

基于卡尔曼滤波的小波去噪和 IWOA-ELM 的 颈肩肌肉疲劳分类方法^{*}

隋修武^{1,2} 付世雄^{1,2} 刘金雨^{1,2} 王涛^{1,2} 刘阳^{1,2}

(1. 天津工业大学机械工程学院 天津 300387; 2. 天津市现代机电装备技术重点实验室 天津 300387)

摘要: 针对采集的表面肌电信号噪声干扰多,以及缺少颈肩肌肉疲劳状态划分标准和分类模型的问题,本文提出了一种基于联合去噪和优化极限学习机的颈肩肌肉疲劳分类方法。首先,使用 AnyBody 建立颈肩骨骼肌肉生物力学模型,根据肌肉 pH 值和 RPE 劳累感知量表划分肌肉疲劳状态。采集 6 名健康青年人斜方肌上束疲劳状态下的表面肌电信号。然后,结合卡尔曼滤波和改进的小波阈值函数进行联合去噪,提取均方根、积分肌电值、平均功率频率、中值频率、瞬时平均频率、瞬时中值频率 6 个特征参数。最后,使用改进鲸鱼优化算法优化极限学习机的权值和阈值,建立 IWOA-ELM 颈肩肌肉疲劳分类模型。实验结果表明,联合去噪算法效果更佳,IWOA-ELM 模型训练集准确率为 96.3%,测试集准确率为 97.5%,均方根误差为 1.108,对于不同受试者分类模型准确率均高于 95%,因此本文提出的联合去噪算法和 IWOA-ELM 模型在颈肩肌肉疲劳分类方面具有优势。

关键词: 表面肌电信号;颈肩肌肉疲劳;卡尔曼滤波;小波阈值函数;鲸鱼优化算法;极限学习机算法

中图分类号: TN911.7; R741.044 文献标识码: A 国家标准学科分类代码: 510

Classification method for neck and shoulder muscle fatigue based on Kalman filter wavelet denoising and IWOA-ELM

Sui Xiuwu^{1,2} Fu Shixiong^{1,2} Liu Jinyu^{1,2} Wang Tao^{1,2} Liu Yang^{1,2}

(1. School of Mechanical Engineering, Tianjin University, Tianjin 300387, China;

2. Tianjin Modern Electromechanical Equipment Technology Key Laboratory, Tianjin 300387, China)

Abstract: Aiming at the problem of much noise interference in the acquired surface EMG signals and the lack of neck and shoulder muscle fatigue state classification standard and classification model, this paper proposes a neck and shoulder muscle fatigue classification method based on joint denoising and optimized limit learning machine. First, AnyBody was used to establish a biomechanical model of neck and shoulder skeletal muscles, and the muscle fatigue state was classified according to the muscle pH value and the RPE exertion perception scale. Surface EMG signals were collected from six healthy young people in the fatigue state of the upper trapezius muscle bundle. Then, joint denoising was performed by combining Kalman filtering and improved wavelet threshold function to extract six feature parameters: root mean square, integrated electromyography, mean power frequency, median frequency, instantaneous mean power frequency, and instantaneous median frequency. Finally, the weights and thresholds of Extreme Learning Machine were optimized using Improved Whale Optimization Algorithm to establish the IWOA-ELM neck and shoulder muscle fatigue classification model. The experimental results show that the joint denoising algorithm is more effective, and the accuracy of the IWOA-ELM model is 96.3% in the training set and 97.5% in the test set, with a root mean square error of 1.108, and the accuracy of the classification model is higher than 93% for different subjects, so the joint denoising algorithm and the IWOA-ELM model proposed in this paper have an advantage in classifying the fatigue of neck and shoulder muscles.

Keywords: sEMG signal; muscle fatigue; Kalman filtering; wavelet denoising; IWOA; ELM

0 引言

随着现代生活节奏的加快和工作方式的转变,颈肩肌肉疲劳问题日益受到关注。颈肩肌肉疲劳不仅会影响个体的舒适度和工作效率,而且长期累积可能导致严重的肌肉损伤甚至职业病^[1]。因此,对颈肩肌肉疲劳分类方法的研

究具有重要的现实意义,有助于个体健康和工作效率的提升。

表面肌电信号(surface electromyography signal, sEMG)作为一种非侵入性的生物电信号检测技术,能够实时、动态地反映肌肉的工作状态和疲劳程度^[2]。对sEMG信号的深入分析,可以提取出与肌肉疲劳紧密相关的特征信息,进而为客观、准确地评估肌肉疲劳状态提供科学依据^[3]。

