势动作预测[J]. 计算机科学, 2025, 52(11): 166-174.

ZHAO Lian, WU Yangdong, DENG Zhifang, LI Fengshuo, YUAN Qingni, ZHANG Taihua. [Gesture Action Prediction Based on VMD Composite Neural Network Model](#) [J]. Computer Science, 2025, 52(11): 166-174.

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)

[基于加性秘密共享的轻量级隐私保护移动传感分类框架](#)

Lightweight Privacy-preserving Mobile Sensing Classification Framework Based on AddictiveSecret Sharing

计算机科学, 2025, 52(11): 415-424. <https://doi.org/10.11896/jsjcx.241100101>

[基于多粒度统计特征的僵尸网络流量智能检测方法](#)

Intelligent Botnet Traffic Detection Method Based on Multi-granularity Statistical Features

计算机科学, 2025, 52(11): 373-381. <https://doi.org/10.11896/jsjcx.241100019>

[一种3D可变形卷积结合Transformer的视频压缩感知方法](#)

Video Compressed Sensing Method with Integrated Deformable 3D Convolution and Transformer

计算机科学, 2025, 52(11): 150-156. <https://doi.org/10.11896/jsjcx.240800026>

[基于良性显著区域的端到端恶意软件对抗样本生成方法](#)

Benign-salient Region Based End-to-End Adversarial Malware Generation Method

计算机科学, 2025, 52(10): 382-394. <https://doi.org/10.11896/jsjcx.240800046>

[基于改进主动学习的入侵检测方法](#)

Intrusion Detection Method Based on Improved Active Learning

计算机科学, 2025, 52(10): 357-365. <https://doi.org/10.11896/jsjcx.240900142>

基于 VMD 复合神经网络模型的手势动作预测

赵 炼¹ 吴扬东¹ 邓智方¹ 李丰硕¹ 袁庆霓¹ 张太华²

1 贵州大学现代制造技术教育部重点实验室 贵阳 550025

2 贵州师范大学机械与电气工程学院 贵阳 550025

(1850005054@qq.com)

摘 要 表面肌电信号(Surface Electromyography,sEMG)常用于预测人体意图行为,是一种不平稳、非周期、含有噪声的生物电信号,容易受工频干扰、环境干扰等影响,导致对其进行预测存在一定难度。对此,提出了一种基于变分模态分解(Variational Mode Decomposition,VMD)和改进粒子群优化(Particle Swarm Optimization,PSO)算法的复合神经网络模型(Composite Neural Network Model,CNNM)。该模型结合了长短期记忆网络(Long-Short Term Memory,LSTM)、卷积神经网络(Convolutional Neural Networks,CNN)和双向长短期记忆网络(Bidirectional Long Short Term Memory,BiLSTM)。首先对 PSO 算法进行改进以优化 VMD 的参数,通过 VMD 处理 sEMG 信号,提出希尔伯特能量法,对分解后的分量进行加权重构,降低信号复杂性并保留关键特征。然后利用 LSTM 方法从 sEMG 信号中提取时间特征,利用 CNN 方法进一步提取空间特征,并通过注意力机制强化对关键信息的提取,最后输入 BiLSTM 中进行预测识别。实验结果表明,该模型的预测准确率可达 99.9%,相较于其他模型提高了 3%~8%,并通过消融实验验证了各模块的作用。该研究旨在提高手势动作的预测识别精度,为康复训练机器人的控制提供有效的解决方案。

关键词: 表面肌电信号;变分模态分解;卷积神经网络;长短期记忆网络;双向长短期记忆网络

中图分类号 TN911.72;TP183

Gesture Action Prediction Based on VMD Composite Neural Network Model

ZHAO Lian¹, WU Yangdong¹, DENG Zhifang¹, LI Fengshuo¹, YUAN Qingni¹ and ZHANG Taihua²

1 Key Laboratory of Advanced Manufacturing Technology of the Ministry of Education, Guizhou University, Guiyang 550025, China

2 School of Mechanical and Electrical Engineering, Guizhou Normal University, Guiyang 550025, China

Abstract sEMG is often used to predict human intention behavior. It is an unstable, non-periodic and noisy bioelectrical signal, which is easily affected by power frequency interference and environmental interference, so it is difficult to predict it. This paper proposes CNNM based on VMD and PSO algorithm. The model combines LSTM, CNN and BiLSTM. Firstly, the Ninapro dataset is used to optimize the parameters of VMD through the improved PSO algorithm, and the sEMG signal is processed by VMD. The decomposed components are weighted and reconstructed according to the Hilbert energy method, which reduces the complexity of the signal and retains the key features. Then, the LSTM method is used to extract the temporal features from sEMG signals, the CNN method is used to further extract the spatial features, and the attention mechanism is used to strengthen the extraction of key information. Finally, it is input into BiLSTM for prediction and recognition. Experimental results show that the prediction accuracy of the proposed model can reach 99.9%, and the prediction accuracy of CNNM is improved by 3%~8% compared with other models. Finally, the role of each module is verified by ablation experiments. This research aims to improve the prediction and recognition accuracy of gesture actions and provide an effective solution for the control of rehabilitation training robots.

