

DOI:10.19651/j.cnki.emt.2519748

基于 VMD-Informer 和表面肌电信号的 下肢关节角度预测*

吴生彪^{1,2} 游涛¹ 桂家政¹

(1. 东华理工大学电子与电气工程学院 南昌 330013; 2. 江西省康复辅具产业技术研究院 南昌 330013)

摘要: 针对下肢关节角度预测精度低、实时性差及模型泛化弱等问题,提出了一种基于 VMD-Informer 和表面肌电信号(sEMG)的下肢关节角度预测方法。首先采集受试者在行走和上楼模式下的下肢 sEMG 及对应关节角度数据,为增强原始数据的稳定性,采用变分模态分解(VMD)算法对肌电信号进行分解,负梯度和自适应粒子群算法(NGSPSO)对 VMD 的两个关键参数进行了优化:本征模态函数(IMF)的成分数量与惩罚因子。其次,从各 IMF 中提取多域特征,采用主成分分析法(PCA)从特征序列中提取关键因素,从而降低模型的输入维度。最后,运用 Informer 模型对多变量特征序列进行动态时序建模。实验结果表明,所提 VMD-Informer 模型在平地行走场景中髋、膝关节 RMSE 分别为 2.688 5°和 3.351 6°,在上楼梯场景中 RMSE 分别为 3.508 8°和 3.856 2°,相比 VMD-Transformer 平均误差降低 18%,明显提升了预测精度与系统实时性,为康复外骨骼的运动意图识别提供了技术支撑。

关键词: 关节角度预测;表面肌电信号;变分模态分解;负梯度和自适应粒子群优化;主成分分析;Informer 模型
中图分类号: TN911.72 **文献标识码:** A **国家标准学科分类代码:** 510.40.30

Prediction of lower limb joint angles based on VMD-Informer and surface electromyography signals

Wu Shengbiao^{1,2} You Tao¹ Gui Jiazheng¹(1. School of Electronic and Electrical Engineering, East China University of Technology, Nanchang 330013, China;
2. Jiangxi Industrial Technology Research Institute of Rehabilitation Assistance, Nanchang 330013, China)

Abstract: To address issues such as low prediction accuracy, poor real-time performance, and weak model generalization in lower limb joint angle prediction, this study proposes a method based on VMD-Informer and surface electromyography signals (sEMG). First, sEMG signals and corresponding joint angle data were collected from subjects during walking and stair-climbing patterns. To enhance the stability of raw data, the variational modal decomposition (VMD) algorithm was applied to decompose the EMG signals. The negative gradient and adaptive particle swarm optimization (NGSPSO) algorithms were used to optimize two key parameters of VMD: The number of Intrinsic modal function (IMF) components and the penalty factor. Next, multi-domain features were extracted from each IMF. Principal component analysis (PCA) was applied to identify key factors within the feature sequences, thereby reducing the model's input dimension. Finally, the Informer model was employed for dynamic temporal modeling of the multivariate feature sequences. Experimental results demonstrate that the proposed VMD-Informer model achieves RMSE values of 2.688 5° and 3.351 6° for hip and knee joints, respectively, in flat walking scenarios, and 3.508 8° and 3.856 2° for the stair-climbing scenario, respectively. Compared to VMD-Transformer, this represents an 18% reduction in average error, significantly enhancing prediction accuracy and system real-time performance. This provides a technical foundation for recognizing movement intentions in rehabilitation exoskeletons.

Keywords: joint angle prediction; surface electromyography signals; variational mode decomposition; negative gradient and adaptive particle swarm optimisation; principal component analysis; Informer model

0 引言

随着全球人口老龄化的加剧,因神经系统疾病或外伤

导致的下肢运动功能障碍患者持续增多^[1]。康复外骨骼作为新兴的运动辅助与康复手段,通过提供动力支持与运动引导,可改善患者步态,在临床康复中前景良好^[2]。为实现

收稿日期:2025-08-31

* 基金项目:国家自然科学基金项目(62141102)、江西省教育科学规划项目(2025ZX184)、江西省重大科技研发专项(20233AAE02008)资助

更安全、舒适、高效的人机协同,外骨骼系统对用户运动意图的精准识别与实时响应提出了更高要求^[3]。

生物电信号因其检测方便、无创等特点,成为人机协同领域的主流研究对象^[4]。其中表面肌电信号(surface electromyography, sEMG)记录着人体肌肉的电活动,相比脑电信号更稳定,被广泛应用于连续关节运动估计^[5]。基于 sEMG 的连续运动预测能显著提升康复设备的人机协作效率^[6],而对连续运动量变化的精准预测,正是康复机器人实现精准控制的关键所在^[6]。

sEMG 特征提取是实现运动意图识别和关节角度预测的关键前提。研究人员利用离散小波变换(discrete wavelet transform, DWT)提取肌电时频特征,结合神经网络分类器,动作分类达到 98.5% 的准确率^[7]。但传统时域、频域方法难以适配信号的时变特性,时频分析方法存在模态混叠、自适应分解能力弱问题;在此背景下,变分模态分解(variational mode decomposition, VMD)方法逐渐受到关注。VMD 传统参数设定依赖经验试错,难以适应 sEMG 时频特性突变,吴田等^[8]提出改进麻雀算法(improved sparrow search algorithm, ISSA)优化 VMD, sEMG 降噪信噪比提升 15.2%;李效等^[9]提出(complementary ensemble empirical mode decomposition, CEEMD)-VMD-(sliding interval soft threshold, SIST)混合架构显著抑制了频率混叠效应;然而其麻雀算法易陷入局部最优,而 CEEMD-VMD 的计算复杂度限制了其在实时外骨骼控制中的应用。粒子群优化算法(particle swarm optimization, PSO)因收敛速度快、参数少的特点被广泛用于 VMD 参数调优,但标准 PSO 也存在早熟收敛问题。VMD 分解后的多模态分量直接作为输入特征将导致维度灾难,主成分分析(principal component analysis, PCA)通过正交变换提取主方向,为高维特征压缩提供有效路径。Li 等^[10]验证 PCA 可将下肢 sEMG 特征维度压缩 80%,保留 90% 原始方差,但其并未深入验证跨步态泛化能力。