在肌肉疲劳状态识别领域,国内外学者运用先进的信号处理技术与方法,结合机器学习算法,取得了显著的研究成果,实现了肌肉疲劳状态的准确分类与识别。姚贺龙等^[4]采用傅里叶分解方法提取傅里叶固有频带函数分量总功率占sEMG信号总功率的比例特征,使用支持向量机判断肌肉的疲劳和非疲劳状态。Al-Mulla等^[5]将局部肌肉疲劳划分为非疲劳态、疲劳过渡态、疲劳态,使用线性判别分析方法进行疲劳状态分类,分类准确率为90.37%。苑尧尧等^[6]使用改进的粒子群优化支持向量机分类器对心电信号和sEMG信号的融合特征进行疲劳识别,实现了对轻松、过渡和疲劳3种疲劳状态的准确识别。上述方法只是对肌肉疲劳状态的简单划分,目前缺乏对肌肉疲劳状态定量划分。Ouyang等^[7]使用改进的小波阈值方法对sEMG信号进行滤波,过滤后的sEMG信号具有较低的噪声基线,同时保留了信号的峰值强度,提高了后续实验分析的精度和可靠性。Dandumahanti等^[8]通过测量两块颈部肌肉的肌肉活动,发现上斜方肌在运动过程中表现出比胸锁乳突肌更多的肌肉活动,使用3种机器学习分类算法来区分中性姿势和屈颈姿势。王君洪等^[9]采用改进型小波阈值函数去噪方法对sEMG特征数据处理,使用长短时记忆神经网络对肌肉疲劳状态进行识别,实现了更准确的肌肉疲劳状态判断,但存在训练时间较长的缺点。刘光达等^[10]采用核主成分分析方法对sEMG信号的时域、频域和时频域等特征进行降维,使用支持向量机进行轻松与疲劳状态的分类识别,但分类模型在对多种疲劳状态分类时可能存在一定的局限性。

以上研究仍然存在一些问题和挑战。首先,在肌肉疲劳状态划分上,多数研究进行了简单的分类,即将肌肉状态划分为疲劳、非疲劳和疲劳过渡态。这种简单的划分方式虽然能够在一定程度上反应肌肉的疲劳程度,但无法提供更为详细的信息。其次,改进的小波阈值方法相比传统方法在处理sEMG时,虽然能有效滤除噪声并保留信号细节,但仍存在一些潜在的缺点,尤其是在sEMG信号质量不佳或噪声干扰较强的情况下。同时,颈肩肌肉疲劳分类对于分类模型的准确性要求极高,以确保精准地识别和区分不同疲劳状态,从而有效地预防肌肉损伤和提升训练效果。针对以往方法存在的问题,本文通过AnyBody建立颈肩骨骼肌肉模型,实现准确分析颈肩肌肉在不同负载下的受力,并对肌肉的疲劳状态进行详细划分。利用卡尔曼滤

波和改进的小波阈值函数联合去噪的方法对采集的sEMG信号进行去噪处理。建立改进的鲸鱼优化算法优化极限学习机的颈肩肌肉疲劳状态分类模型,以提升颈肩肌肉疲劳状态分类的准确性和客观性。

1 疲劳状态划分

1.1 肌肉疲劳等级

目前对肌肉疲劳等级的划分主要分两类,通过结合主观疲劳感受,一类是将肌肉疲劳简单的分为疲劳状态和非疲劳状态^[11],另一类是分为轻松态、疲劳过渡状态与疲劳状态^[12]。由于不同受测者对疲劳的感知具有差异性,本文采用肌肉pH值作为关键指标,对疲劳等级进行划分与界定。

1.2 颈肩肌肉模型

使用AnyBody软件建立颈肩肌肉模型,设置不同的负载条件,模拟运动过程颈肩肌肉所承受的力量。分析不同负载下肌肉力的变化情况。颈肩肌肉模型如图1所示。

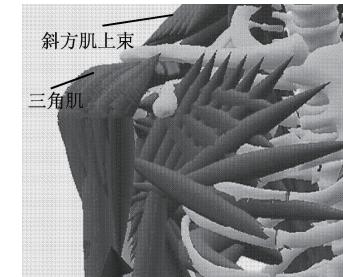


图1 颈肩肌肉模型

1.3 肌肉pH值

通过AnyBody分析计算出肌肉最大受力值百分比,根据Jebelli^[13]的研究模型,反推出肌肉pH值的计算方法,如式(1)所示。

$$pH = \begin{cases} 4.003 + 3.003 \times MVC\%, & MVC\% > 0.891 \\ 6.4 + 0.333 \times MVC\%, & MVC\% > 0.6 \\ 6.2 + 0.667 \times MVC\%, & MVC\% > 0 \end{cases} \quad (1)$$