Keywords Surface electromyography, Variational mode decomposition, Convolutional neural network, Long short-term memory network, Bidirectional long-short term memory network

在现代社会,中风、脊髓损伤等导致肢体功能障碍的疾病逐渐成为全球性健康挑战。流行病学研究表明,每年新增的

创伤患者超过 1000 万^[1]。这些患者无法自理日常活动,而传统康复治疗存在个性化不足及缺乏生物反馈等问题^[2]。为解

到稿日期:2024-10-21 返修日期:2025-03-09

基金项目:国家自然科学基金(72061006);贵州省科技支撑项目(黔科合支撑[2023]一般 094,[2020]4Y140)

This work was supported by the National Natural Science Foundation of China(72061006) and Guizhou Province Science and Technology Support Project(Guizhou Science and Technology Joint Support[2023]General 094,[2020]4Y140).

通信作者:吴扬东(ydwu@gzu.edu.cn)

决这些问题,帮助患者进行治疗的康复训练机器人应运而生^[3],其中基于表面肌电信号的康复训练机器人是当前的研究热点。表面肌电信号(sEMG)有效频率范围为 20~200 Hz,通过去除采集时受到的噪声干扰,提取表面肌电信号特征^[4],构建表面肌电信号与人体行为意图之间的数学模型,实现人体行为意图的预测识别^[5]。

在基于表面肌电信号的研究中,Huo 等^[6]提出了一种基于小波包变换和主成分分析的新方法,该方法在 6 种手部动作产生的 sEMG 数据集上进行测试,得出平均预测准确率为 96.03%;Zhang 等^[7]通过支持向量机对肌电-运动的映射关系进行训练,实现下肢髋、膝和踝 3 个关节矢状面内的连续运动预测,其预测均方根误差分别为 9.36°,10.82°和 6.87°。上述研究均使用机器学习算法,但机器学习算法依赖人工提取表面肌电信号特征,同时对数据预处理的要求较高,需要对表面肌电信号进行复杂的数据处理。

随着深度学习的发展,Triwiyanto 等^[8]开发了一种使用卷积神经网络(CNN)的深度学习分类器,提出的基于全方向 CNN 分类器的准确性优于其他传统分类器(96.8±1.87%)。Wei 等^[9]提出了一种基于双流卷积神经网络的肌电信号手势识别方法,将原始表面肌电信号离散小波变换系数与原始表面肌电信号分别作为双流卷积神经网络两个分支的输入。该方法在大规模基准数据集上的投票准确率分别达到了 97.9%,81.3%和 82.4%。深度学习算法实现了肌电信号特征的自动提取,但是其性能在很大程度上取决于训练数据的数量和质量。

为了提高表面肌电信号数据的质量和手势动作预测的准确性,本文提出了一种基于变分模态分解的数据处理方法,通过改进的粒子群优化算法实现对 VMD 参数 K 和 α 的寻优,创新性地使用 Herbilt 能量法实现对 VMD 分量的加权重构,提高了表面肌电信号的数据质量;同时,构建以 LSTM-CNN 为基础的肌电信号时空特征提取模块,引入注意力机制,强化对空间特征的提取,提高 Bi-LSTM 模型的手势动作预测准确性,并通过实验验证了所提方法的可行性。

1 数据

1.1 数据说明

本文的实验数据来自数据集 NinaPro¹⁾,该数据集目前包含 DB1-DB10 共 10 个完整数据集,包括截肢者和非截肢者的 sEMG 信号文件。本文使用的 DB1 数据集包括 27 名完整受试者重复 52 次手部动作以及休息的表面肌电信号和运动学数据。sEMG 数据使用 10 个 Otto Bock MyoBock 13E200 电极获取,受试者被要求重复在笔记本电脑屏幕上显示的动作,采集到的肌电信号是一个二维矩阵,横坐标是时间戳,纵坐标是电极通道,S1_A1_E1.mat 的 emg 数据形状为 (101 014,10),第 1-8 列是在桡肘关节高度处围绕前臂等距分布的电极,第 9 和第 10 列包含来自指浅屈肌和伸肌的主要活动

点的信号^[10]。实验分为 3 个练习,如表 1 所列。

表 1 DB1 数据集标签和手势动作

Table 1 DB1 dataset labels and gesture actions		
标签	练习分类	手势动作
0	—	休息阶段
1-12	练习 1	手指的基本动作
13-29	练习 2	等距、等张和基本的手腕运动
30-52	练习 3	抓握和功能性动作

1.2 数据选取

在上肢功能障碍患者群体中,由于运动障碍的表现形式具有高度的个体差异性,因此,精心选择实验数据对于准确评估和分析至关重要。考虑到实际应用场景,在下文的主要实验中,选取 DB1_s1 中的练习 2,并选择其中的 8 个手势动作进行实验,包含抓取、拿捏、紧握以及其他复杂动作,相应的动作如图 1 所示²⁾。