建立从多维度 sEMG 特征到连续关节角度的精准预测关系,是实现下肢运动高精度估计的核心^[11]。早期研究多依赖于线性模型,精度有限,随着深度学习技术的发展,卷积神经网络(convolutional neural networks, CNN)与长短期记忆网络(long short-term memory, LSTM)已成功应用于连续关节角度估计中^[12],Tang 等^[13]提出的基于注意力机制的 CNN-LSTM 网络,利用 10 通道 sEMG 预测三种步态下膝关节角度,精度优于传统模型;Liu^[14]采用反向传播神经网络(back propagation neural network, BPNN)融合 sEMG 与运动学数据,平均 RMSE 为 3.9°。但是 LSTM 模型在处理长序列数据时存在信息衰减,难以有效提取 sEMG 关键信息^[15]。Transformer 架构因自注意力机制在长程依赖建模上的优势被引入下肢运动估计任务,Zeng 等^[16]提出的基于 Transformer 的预测模型将 RMSE 降至 3.094°。然而,标准 Transformer 因其计算复杂度和内存

消耗,难以处理极长序列;在此基础上,Informer 模型作为 Transformer 的高效变体,在处理序列时,Informer 能更高效地捕捉数据中的时序依赖关系与关键特征。Wan 等^[17]通过融合步态特征与 Informer 模型,验证了其在关节角度连续预测中的有效性,但其方法侧重于外部信息融合,而非解决 sEMG 内部非平稳性的核心挑战;Lu 等^[18]将 Informer 模型应用于 sEMG,实现了肘关节力的区间预测,其采用的小波变换在信号自适应分解上存在局限,且仅依赖均值与方差的特征无法充分表征与复杂运动相关的全部信息。

综上所述,本文提出了一种多通道 sEMG 的下肢关节角度预测方法,旨在提高预测的准确性。具体而言,首先采集了 sEMG 及对应关节角度数据,然后采用 VMD 方法对 sEMG 进行分解;通过负梯度和自适应粒子群算法(negative gradient and self-adaption particle swarm optimization, NGSPSO)优化 VMD 中的(intrinsic mode function, IMF)成分数量与惩罚因子;随后从各 IMF 中提取多域特征,并运用 PCA 对特征进行降维,最后引入 Informer 关节角度预测模型。该方法有效性通过实验进行了验证,实验结果表明,相较于传统方法具有更高的精度。

1 数据处理及特征提取

1.1 实验数据采集和处理

1) 数据采集

sEMG 采集是实现外骨骼精准控制的关键前提,下肢运动模式由特定肌肉群协同驱动,根据行走和上楼过程中下肢主要活跃的肌肉,选取了股直肌、股二头肌、股外侧肌、胫骨前肌、外侧腓肠肌和比目鱼肌六块肌肉^[19]。实验数据采集流程如图 1 所示,sEMG 采集采用 RS-EMG8 生物信号采集系统,采样频率为 1 000 Hz,关节角度数据通过 WT901BC-TTL 姿态角度传感器采集,传感器贴附于受试者下肢相应位置,采样频率为 200 Hz。




图 1 实验采集流程图

Fig. 1 Experimental data acquisition flowchart

实验开始前对受试者皮肤进行清洁,避免汗水和油脂影响电极的附着和信号质量;将电极片阵列的方向与肌肉的活动方向保持一致,保持信号稳定清晰。共 10 名健康受试者参与了本研究实验,其中包括 9 名健康个体及 1 名具有轻度运动障碍的个体,受试者信息如表 1 所示。所有受

试者能够正常进行平地行走和上楼梯运动实验。

表1 受试者身体特征

Table 1 Physical characteristics of participants

受试者	年龄	身高/cm	体重/kg	身体状况	性别
1	23	176	70	健康	男
2	25	173	68	健康	女
3	24	165	55	健康	男
4	23	168	62	健康	女
5	25	170	65	健康	女
6	25	175	68	健康	男
7	35	167	55	健康	女
8	40	170	58	健康	女
9	45	178	75	健康	男
10	52	175	78	轻度运动障碍	男

在平地行走运动实验中,受试者匀速地进行步行周期性切换;在上楼梯运动实验中,受试者完成一次上阶梯为一组数据实验;每次采集30 s以上,受试者每采集3组进行5 min的休息,以确保动作采集的数据准确性。以受试者3为例,初始状态和2种运动模式信号采集如图2所示。



图2 不同运动模式下sEMG采集

Fig. 2 sEMG acquisition in different movement modes

2) 数据处理

对于采集的原始sEMG,利用四阶巴特沃斯带通滤波器(20~450 Hz)及50 Hz陷波滤波去除噪声与工频干扰;以平地行走下的股直肌为例,得到图3所示的滤波前后肌电信号时域图。由图3可以看出,滤波后信号中的高频噪声和工频干扰被有效抑制,波形整体更平滑,显著提升了信号的质量,为后续信号特征提取提供了可靠的数据基础。

1.2 数据特征提取

1) 变分模态分解(VMD)

VMD是一种基于约束变分优化的自适应信号处理方法,通过模态分解得到不同频率尺度的子序列^[20]。VMD将原始肌电信号分解成一系列模态分量,目标是最小化各模态估计带宽的总和。

原始信号 $x(t)$ 可以直接定义为:

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




图3 滤波前后sEMG时域比较

Fig. 3 Comparison of sEMG time domain before and after filtering

分解过程通过解决约束条件下的变分问题^[20],目标函数为:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \\ s. t. \sum_{k=1}^K u_k(t) = x(t) \end{cases} \quad (2)$$

式中: $u_k(t)$ 表示第 k 个模态分量;其中 $\{u_k\}, \{\omega_k\}$ 分别是分解子序列和中心频率的集合; ∂_t 表示时间导数; $*$ 表示卷积。