图 1 选取的实验动作

Fig.1 Selected experimental actions

为了验证所提出模型对于不同受试者的普适性和预测效果的一致性,本文在已有受试者肌电数据的基础上,进一步从 DB1 数据集中选取了 2 名男性和 3 名女性的表面肌电信号数据作为补充实验样本。利用这些新增的表面肌电信号数据进行实验,以评估模型在不同性别和个体间的预测性能。所有受试者的身高体重参数如表 2 所列³⁾。

表 2 实验者的基本数据

Table 2 Basic data of participants

受试者编号	性别	年龄	身高/cm	体重/kg
DB1_s1	男	31	170	75
DB1_s2	男	27	170	62
DB1_s3	男	22	180	85
DB1_s6	女	22	163	48
DB1_s8	女	27	164	54
DB1_s10	女	30	160	60

在表 2 所列的 6 名受试者中,所有个体的惯用手均为右手。为了进一步评估模型的预测能力,本文从编号为 DB1_s2,DB1_s3,DB1_s6,DB1_s8,DB1_s10 的 5 名受试者中选取了 4 种手势动作进行预测分析。这些手势动作的选择不仅基于实际生活中的需求,而且旨在减少重复性,以确保实验结果的广泛适用性和有效性。具体的手势动作标签如表 3 所列。

¹⁾ <http://ninapro.hevs.ch/>

²⁾ <http://ninapro.hevs.ch/>

³⁾ <http://ninapro.hevs.ch/>

表 3 选取的实验者动作标签

Table 3 Selected experimenter action labels

实验者序号	手动动作分类	动作标签
DB1_s1	练习 3	1,4,7,10,13,16,19,23
DB1_s2	练习 2	1,4,8,12
DB1_s3	练习 1	2,3,9,10
DB1_s6	练习 2	5,6,13,14
DB1_s8	练习 1	2,5,7,9
DB1_s10	练习 3	2,6,14,21

2 实验方法

2.1 变分模态分解

DB1 数据集在采集时经过全波段整流等数据处理,因此无需进行滤波处理。同时,在表面肌电信号领域,变分模态分解 VMD 能够起到滤波去噪的作用^[11]。VMD 是一种自适应、完全非递归的模态变分和信号处理的方法^[12]。该技术能够有效地分离固有模态函数(Intrinsic Mode Function,IMF),对信号进行频域划分,获得给定信号的有效分解成分,最终获得变分问题的最优解^[13]。

VMD 假定所有分量都是集中在各自中心频率附近的窄带信号,因此 VMD 根据分量窄带条件建立约束优化问题,从而估计信号分量的中心频率以及重构相应分量。

假设原始信号为 $f(t)$,该信号将被分解为多个分量,相应的变分模态模型如式(1)所示:

min_{\{u_k\},\{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * \mu_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \tag{1}

s. t. \sum_k \mu_k = f(t) \tag{2}

其中, $\{u_k\}$ 和 $\{\omega_k\}$ 为分解后模态分量及模态中心频率, $*$ 表示卷积运算, δ 为狄拉克分布, ∂ 为求偏导符号。

通过增广拉格朗日函数将上述约束优化问题等效为一个无约束问题,如式(3)所示:

L(\{\mu_k\},\{\omega_k\},\lambda) = \alpha \sum_K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * \mu_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k \mu_k(t) \rangle \tag{3}

其中, α 为惩罚因子,用于平衡模态数量和稀疏性; λ 为拉格朗日乘子,在 VMD 中用于平衡数据拟合度和模态平滑性。

求解该约束问题可通过交替方向乘子法 ADMM(Alternating Direction Method of Multipliers)来求解,其思想可简述为:固定另外两个变量,更新其中一个变量。具体如下:

u_k^{n+1} = \arg \min_{u_k} L(\{u_i^{n+1}_{i < k}\}, \{\omega_k^n\}, \lambda^n) \tag{4}

w_k^{n+1} = \arg \min_{w_k} L(\{u_k^n\}, \{\omega_{i < k}^{n+1}\}, \lambda^n)

\lambda^{n+1} = \lambda^n + \rho(f(t) - \sum_k u_k^{n+1}(t))

根据傅里叶变换的等效性,利用 Parseval 定理在频域内对 u_k^{n+1} , w_k^{n+1} 和 λ^{n+1} 进行求解,并对 u_k^{n+1} , w_k^{n+1} 和 λ^{n+1} 进行更新,当满足条件时,更新停止,迭代停止条件为:

\sum_{k=1}^K \frac{u_k^{n+1} - u_k^n}{u_k^n} < \epsilon \tag{5}

2.2 改进粒子群优化算法

粒子群优化算法(PSO)是一种基于群体智能的优化算法,其基本思想源于对鸟群觅食行为的研究,具有收敛速度

快、参数少、算法简单易实现的优点。

标准 PSO 的位置和速度的计算式如下:

v_i^{(k+1)} = \omega v_i^{(k)} + c_1 r_1 (p_{best_i} - x_i^{(k)}) + c_2 r_2 (g_{best_i} - x_i^{(k)}) \tag{6}

x_i^{(k+1)} = x_i^{(k)} + v_i^{(k+1)} \tag{7}

其中, ω 为惯性权重; c_1 和 c_2 为加速因子; $v_i^{(k)}$ 为当前迭代次数中第 i 个粒子的速度; p_{best_i} 为当前迭代次数中第 i 个粒子的最佳位置, g_{best_i} 为全局最佳位置; $x_i^{(k)}$ 为当前迭代次数中第 i 个粒子的位置; r_1 和 r_2 为 $[0,1]$ 内的随机数,可增加搜索的随机性。