2) NGPSO 优化 VMD 参数

VMD用于分解sEMG时,预设的IMF分量 K 和惩罚因子 α 的数量对分解性能有显著影响,标准PSO在优化VMD参数时易陷入局部最优^[21],本文采用NGPSO实现VMD参数自适应选择^[21]。改进后的粒子速度更新和位置公式为:

$$v_{ij}(t+1) = aR_1 v_{ij}(t) - bR_2 \Delta f_{pi}(t) \times (p_{ij}(t) - x_{ij}(t)) - cR_3 \Delta f_g(t)(g_j(t) - x_{ij}(t)) \quad (3)$$

$$x_{ij}^{t+1} = \eta \times R \times (x_{ij}^t + v_{ij}^{t+1}) \quad (4)$$

式中: $\Delta f_{pi}(t) = -(f_{pi}(t) - f_i(t))$ 表示第 i 个粒子当前最优适应度值与当前适应度值的差值。取两者的负值反映粒子的搜索方向, $\Delta f_g(t) = -(f_g(t) - f_i(t))$ 表示种群最优适应度值与当前粒子适应度的差值, $p_{ij}(t)$ 是粒子 i 的历史最优位置, $g_j(t)$ 是全局最优位置; a, b, c 为学习因子; $a=0.01, b=1, c=0.002$; η 表示自适应调整系数, R 为随机搜索因子,其范围为 $0 < R < 1$ 。

自适应调整系数 η 基于反正切函数定义,表达式为:

$$\eta = \frac{2}{\pi} \arctan\left(\frac{t}{T_{\max}}\right) \quad (5)$$

式中: t 为当前迭代次数, T_{\max} 为最大迭代次数,当其导数 $\frac{d\eta}{dt} > 0$, η 随迭代过程单调递增,当 $t \rightarrow 0^+$, $\eta \rightarrow 0$,算法在此阶段侧重于全局探索; η 逐渐增大,算法转向局部精细搜索,从而实现搜索策略的自适应平衡。

在 NGPSO 寻找最优解时,所选择适应度函数是通过构建融合信号重构精度与模态稀疏性的优化目标函数实现,公式为:

$$F(K, \alpha) = SE(K, \alpha) + \gamma K \quad (6)$$

$$SE = \sum_{t=1}^N (x(t) - \sum_{k=1}^K u_k(t))^2 \quad (7)$$

式中: γ 为模态数惩罚权重, SE 表示信号重构误差。

为系统评估 NGPSO 算法在 VMD 参数优化中的性能,本文将其与标准 PSO 算法在相同适应度函数下进行对比,收敛性能对比结果如图 4 所示。




图 4 NGPSO 与标准 PSO 的收敛曲线

Fig. 4 Convergence curves for NGPSO and standard PSO

从图 4 可知,NGPSO 算法在迭代早期便表现出较快的收敛速度,且能够获得更优的适应度值,说明其在全局搜索与局部优化之间实现了更优平衡。

因此 NGPSO 算法优化 VMD 参数流程如图 5 所示,当达到最大迭代次数为 100,输出最优参数 $K^* = 5$ 。

为进一步量化 NGPSO 对 VMD 参数的优化效果,经 NGPSO 寻优后,不同下肢肌肉 sEMG 对应的 IMF 分量数与惩罚因子取值如表 2 所示。

从表 2 可知,说明经 NGPSO 全局寻优后,不同肌肉的 sEMG 信号在分解为 5 个 IMF 分量时,能最有效地分离出与下肢关节运动强关联的模态,为后续精准提取特征并实现高精度关节角度预测奠定了坚实基础。

3) 模态信号特征提取

为充分表达肌电信号的变化趋势和与关节运动之间的关系,从各模态数据中提取时域、频域及非线性特征,作为预测模型的输入。

(1) 时域特征

平均绝对值(mav)能直观反映肌电信号幅值的平均强度,均方根值(rms)能显示肌电信号的有效值,计算公式为:

$$mav = \frac{1}{T} \int_0^T |u_k(t)| dt \quad (8)$$

$$rms = \sqrt{\frac{1}{T} \int_0^T u_k^2(t) dt}$$

式中: $u_k(t)$ 为单个 IMF 分量,时间区间为 $[0, T]$ 。

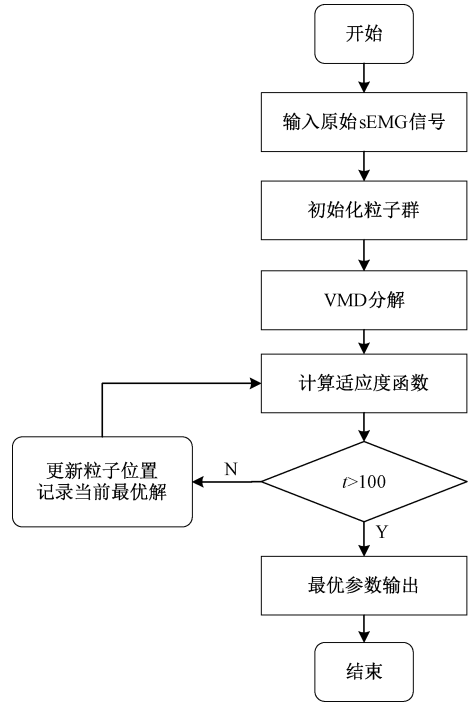


图 5 NGPSO 算法优化 VMD 参数流程

Fig. 5 Flowchart of NGPSO algorithm optimization for VMD parameters

表 2 各肌肉最优 VMD 参数

Table 2 Optimal VMD parameters for each muscle

肌肉名称	最优 K 值	最优 α 值
股直肌	5	452
股二头肌	5	1 285
股外侧肌	5	485
胫骨前肌	5	623
外侧腓肠肌	5	598
比目鱼肌	5	612

过零点数(z_c)表现肌电信号在时间序列上的波动情况,计算公式为:

$$z_c = \frac{1}{2} \int_0^T \left| \frac{d}{dt} \text{sgn}(u'_k(t)) \right| dt \quad (9)$$

式中: $\text{sgn}(\cdot)$ 为符号函数, $u'_k(t) = \frac{du_k(t)}{dt}$ 。

(2) 频域特征

中值频率(mf)和平均功率频率(mpf)分别表示肌电信号的频率中值和功率频率分布的平均值。计算公式为:

$$\int_0^{f_m} P(f) df = \int_{f_m}^{f_{\max}} P(f) df \quad (10)$$

$$mpf = \frac{\int_0^{f_{\max}} f P(f) df}{\int_0^{f_{\max}} P(f) df} \quad (11)$$

式中: f_{\max} 为奈奎斯特频率, $P(f) = |u_k(f)|^2$ 为肌电信号的功率谱密度函数, $u_k(f)$ 为积分累计函数。

(3) 非线性特征

为用于量化肌电信号的复杂性和不规则性,引入模糊熵作为非线性动力学特征,对单个 IMF 分量构造向量序列,模糊熵的计算公式为:

$$FE(m, r, N) = \ln \frac{A^m(r)}{B^m(r)} \quad (12)$$

式中: m 为片段长度, r 为容限度, $A^m(r)$ 表示 m 维向量间的平均相似度, $B^m(r)$ 表示 $m+1$ 维向量间的平均相似度。

采用以上特征提取方式,将 6 个特征依次排列,为每个 IMF 构造一个 6 维特征向量,最后将 6 通道拼接得到全局特征向量为:

$$f_k = [mav, rms, zc, mf, mpdf, FE]^T \quad (13)$$

$$\mathbf{X}_{feat} = [f_1, f_2, \dots, f_6]^T \quad (14)$$

4) 主成分分析(PCA)降维

为了减少特征中的冗余信息并提升关节角度估计精度,维持模型的计算效率,对特征提取后的全局特征向量应用 PCA 方法。

先对 180 维特征向量分别按列进行均值-方差标准化,得到标准化矩阵 $\tilde{\mathbf{X}}$, 计算样本协方差矩阵,即:

$$\mathbf{S} = \frac{1}{N-1} \tilde{\mathbf{X}} \tilde{\mathbf{X}}^T \quad (15)$$

再对协方差矩阵求解特征值与特征向量 $\mathbf{S}v_i = \lambda_i v_i$, 并按降序排列特征值 $\lambda_1 \geq \dots \geq \lambda_{180}$ 。计算贡献率 τ_i 和累积贡献率 η_i , 公式如式(16)所示。

$$\begin{cases} \tau_i = \frac{\lambda_i}{\sum_{k=1}^{180} \lambda_k} \\ \eta_i = \sum_{k=1}^{180} \tau_k \end{cases} \quad (16)$$

为保留绝大部分信息的同时最大限度降低输入维度,如图 6 所示,前 4 个主成分的累积贡献率已达 90%,选择前 4 个特征序列来替换原始变量作为 Informer 模型的输入,得到降维后特征输入如式(17)所示。

$$\mathbf{W} = [v_1, v_2, v_3, v_4] \cdot \mathbf{z}_t = \mathbf{W}^T \tilde{x}_t \in \mathbb{R}^{4 \times 1} \quad (17)$$

式中: \tilde{x}_t 为时间步 t 的降维特征。

2 预测模型构建与参数设置

2.1 Informer 预测模型

Transformer 模型存在二次时间复杂度、高内存消耗问题。为此,本文采用 Informer 模型,该模型在概率上简化了 Transformer 的原始自我注意机制,降低了计算复杂度,有效地提高了精度;Informer 模型的结构如图 7 所示。

2.2 稀疏概率(ProbSparse)注意力机制

相较于传统自注意力机制,ProbSparse 自注意力机制




图 6 PCA 主成分贡献率

Fig. 6 PCA principal component contribution rate

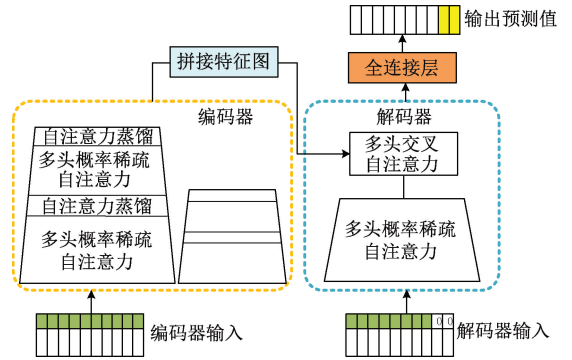


图 7 Informer 模型结构图

Fig. 7 Informer model architecture diagram

是对传统机制中的查询向量(Query)进行稀疏化处理,并生成新的稀疏化 Query,从而降低计算复杂度,稀疏自注意力机制的公式为:

$$A(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\tilde{\mathbf{Q}}\mathbf{K}^T}{\sqrt{d}}\right) \mathbf{V} \quad (18)$$

式中: A 是注意力机制; \mathbf{Q} 、 \mathbf{K} 和 \mathbf{V} 是通过线性变换组成的矩阵; T 是矩阵转置; softmax 是激活函数, d 是变量的输入维度, $\tilde{\mathbf{Q}}$ 为稀疏化后的矩阵。

2.3 编码器

编码器由多个 ProbSparse 自注意力机制和蒸馏机制组成,旨在处理来自时间序列数据的输入并捕获数据中的长期依赖关系。经 PCA 降维后的特征序列,与正弦位置编码相加,作为编码器的输入,经由多头 ProbSparse 自注意力模块处理。输出经残差连接与层归一化(LayerNorm)后得到中间特征,为逐步压缩序列长度,在每一层后引入蒸馏模块。

$$\mathbf{Z} = [z_1, z_2, \dots, z_t]^T \quad (19)$$

$$\mathbf{H}^{(0)} = \mathbf{Z} + \mathbf{P} \quad (20)$$

$$\mathbf{H}' = \text{LayerNorm}(\mathbf{H} + A(\tilde{\mathbf{Q}}, \mathbf{K}, \mathbf{V})) \quad (21)$$

$$\mathbf{H}'_{\langle t+1 \rangle} = \text{MaxPool}(\text{ELU}(\text{Conv1D}(\mathbf{H}'_t))) \quad (22)$$

式中: \mathbf{P} 为正弦位置编码; \mathbf{H}'_{t+1} 是目标序列的占位符;

Conv1d 表示一维卷积;ELU 为激活函数;MaxPool 是最大池化。

最后经过两层蒸馏后编码器输出为:

$$\mathbf{H}_{enc} = H^{(2)} \mathbf{W}_{enc} \in \mathbb{R}^{[T/4] \times d_{bmodel}} \quad (23)$$