在 VMD 分解中,分解数量 K 和惩罚因子 α 需要手动设定,而不同的场景下, K 和 α 对 VMD 分解的效果影响较大,因此使用 PSO 算法对其进行参数寻优^[14]。

在标准的 PSO 算法中, ω , c_1 , c_2 为固定值,容易导致寻优能力差、陷入局部最优等问题。因此将 ω , c_1 , c_2 进行相应的改进,以增强前期的全局搜索能力和后期的局部搜索能力。

ω 为改进的随机惯性权重,随机的惯性权重可以避免在迭代前期局部搜索能力不足,还能避免在迭代后期全局搜索能力不足。改进如式(8)所示:

\omega(k) = \omega_{min} - (\omega_{max} - \omega_{min}) \times rand \times 2\pi + \sigma \times randn \tag{8}

其中, $\omega_{max} = 0.9$, $\omega_{min} = 0.4$, $rand$ 为 $[0,1]$ 内均匀分布的随机数, $randn$ 为正态分布的随机数。

c_1 和 c_2 改用 Clerc 构造的收缩因子,采用这种调整方法选取参数可确保 PSO 算法的收敛性,并可取消对速度的边界限制。改进后的收缩因子法如下:

v_i^{k+1} = \varphi [\omega v_i^{(k)} + c_1 r_1 (p_{best_i} - x_i^{(k)}) + c_2 r_2 (g_{best_i} - x_i^{(k)})] \tag{9}

\varphi = \frac{2}{| (3 - C - \sqrt{C^2 - 4C}) |} \tag{10}

c_1 = c_2 = 2.05, C = c_1 + c_2 \tag{11}

在使用改进 PSO 算法优化 VMD 参数的过程中,使用最小包络熵作为适应度函数,计算式如下:

E_P = - \sum_{j=1}^N p_j \lg p_j \tag{12}

p_j = a(j) / \sum_{j=1}^N a(j) \tag{13}

包络熵代表原始信号的稀疏特性,当 IMF 中噪声较多、特征信息较少时,包络熵值较大;反之,则包络熵值较小。因此,在 PSO 寻找最优解时,以包络熵最小时的 K 和 α 作为目标函数。

2.3 引入注意力机制的复合神经网络模型(CNNM)

在该模型中,使用 VMD 对原始表面肌电信号数据进行分解,得到若干个固有模态函数,即分量,每个固有模态函数代表了原始肌电信号在不同频率和振幅上的成分。随后将这些分量进行加权重构,重构后的数据将作为混合神经网络模型(CNNM)的输入。这种处理方式更有利于捕捉信号的特征和时空关系,从而提高模型的预测能力和泛化能力。模型内部结构如图 2 所示。

输入层接收重构后的数据,将其送入 LSTM 层,LSTM 层对数据进行序列建模,提取表面肌电信号的时间特征,通过门控机制来记忆和遗忘信息,捕捉数据在时间维度上的依赖关系。使用 LSTM 可以有效地传递和表达长时间序列中的

信息,且不会导致过去的有用信息被忽略。与此同时,LSTM

还可以解决 RNN 中的梯度消失/爆炸问题。




图2 复合神经网络模型基本架构

Fig.2 Basic architecture of composite neural network models

CNN 层接收 LSTM 层的输出,将其送入卷积层提取数据中的空间特征,卷积层会定义两个卷积核,大小分别为 5×5 和 3×3 ,每个卷积核都会沿着数据的一维方向(时间轴)进行滑动,并在每个位置上与数据进行点积运算。这个过程类似于一个滑动窗口,在每个窗口位置上都会生成一个新的特征值,如下:

$$w_{i+1} = f(\sum_i w_i x_i + b) \quad (14)$$

卷积层使用 ReLU 激活函数,不仅可以增加 CNN 的非线性特征,还可以提升神经网络的表达能力。激活函数定义如下:

$$ReLU(x) = \begin{cases} 0, & x \leq 0 \\ x, & x > 0 \end{cases} \quad (15)$$

随后,将经过 CNN 层处理的数据输入到最大池化层(MaxPooling1D),池化窗口大小为 2,步长为 1。通过最大池化操作,可减少数据维度,捕捉数据在空间维度上的模式和结构,同时保留最重要的特征。

在传统的神经网络中,输入数据的所有部分受到同等对待,但忽略了不同部分对于任务完成的重要性。表面肌电信号是由多个运动单元发出的动作电位序列,在数据中呈现为时间和空间上综合叠加的结果。在不同的手势动作中,各运动单元的参与程度不同。因此,注意力机制的引入可以动态聚焦于表面肌电信号的相关部分,关注到与任务相关的关键信息,提高信号处理的性能和模型的解释性^[15]。