2.4 解码器

解码器采用生成式预测框架,包含多头掩码稀疏自注意力和交叉注意力机制,实现关节角度序列的单步预测。

解码器输入由起始标记与目标占位符拼接构成,公式为:

$$\mathbf{X}'_{feed_de} = \text{Concat}(\mathbf{X}'_{token}, \mathbf{X}'_0) \quad (24)$$

式中: \mathbf{X}'_{token} 为起始标记, \mathbf{X}'_0 为目标序列的占位符。

为融合编码器提取的全局特征信息,解码器采用编码器-解码器交叉注意力机制,公式为:

$$\mathbf{C}'_{cross} = A(\mathbf{Q}_{dec}, \mathbf{K}_{enc}, \mathbf{V}_{enc}) \quad (25)$$

式中: \mathbf{Q}_{dec} 由解码器中间状态生成; $\mathbf{K}_{enc}, \mathbf{V}_{enc}$ 来自编码器最终输出 \mathbf{H}_{enc} 。

最终通过全连接层将解码器输出映射为关节角度预测值,公式为:

$$\hat{\theta}_i = \mathbf{W}_0 \mathbf{C}'_{cross} + \mathbf{b}_0 \quad (26)$$

式中: \mathbf{W}_0 为权重矩阵; $\mathbf{b}_0 \in \mathbb{R}^2$ 为偏置项;输出维度为 2,分别对应髋关节与膝关节的角度预测值。

2.5 Informer 模型的超参数设置

为验证所提方法的有效性,本文基于标准实验环境构建完整验证框架。硬件平台为 NVIDIA RTX 4050 GPU,软件环境集成 PyTorch、MATLAB 2023a 与 TensorBoard 构建协同计算架构。

在将 Informer 模型应用于关节角度估计任务时,超参数配置对模型性能具有关键影响。为充分挖掘模型潜力并确保其在实际应用中的优越性能,本文采用网格搜索策略,网格搜索通过系统地遍历每个超参数的可能组合,结合关节角度估计定量评估与实验结果的对比分析,确保了超参数的最优选择,最终确定的基本超参数配置如表 3 所示。

表 3 Informer 模型的基本超参数

Table 3 Basic hyperparameters of the Informer model

模块	参数	值/配置
编码器	编码器输入维度	4
	编码器层数	2
	注意力头数	8
解码器	解码器输入维度	4
	解码器层数	1
	类型	AdamW
优化器	初始学习率	0.000 1
	训练数据的批量大小	32
	激活函数	GELU

3 实验结果及分析

3.1 基于 NGSPSO-VMD 的 sEMG 特征提取结果

本文为避免在模型训练中引入未来数据,将数据集分为训练集和测试集,基于训练集数据,利用 NGSPSO 优化 VMD 参数,并进行信号分解。以股二头肌表面肌电信号为例,经 VMD 分解得到波形如图 8 所示。可见 NGSPSO-VMD 方法实现了模态函数的自适应分解,解决了过度分解和分解不足等问题,该结果验证了 NGSPSO 优化 VMD 参数的可行性。

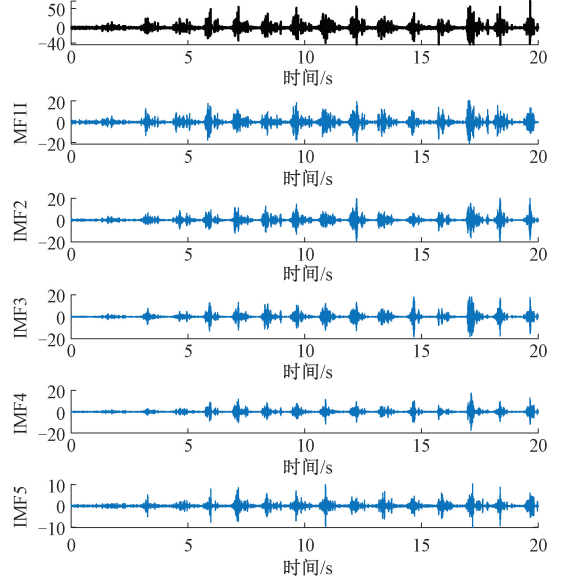


图 8 VMD 分解波形图

Fig. 8 VMD decomposition waveform diagram

3.2 评价指标

在评估模型的性能时,通常量化预测和实际关节角度之间的差异^[22],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^[20],因此本文采用均方根误差(RMSE)与平均绝对误差(MAE)作为标准化评估指标,计算公式为:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{Y}_i - Y_i)^2} \quad (27)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{Y}_i - Y_i| \quad (28)$$

式中: Y_i 是关节角度的实际值, \hat{Y}_i 是关节角度的估计值, N 是样本数。

3.3 VMD-Informer 模型预测结果

本文提出了一种结合 VMD 和 Informer 模型的联合角度估计模型,VMD 的分解特性使回归模型能够有效地学习输入和输出之间的内在关系。为了验证所提模型的性能,本研究在平地行走和上楼梯两种典型运动场景中进行了实验,并将模型的预测结果与实际角度测量值进行了对比分析,如图 9 所示。

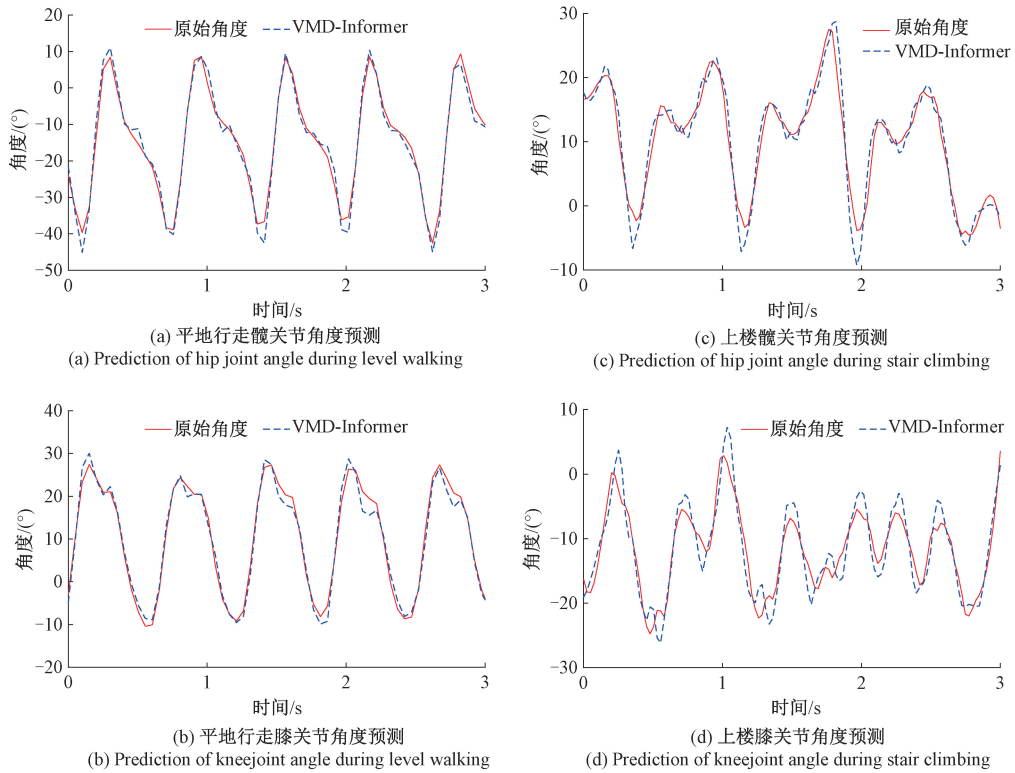


图9 VMD-Informer模型预测结果

Fig.9 VMD-Informer model angle prediction results

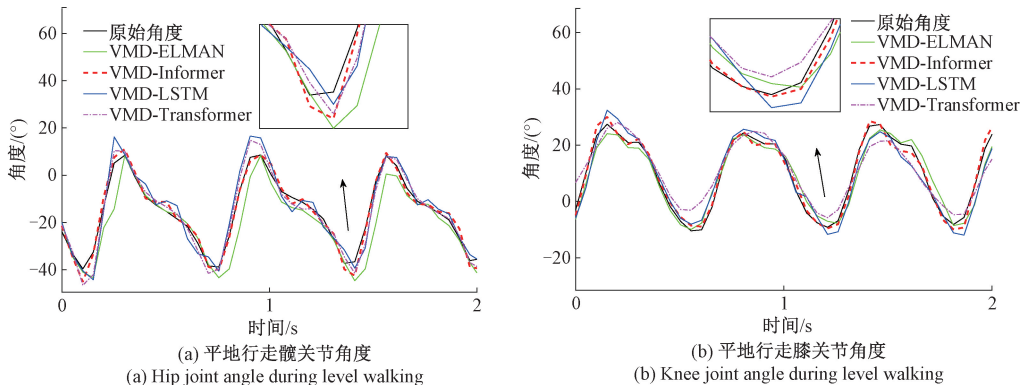
预测实验结果显示,VMD-Informer模型预测得到的髋、膝关节角度曲线与原始角度曲线在时间序列维度上变化趋势高度一致,呈现出良好的拟合一致性,证明了该模型的高精度和可靠性,实验证实加入模糊熵此非线性特征后^[23],特征集更完整,最终提升了预测精度。

为了验证VMD-Informer模型的有效性,本文将其与VMD-LSTM、VMD-Transformer和VMD-ELMAN模型进行了关节角度预测性能对比。如图10所示,VMD-Informer模型显著优于对比模型。在膝关节预测中,其估计结果更接近真实值,且在运动拐点处波动更小、稳定性更强;而在髋关节预测中,VMD-Informer展现出明显优

势,预测误差更小,受噪声干扰产生的波动更轻微,表明其抗噪声干扰能力更强,预测结果更可靠稳定。

为验证VMD-Informer模型的泛化性能,本文在平地行走与上楼梯两种典型步态场景下,基于跨受试者的实验数据,对比分析了VMD-ELMAN、VMD-LSTM、VMD-Transformer及VMD-Informer 4类模型对髋、膝关节角度的预测RMSE,如表4所示。结果表明,在平地行走和上楼梯任务中,VMD-Informer模型对髋、膝关节角度的预测精度均显著优于其他对比模型。

此外,本文利用MAE对不同模型在关节角度预测中的性能进行了量化分析,如表5所示。结果显示,VMD-



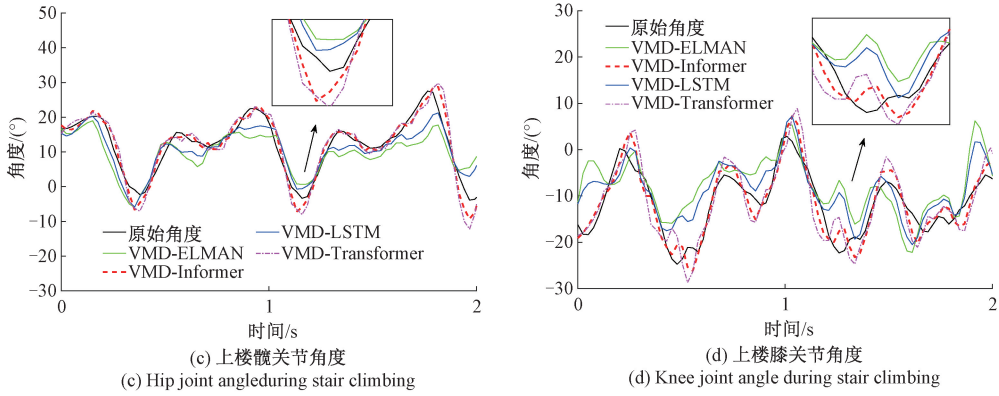


图 10 髋和膝关节角度不同预测模型对比

Fig. 10 Comparison of predictive models for hip and knee angle differences

表 4 不同步态下关节角度预测模型的 RMSE

Table 4 RMSE of joint angle prediction models under different gait patterns

模型	受试者 1(176 cm/70 kg) 平地行走/上楼梯		受试者 2(173 cm/68 kg) 平地行走/上楼梯		受试者 3(165 cm/55 kg) 平地行走/上楼梯	
	髋关节	膝关节	髋关节	膝关节	髋关节	膝关节
	VMD-ELMAN	5.017 3/7.102 3	6.484 2/7.352 1	4.846 1/7.001 7	6.373 9/7.250 3	4.936 2/7.118 0
VMD-LSTM	3.882 4/5.732 5	5.132 1/6.000 1	3.850 5/5.681 3	5.051 3/5.951 2	3.865 0/5.587 2	4.888 9/5.855 4
VMD-Transformer	3.221 5/4.623 0	4.142 2/4.865 4	3.180 2/4.542 2	4.046 8/4.750 2	3.176 0/4.524 2	4.102 0/3.720 2
VMD-Informer	2.647 8/3.524 8	3.287 5/3.802 5	2.721 4/3.489 1	3.330 2/3.874 2	2.696 4/3.512 6	3.437 2/3.891 8