经过注意力机制加权后的表面肌电信号时空特征将送入 BiLSTM 层进行预测处理,BiLSTM 层分别有 100 个和 200 个神经元。相对于 LSTM,BiLSTM 能够同时考虑序列中的前向和后向信息,从而更全面地理解输入序列。这种双向性使得 BiLSTM 在处理需要上下文信息的任务时表现更佳,同时 BiLSTM 在 LSTM 基础上进一步增加了反向传播,使得

梯度能够更好地传递,有助于提高模型的训练效果,因此在预测任务时通常更准确。

BiLSTM 层的输出被送入 Flatten 层,将其展平成一维向量,随后经过有 25 个神经元的全连接层,最后送入输出层,得到最终预测结果。

2.4 评估标准

对于表面肌电信号预测模型的性能评估,本文选择以下统计指标。

均方误差(Mean Squared Error,MSE)和平均绝对误差(Mean Absolute Error,MAE):用于衡量预测值和真实值之间的标准差。

标准均方误差(Root Mean Squared Error, RMSE):MSE 的平方根,使得解释更为直观。

拟合优度(R^2):用于衡量模型对数据变化的解释程度,其取值为 0~1,越接近 1 表示模型拟合效果越好。

相关计算式如下:

$$MSE = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (16)$$

$$MAE = \frac{1}{m} \sum_{i=1}^m |\hat{y}_i - y_i| \quad (17)$$

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (18)$$

$$R^2 = 1 - \frac{\sum_i (\hat{y}_i - y_i)^2}{\sum_i (\bar{y}_i - \hat{y}_i)^2} \quad (19)$$

3 实验

3.1 VMD 参数选取与加权重构

VMD 分解中,参数 K 的选取直接决定了分解后模式分量的数目。若 K 设置得过大,会造成过分解,产生虚假模式;若 K 设置得偏小,会造成欠分解,不能充分提取时间序列隐

含特征。其次,惩罚因子 α 对分解结果也有重要影响, α 的取值影响了模态分量的带宽,与带宽成反比。

因此,本文根据改进粒子群优化算法,对分解层数 K 和惩罚因子 α 进行寻优。设置粒子数为40,迭代次数为50,寻优结果如图3所示。





图3 PSO 优化参数曲线
Fig. 3 PSO optimization parameter curve



由图3可知,对于文中使用的表面肌电数据数据,VMD的参数 K 和 α 取整有 $K=5,\alpha=1200$,因此VMD相关参数如表4所列。

表4 VMD 相关参数
Table 4 VMD related parameters

参数	值
k	5
α	1200
τ	0
DC	0
$init$	1
tol	1×10^{-7}

其中, K 为分解层数, α 为惩罚因子, τ 为噪声容忍度, DC 为直流分量, $init$ 为初始化中心频率, tol 为收敛准则容忍度。

确定VMD的相关参数后,选取Ninapro DB1_s1练习2中的8个手势动作数据进行信号分解处理,其中标签为1的手势动作表面肌电信号分解如图4所示。




图4 VMD 分解结果
Fig. 4 Results of VMD decomposition

由图4可以看出,VMD将原始肌电信号分解为5个特征分量,特征分量经傅里叶转换后处于不同频率,说明VMD成功提取出了原始肌电信号中不同层次的频率。

由于表面肌电信号的有效频率通常集中在20~200 Hz的频率范围内,由图4可以得出,从IMF1—IMF5,频率逐渐增加。因此,在重构环节,与原始肌电信号有效频率越接近的分量,应该赋予越大的权重。

为了评价各分量与原始肌电信号有效频率的接近程度,首先使用希尔伯特变换提取表面肌电信号有效频率区间内的信号,得到解析信号;然后计算解析信号的绝对值,得到振幅包络;最后对振幅包络的平方求和,得到希尔伯特谱的能量[16]。其希尔伯特变换定义如下:

$$H(u)(t)=\frac{1}{\pi}p\cdot v\cdot\int_{-\infty}^{+\infty}\frac{u(\tau)}{t-\tau}d\tau\tag{20}$$

为了确定每个模态函数在信号中的重要性,将每个模态

函数的能量除以所有模态函数能量的总和,得到模态函数重要性。图4的信号分量经计算后,得到的能量分布和重要性如图5所示。




图5 肌电能量分布与重要性
Fig. 5 Myoelectric energy distribution and importance

由图4可知,IMF2与IMF3为表面肌电信号主要有效信号分布的分量。由图5可知,在希尔伯特能量分布中,IMF2

与 IMF3 的能量分布高于其余分量,二者的重要性占比达到 88%,其中 IMF2 的能量最高,重要性达到 52.3%,而 IMF5 的能量最低,其频率范围与表面肌电信号有效频率范围差值最大,且重要性占比仅为 0.7%,符合预期。因此在肌电信号分量重构中,IMF2 与 IMF3 应该占据更大比重,IMF1,IMF4 和 IMF5 在重构过程应该占据更小的比重。希尔伯特加权重构后的肌电信号在保证信号特征不遗失的情况下,能更程度地减少非特征信息的干扰。

接下来,将数据集中的每个模态函数与其对应的重要性相乘,得到加权后的模态函数。最后,将加权后的模态函数沿着列方向求和,得到加权重构的信号。经过 VMD 处理的表面肌电信号与原始肌电信号的对比如图 6 所示。




图 6 有无 VMD 的肌电信号图

Fig. 6 EMG signal plots with and without VMD

由图 6 可知,经 VMD 加权重构后的数据曲线(Original(VMD))更加平滑,这种平滑化处理有助于提高模型的预测性能。相比之下,未经 VMD 处理的信号(Original)包含更多的噪声,这些噪声可能会干扰模型的学习过程,降低预测




图 8 CNNM 对动作 1 预测结果

Fig. 8 Result of CNNM prediction for action 1

在对动作 1 的表面肌电信号数据进行训练后,得到的模型损失函数曲线如图 9 所示。其中,loss 代表动作 1 训练集的损失值,而 val_loss 则表示动作 1 验证集的损失值。




图 9 模型损失曲线

Fig. 9 Curve of model loss

由图 9 可知,在训练初期,训练集与验证集的损失值快速下降,随着迭代次数的增加,二者损失值的下降速度减缓,

精度。因此,采用 VMD 对表面肌电信号进行预处理是提升手势动作预测准确性的有效手段。

为验证 VMD 处理后的数据是否保留表面肌电信号的关键信息,提取了 VMD 处理前后有效频率范围内的表面肌电信号特征(如 VAR(Variance),RMS(Root Mean Square),IEMG(Integral EMG)等)进行对比,结果如图 7 所示。




图 7 VMD 处理前后肌电特征对比

Fig. 7 Comparison of EMG features before and after VMD treatment

由图 7 可知,VMD 处理前后的表面肌电信号特征并未发生明显变化,证明 VMD 处理后的数据仍然保留着表面肌电信号中的关键信息。

3.2 模型实验结果与分析

重构后的数据将作为混合神经网络的输入,设置 epoch=50,选取数据总数的 20%作为测试集,其余为训练集。DB1_s1 在练习分类 2 中标签为 1 的手势动作的预测结果如图 8 所示。

最终趋于稳定。训练集与验证集损失值的下降趋势表明该模型是收敛的。

为了验证模型的泛用性,在数据集 DB1_s1 练习分类 2 中选取 8 个手势动作的表面肌电数据进行实验,得到各手势动作的模型性能评估指标结果如表 5 所列。

表 5 CNNM 对 8 个动作的预测结果

Table 5 Prediction results of CNNM for eight actions				
动作	MSE	RMSE	MAE	R ²
动作 1	0.000 002	0.001 540	0.001 178	0.999 963
动作 4	0.000 001	0.001 189	0.000 971	0.999 949
动作 7	0.000 025	0.005 043	0.003 747	0.999 632
动作 10	0.000 013	0.003 640	0.002 773	0.999 915
动作 13	0.000 037	0.006 070	0.005 803	0.995 859
动作 16	0.000 013	0.003 562	0.003 057	0.999 467
动作 19	0.000 004	0.001 974	0.001 388	0.999 876
动作 23	0.000 008	0.002 847	0.002 302	0.999 606

为了验证所提模型是具有优势的,将 CNNM 与 VMD-CNN-LSTM,VMD-CNN,VMD-LSTM 进行了实验对比,同时为了验证复合模型相比于单一模型是具有优势的,将其与 LSTM,CNN,CNN-LSTM 进行了实验对比。图 10 展示了对动作标签为 1 的手势动作预测结果。




图 10 不同模型的预测结果

Fig. 10 Prediction results of different models

由图 10 可知,加入 VMD 后的模型预测曲线都更加平滑。这表明,相对于原始肌电信号,经过 VMD 处理后的肌电数据去除了表面肌电信号中的噪声。图 11 为不同模型的拟合优度 R^2 。




图 11 各模型对动作 1 的预测拟合优度

Fig. 11 Prediction goodness of fit of each model for action 1

从图 11 中可以观察出,CNNM 的预测效果最佳。未加入变分模态分解的模型无论是单一模型还是复合模型,在对手势动作的预测准确性上,均不如引入变分模态分解后的模型。

现使用 CNNM 与其余模型对 DB1_s1 的 8 个手势动作进行实验对比,实验结果取平均值,如图 12、图 13 所示。




图 12 不同模型对 8 个动作预测指标

Fig. 12 Eight action prediction metrics for different models

图 12 展示了不同模型在手势动作预测任务上的 MSE, RMSE 与 MAE 评估指标的结果对比。结果显示,本文提出的复合神经网络模型在这些指标上均表现出更小的误差值,显著优于其他单一模型。此外,CNNM 的评估指标也均小于

其特征提取模块 CNN 和 LSTM 单独应用时的评估指标,这表明将 CNN 和 LSTM 作为 CNNM 的特征提取模块,对于提升手势动作预测的准确性是有效的。