Informer 模型在髋关节与膝关节预测中表现最优。其预测误差显著低于 VMD-LSTM 和 VMD-ELMAN 模型。尤其在上楼梯场景下, VMD-Informer 的跨受试者预测误差优势更为明显, 进一步验证了多尺度 VMD 分解与 Informer 架构结合的显著优势。

3.4 跨个体泛化能力验证

为了验证模型的跨个体泛化能力, 本文采用留一受试

者法交叉验证, 基于包含 10 名受试者的数据集进行验证, 为充分体现模型对多样化生理特征的适应性, 选取 4 名具有显著体型差异的代表性受试者进行分析, 结果如表 6 所示。实验结果显示, VMD-Informer 在跨个体预测中表现最优, 较 VMD-Transformer 降低 8.4%。在代表性个体测试中, 该模型在不同体型受试者上均保持最优性能, 表明 VMD-Informer 具备良好的跨个体泛化能力。

表 5 不同步态下关节角度预测模型的 MAE

Table 5 MAE of joint angle prediction models under different gait patterns

模型	受试者 1(176 cm/70 kg) 平地行走/上楼梯		受试者 2(173 cm/68 kg) 平地行走/上楼梯		受试者 3(165 cm/55 kg) 平地行走/上楼梯	
	髋关节	膝关节	髋关节	膝关节	髋关节	膝关节
	VMD-ELMAN	4.013 8/5.681 8	5.187 4/5.881 7	3.876 9/5.601 4	5.009 1/5.800 2	3.949 0/7.118 0
VMD-LSTM	3.105 9/4.586 0	4.105 7/4.800 1	3.080 4/4.545 0	4.041 0/4.760 9	3.092 0/4.469 8	3.911 1/4.684 3
VMD-Transformer	2.612 4/3.702 2	3.304 6/3.842 2	2.582 0/3.640 0	3.250 2/3.801 2	2.562 4/3.602 0	3.201 0/3.642 6
VMD-Informer	2.128 2/2.819 8	2.630 0/2.862 0	2.177 1/2.791 3	2.664 2/2.839 4	2.157 1/2.810 1	2.649 8/2.753 4

表6 跨个体泛化能力验证结果

Table 6 Cross-Individual generalisation ability verification results

模型	整体性能			代表性受试者 RMSE(°)		
	平均 RMSE/(°)	变异 系数/%	受试者 1 (176 cm/70 kg)	受试者 3 (165 cm/55 kg)	受试者 5 (170 cm/65 kg)	受试者 10 (175 cm/78 kg)
VMD-ELMAN	5.23±0.31	5.93	5.18	5.35	5.10	5.29
VMD-LSTM	4.35±0.22	5.06	4.30	4.45	4.20	4.38
VMD-Transformer	3.95±0.19	4.81	3.92	4.05	3.80	3.98
VMD-Informer	3.62±0.17	4.70	3.58	3.65	3.45	3.72

4 结 论

本研究提出了一种基于 VMD-Informer 和表面肌电信号的下肢关节角度预测方法,通过 NGSPSO 算法实现 VMD 参数的自适应调整、PCA 特征降维,以及 Informer 模型长序列建模的协同优化,有效提升了利用 sEMG 预测下肢关节角度的精度。为验证该方法在实际场景中的表现,在平地行走和上楼梯两种典型步态场景中,选取了 3 名体型差异明显的受试者开展了系统测试。实验结果显示,所提方法在髋关节与膝关节角度预测的 RMSE 和 MAE 上,均显著优于传统的 VMD-LSTM 和 VMD-ELMAN 方法,同时还具备良好的跨个体泛化能力与实时响应性能。

在实验任务上目前仅针对平地行走和上楼梯两种常见步态情景,后续研究将进一步扩大患者样本规模,采用分组对照实验设计,在上下坡等更复杂的步态场景中,系统评估模型的适用性与泛化性能,同时探索 sEMG 与 IMU、足底力信号等多模态数据的融合方式;从而进一步拓展其在康复外骨骼、运动科学以及人机交互等领域的应用场景和实用性。

参考文献

- [1] 田宇,程枚,王青,等. 下肢康复机器人对脑卒中患者下肢运动功能障碍的影响研究[J]. 中国医药科学, 2025, 15(10):21-24.
TIAN Y, CHENG M, WANG Q, et al. Research on the impact of lower limb rehabilitation robots on lower limb motor dysfunction in stroke patients[J]. China Medicine and Pharmacy, 2025, 15(10): 21-24.
- [2] 彭小柯,赵国顺,韩诗雨,等. 外骨骼机器人对脑卒中患者平衡和下肢功能的影响 Meta 分析[J]. 康复学报, 2025, 35(2):197-204.
PENG X K, ZHAO G SH, HAN SH Y, et al. Effects of exoskeleton robots on balance and lower limb function of patients with stroke: A Meta-analysis[J]. Rehabilitation Medicine, 2025, 35(2): 197-204.
- [3] 董婷婷,王钰宏,李维朝,等. 外骨骼机器人在脊髓损伤患者康复领域中的应用综述[J]. 医疗卫生装备, 2025, 46(4):100-107.

DONG T T, WANG Y H, LI W CH, et al. Application progress of exoskeleton robots in rehabilitation for patients with spinal cord injury[J]. Chinese Medical Equipment Journal, 2025, 46(4): 100-107.