图 13 不同模型对 8 个动作的拟合优度

Fig. 13 Goodness of fit of different models for eight actions

由图 13 可知,CNNM 在拟合优度上,相比传统的 LSTM 和 CNN 模型分别提升了 4.37%~6.04%。与其他复合模型相比,CNNM 模型同样展现出显著优势,其提升幅度为 1.6%~3.2%。实验结果表明,本文方法能够实现对手势动作的高精度预测。同时,为进一步说明本文模型的有效性,还将其与近年提出的新模型进行对比,包括 STID(Spatial-Temporal Identity)(2022),TimeMixer(2024)和 MSGNet(2023)。对比结果如表 6 所列。

表 6 各模型的对比结果

Table 6 Comparison results of each model

Model	MSE	RMSE	MAE	MAPE
STID	0.000135	0.012058	0.005225	0.788954
TimeMixer	0.001422	0.037713	0.019289	0.299235
MSGNet	0.056508	0.291629	0.161589	1.587138
CNNM	0.000013	0.003233	0.002652	0.024963

由表 6 可知,相较于近年来提出的 STID,TimeMixer 和 MSGNet 等时间序列预测模型,本文提出的基于变分模态分解的复合神经网络模型(CNNM)在各项评估指标上表现出显著优势,表明其能更好地提取肌电信号特征,显著提升数据的质量及手势动作预测的准确性。

根据 1.1 节中选取的实验数据,进行了模型泛化性实验,实验过程与模型参数均与前述一致,取 5 个受试者的 4 个不同手势动作的评估指标平均值作为最终结果。详细实验结果如表 7 所列。

表 7 5 名受试者不同手势动作预测结果

Table 7 Prediction results of different gestures of five experimenters

受试者	MSE	RMSE	MAE	R^2
2	0.00002	0.00444	0.00371	0.99956
3	0.00016	0.01014	0.00478	0.99685
6	0.00061	0.01880	0.01063	0.99282
8	0.00026	0.01113	0.00637	0.99641
10	0.00001	0.00196	0.00141	0.99298

由表 7 可知,本文模型在不同实验者数据上均取得良好且稳定的预测结果,表明该模型具有较好的泛化性,能适应不同受试者的表面肌电信号数据。

3.3 消融实验

为了验证本文中加入了 VMD、希尔伯特加权重构和注

意力机制模块对模型的有效性,进行了消融实验。从完整模型中移除或替换组件,设计了 4 个对比模型。

Model-1:在完整模型上移除 VMD 模块。

Model-2:在完整模型上移除希尔伯特加权重构,换为普通重构。

Model-3:在完整模型上移除注意力机制模块。

Model-4:在完整模型上移除 VMD、希尔伯特加权重构、注意力机制模块。

进行消融实验的受试者信息如下:DB1_s8,女性,练习分类为 1,选取实验手势动作标签为 9;DB1_s3,男性,练习分类为 2,选取实验手势动作标签为 9。在两个不同的数据上进行实验对比,结果如表 8 所列。

表 8 DB1_s8 和 DB1_s3 标签为 9 的手势动作消融实验
Table 8 Gesture action ablation experiments with label 9 in DB1_s8 and DB1_s3

Model	DB1_s8 手势动作 9				DB1_s3 手势动作 9			
	MSE	RMSE	MAE	R ²	MSE	RMSE	MAE	R ²
CNNM	0.0003	0.0173	0.0142	0.9960	0.0005	0.0222	0.0084	0.9964
Model-1	0.0032	0.0564	0.0426	0.9131	0.0036	0.0601	0.0219	0.9696
Model-2	0.0046	0.0680	0.0507	0.9385	0.0100	0.0998	0.0405	0.9267
Model-3	0.0013	0.0366	0.0287	0.9620	0.0010	0.0317	0.0143	0.9727
Model-4	0.0053	0.0727	0.0569	0.8551	0.0125	0.1116	0.0308	0.8952

通过观察表 8 可知,相比 CNNM 算法,移除 VMD 模块的 Model-1 模型在不同的数据上,拟合优度 R^2 分别降低了 8.29 个百分点和 2.68 个百分点;移除希尔伯特重构的 Model-2 在两个数据上,拟合优度 R^2 分别降低了 5.75 个百分点和 6.97 个百分点;移除注意力机制的 Model-3 在两个数据上,拟合优度 R^2 分别降低了 3.4 个百分点和 2.37 个百分点;将三者全部移除后,Model-4 的拟合优度 R^2 降低了 14.09 个百分点和 10.12 个百分点。同时,在传统神经网络模型 CNN 和 LSTM 上对两组数据进行了验证,在 DB1_s8 数据上,CNN 和 LSTM 的拟合优度仅为 0.821 和 0.780,在 DB1_s3 数据上 CNN 和 LSTM 的拟合优度仅为 0.844 和 0.784,均低于 CNNM。

上述结果表明,利用 VMD 对表面肌电信号进行降噪滤波与特征提取是有效的;其次,相比于将 VMD 分量进行直接重构,表面肌电信号分量经希尔伯特计算后对不同分量进行加权重构,能够更好地将特征提取出来,提升手势动作的预测准确率;此外,注意力机制的引入,为各运动单元的激活状态进行了动态加权,也对模型性能的提升起到了积极作用。

结束语 针对表面肌电信号不稳定、易受干扰的特性,本文提出了基于变分模态分解和希尔伯特加权重构的复合神经网络模型(CNNM),与 LSTM,CNN,TimeMixer,STID,MSGNet 等时间序列预测模型相比,该模型能更好地将表面肌电信号的特征提取出来,显著提高了表面肌电信号数据的质量和手势动作预测的准确性。该模型对数据集 NinaProDB1 中 8 种具有人体上肢运动代表性的表面肌电信号进行实验,在评估指标 RMES,MSE,MAE 上,相对于其他模型有大幅提升。在选取的 8 个动作中,拟合优度 R^2 均值达到 0.99。为验证模型的泛用性,选取 3 男 3 女在不同练习分类下不同手势动作进行实验。结果表明,所提出的模型展现出了良好的鲁棒性,在多组不同的数据上均取得了优异表现。最后通过消融实验,验证了引入的不同模块对模型性能提升的有效性。

但与 TimeMixer,STID 和 MSGNet 等时间序列预测模型相比,CNNM 模型结构复杂,预测结果的可解释性不如对比模型。在应用过程中,还可以进一步优化时间复杂度,为下一步进行康复训练机器人的控制研究留下更多的改进空间。

参 考 文 献

[1] BATTISTON B,TITOLO P,CICLAMINI D,et al. Peripheral Nerve Defects:Overviews of Practice in Europe [J]. Hand Clinics,2017,33(3):545-50.

[2] ZHOU S,ZHANG G J. Research progress on the application of robots in early rehabilitation training of patients with movement disorders after stroke [J]. Chinese Nursing Research, 2024, 38(8):1428-1432.

[3] BERTANI R,MELEGARI C,DE COLA M C,et al. Effects of robot-assisted upper limb rehabilitation in stroke patients:a systematic review with meta-analysis [J]. Neurological Sciences, 2017,38(9):1561-1569.

[4] MARIANNE B,LAURENT B,JEANSÉBASTIEN R,et al. Reducing Noise, Artifacts and Interference in Single-Channel EMG Signals: A Review [J]. Sensors,2023,23(6):2927.

[5] ZHENG Y,ZHENG G,ZHANG H,et al. Mapping Method of Human Arm Motion Based on Surface Electromyography Signals [J]. Sensors,2024,24(9):2827.

[6] HUO Y D,LI F B,LI Q,et al. A Novel Method for Hand Movement Recognition Based on Wavelet Packet Transform and Principal Component Analysis with Surface Electromyogram [J]. Computational Intelligence and Neuroscience, 2022, 2022(1): 8125186.

[7] ZHANG Q,LUO W Y,HUANG B,et al. Continuous kinematics prediction of lower limb driven by EMG [J]. Journal of Huazhong University of Science and Technology (Nature Science Edition),2017,45(10):128-132.

[8] TRIWIYANTO T,VUGAR A,ALI A A. Deep Convolution Neural Network to Improve Hand Motion Classification Performance Against Varying Orientation Using Electromyography Signal [J]. International Journal of Precision Engineering and Manufacturing,2024,25(6):1289-1301.

[9] WEI W T,LI Y J. Surface electromyography based gesture recognition based on dual-stream CNN [J]. Computer Integrated Manufacturing Systems,2022,28(1):124-131.

[10] ARJAN G,MANFREDO A,CLAUDIO C,et al. Movement error rate for evaluation of machine learning methods for sEMG-

based hand movement classification [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2014, 22(4): 735-744.

[11] JIANG H Y, XU X J, ZHONG L J, et al. Gesture Recognition of Surface Electromyography Based on Variational Mode Decomposition and Domain Adaptation [J]. Journal of Xi'an Jiaotong University, 2024, 58(5): 75-87.

[12] DRAGOMIRETSKIY K, ZOSSO D. Variational Mode Decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.

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

[14] LI X, NI R, JI Z. ICG signal denoising based on ICEEMDAN and PSO-VMD methods [J]. Physical and Engineering Sciences in Medicine, 2024, 47: 1547-1556.

[15] WENLI Z, TINGSONG Z, JIANYI Z, et al. LST-EMG-Net: Long short-term transformer feature fusion network for sEMG gesture recognition [J]. Frontiers in Neurorobotics, 2023, 17: 1127338.

[16] VASANTHI S M, LENIN A H, FOUAD Y, et al. Electromyography signal based hand gesture classification system using Hilbert Huang transform and deep neural networks [J]. Heliyon, 2024, 10(11): e32211.



ZHAO Lian, born in 2000, postgraduate, is a member of CCF (No. Y5493G). His main research interest is intelligent rehabilitation robots.



WU Yangdong, born in 1969, Ph.D, associate professor. His main research interests include intelligent manufacturing, multidisciplinary design optimization and intelligent rehabilitation robots.

(责任编辑:何杨)