- [4] 黄秋慧,刘正芳. 基于表面肌电信号的康复护理机器人人机交互技术[J]. 自动化与仪器仪表, 2025(5): 167-171.
HUANG Q H, LIU ZH F. The key technology of human-machine interaction of rehabilitation nursing robot based on surface myoelectric signal[J]. Automation & Instrumentation, 2025(5): 167-171.
- [5] 朱旭,刘静,董泽萍,等. 基于表面肌电图手势动作意图识别的系统综述[J]. 中国康复理论与实践, 2022, 28(9):1032-1038.
ZHU X, LIU J, DONG Z P, et al. Gesture action intent recognition based on surface electromyography: A systematic review[J]. Chinese Journal of Rehabilitation Theory and Practice, 2022, 28(9): 1032-1038.
- [6] LYU H ZH, WANG Y R, HAO B D. Lower limb joint angle estimation based on surface electromyography signals[J]. Biomedical Signal Processing and Control, 2025, 104: 107563.
- [7] ALJEBORY K M, JWMAH Y M, MOHAMMED T S. Classification of EMG signals: Using DWT features and ANN classifier [J]. IAENG International Journal of Computer Science, 2024, 51(1): 23-31.
- [8] 吴田,蔡豪,梁加凯,等. 基于 ISSA-VMD 和二代小波的 sEMG 信号降噪研究[J]. 电子测量技术, 2023, 46(2):93-100.
WU T, CAI H, LIANG J K, et al. Research of noise reduction about sEMG signal based on ISSA-VMD and second generation wavelet [J]. Electronic Measurement Technology, 2023, 46(2): 93-100.
- [9] 李效,张明,张倩,等. 基于 CEEMD-VMD-SIST 算法的 sEMG 信号降噪方法[J]. 计算机测量与控制, 2024, 32(4):180-187.
LI X, ZHANG M, ZHANG Q, et al. Denoising method for sEMG signal based on CEEMD-VMD-SIST

- algorithm[J]. Computer Measurement & Control, 2024, 32(4): 180-187.
- [10] LI X H, NI R Y, JI ZH. ICG signal denoising based on ICEEMDAN and PSO-VMD methods[J]. Physical and Engineering Sciences in Medicine, 2024, 47(4): 1547-1556.
- [11] WEI CH F, WANG H, LU Y ZH, et al. Recognition of lower limb movements using empirical mode decomposition and k-nearest neighbor entropy estimator with surface electromyogram signals [J]. Biomedical Signal Processing and Control, 2022, 71: 103198.
- [12] 周智伟,陶庆,苏娜,等. 基于表面肌电信号的 CNN-LSTM 模型下肢动作识别[J]. 科学技术与工程, 2025, 25(7):2841-2848.
ZHOU ZH W, TAO Q, SU N, et al. Lower limb motion recognition based on surface electromyography and a CNN-LSTM fusion model [J]. Science Technology and Engineering, 2025, 25 (7): 2841-2848.
- [13] TANG G, SHENG J P, WANG D M, et al. Continuous estimation of human upper limb joint angles by using PSO-LSTM model[J]. IEEE Access, 2021, 9: 17986-17997.
- [14] LIU X Y, MA H X, WEI Q, et al. Continuous estimation of lower limb prosthesis based on GBDBN and BP network [C]. 2022 6th International Conference on Robotics and Automation Sciences, 2022: 270-276.
- [15] LI C, HE H, YIN SH Y, et al. Continuous angle prediction of lower limb knee joint based on sEMG[C]. 2021 IEEE International Conference on Recent Advances in Systems Science and Engineering, 2021: 1-6.
- [16] ZENG M, GU J, FENG Y. Motion prediction based on sEMG-Transformer for lower limb exoskeleton robot control[C]. 2023 International Conference on Advanced Robotics and Mechatronics, 2023: 864-869.
- [17] WAN R Y, ZHU Z N, CUI G H, et al. Continuous prediction of multi-joint angles based on Informer model using novel fused features [J]. Measurement Science and Technology, 2024, 36(1): 015709.
- [18] LU W, GAO L F, LI Z B, et al. Prediction of long-term elbow flexion force intervals based on the informer model and electromyography[J]. Electronics, 2021, 10(16): 1946.
- [19] 崔占贺,艾莉莎,马欣雨,等. 基于 1D-CNN-SVM 的下肢外骨骼步态信息识别研究[J]. 电子测量技术, 2025, 48(12):71-78.
CUI ZH H, AI L SH, MA X Y, et al. Gait information recognition study of lower limb exoskeleton based on 1D-CNN-SVM [J]. Electronic Measurement Technology, 2025, 48(12): 71-78.
- [20] 汪文森. 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 W M. Prediction of lower limb joint angle based on VMD-ELMAN electromyographic signals [J]. Computer Science, 2024, 51(3): 257-264.
- [21] 康玉祥,姜春英,秦运海,等. 基于改进 PSO 算法的机器人路径规划及实验[J]. 机器人, 2020, 42(1): 71-78.
KANG Y X, JIANG CH Y, QIN Y H, et al. Robot path planning and experiment with an improved PSO algorithm[J]. Robot, 2020, 42(1): 71-78.
- [22] 隋修武,高俊杰,梁天翼,等. 基于表面肌电信号及肌肉疲劳的上肢肌力预测[J]. 电子测量技术, 2024, 47(5):181-187.
SUI X W, GAO J J, LIANG T Y, et al. Prediction of upper extremity muscle strength based on surface EMG signal and muscle fatigue [J]. Electronic Measurement Technology, 2024, 47(5): 181-187.
- [23] 石欣,余可祺,敖钰民,等. 基于下肢 sEMG 的疲劳模糊增量熵表征方法研究[J]. 仪器仪表学报, 2024, 45(5):271-280.
SHI X, YU K Q, AO Y M, et al. Research on entropy of incremental fuzzy entropy representation model for lower limb fatigue based on sEMG [J]. Chinese Journal of Scientific Instrument, 2024, 45(5): 271-280.

作者简介

吴生彪(通信作者),副教授,主要研究方向为外骨骼机器人、脑肌电信号处理。

E-mail:957188030@qq.com

游涛,硕士,主要研究方向为外骨骼机器人、运动意图识别。

E-mail:290535321@qq.com

桂家政,硕士,主要研究方向为外骨骼机器人、运动控制研究。

E-mail:1816112444@qq.com