其中,MVC%是肌肉最大收缩量(muscle maximal voluntary contraction,MVC)的百分比。

根据肌肉pH值的大小,同时参照劳累感知量表(rating of perceived exertion,RPE)^[14],将肌肉疲劳状态划分为轻松态、负重态、疲劳过渡态、深度疲劳态、疲劳态,分别对应5种不同的疲劳等级,如表1所示。当肌肉pH值下降至6.20~6.40左右,受试者应立即减轻训练强度并适当休息,以避免训练强度过高而引起的肌肉疲劳性损伤。

2 实验设计与数据采集

2.1 实验对象及设备

实验共招募6名惯用手为右手的健康青年人,其中男女比例1:1,确保了性别分布的均衡性。受试者平均年龄

表 1 肌肉疲劳等级

疲劳等级	肌肉 pH	RPE 量表	疲劳状态
I 级	6.7~7.0	6~7	轻松态
II 级	6.60~6.7	8~10	负重态
III 级	6.53~6.60	11~13	疲劳过渡态
IV 级	6.40~6.53	14~16	深度疲劳态
V 级	6.20~6.40	17~20	疲劳态

均为 24 岁,平均身高为 167.3 cm,平均体重为 65.8 kg。受试者在实验前 24 h 均未参加剧烈运动,以避免运动对实验结果产生干扰。使用 Kingfar ErgoLAB Ergonomic analysis system 采集斜方肌上束的 sEMG 信号,人体工效学分析软件 AnyBody、分析软件 MATLAB2022b,磨砂膏、75% 酒精棉、哑铃、Ag/AgCl 电极。实验示意图如图 2 所示。所有参与者均被告知实验的目的、过程、可能的风险和利益处,并在充分了解后签署了书面知情同意书。



图 2 实验示意图

2.2 实验步骤

在实验开始前,先用磨砂膏、75% 酒精棉擦拭受试者斜方肌的皮肤表面,除去皮肤表面的汗渍等,以减少皮肤阻抗的干扰。实验室内的温度保持在 23 ℃~26 ℃ 的恒温状态,以减少环境因素对实验结果的影响。

1) 数据采集开始之前,每位受试者需完成 3 组最大等长收缩的热身动作,每组的持续时间为 3 s,旨在激活和预热斜方肌上束肌肉。

2) 测定每位受试者斜方肌上束的 MVC。在测试过程中受试者要保持身体中立姿势,避免颈部过度前屈,以减少其他肌肉群的代偿作用。同时,受试者需伸直手臂,通过肩膀垂直向上的发力动作,尝试举起尽可能重的哑铃,直至斜方肌上束感到明显疲劳,无法继续维持耸肩动作为止。记录其所举哑铃的重量,并作为 MVC 测试的关键数据。利用建立的 AnyBody 颈肩肌肉模型,对数据进行分析和处理,以精确计算出受试者的斜方肌上束 MVC 值。

3) 利用 AnyBody 计算斜方肌上束在 10% MVC 时对应的哑铃重量,然后受试者进行最大等长收缩实验,直至无法维持耸肩动作,将肌电信号采集设备的采样频率设置为

1 000 Hz,采集 2 s 的肌电信号。并根据式(1)计算当前肌肉 pH 值。

4) 分别以斜方肌上束 20%、30%、40%、50%、60%、70%、80% 和 90% MVC 时计算对应的哑铃重量,重复步骤 3) 实验。

5) 采集 6 名健康青年人每人 20 天的实验数据,受试者每天进行 9 组(10%、20%、30%、40%、50%、60%、70%、80% 和 90% MVC)采集实验,每组实验之间受试者休息 30 min,共采集 1 080 组实验数据。

3 数据预处理

颈肩肌电信号属于非平稳微弱生物电信号,主要频率分布在 50~150 Hz 之间。在实际采集颈肩肌电信号的过程中,由于各种因素的影响,比如环境噪声、设备本身的干扰以及人体自身的其他生物电信号等,这些干扰噪声会混入到有用的肌电信号中,导致信号的采集质量下降,甚至可能掩盖掉一些重要的信息^[15]。为了解决这个问题,小波去噪是一种常用的方法。它通过在小波变换的基础上设定阈值,将低于该阈值的小波系数视为噪声进行去除,从而得到较为纯净的信号。然而,当小波去噪面对低信噪比环境时,其去噪效果往往并不理想,难以有效地从噪声中提取出有用的肌电信号。

本研究采用了一种更为综合和高效的信号处理方法。首先,利用卡尔曼滤波,通过预测和更新步骤来估计肌电信号的真实值,并减少随机噪声的干扰。卡尔曼滤波可以有效地处理非平稳信号,并能够在不确定的环境下提供较为准确的信号估计。此外,还采用了改进的小波阈值函数来进一步提高去噪效果。通过对传统小波阈值函数的改进,使其能够更好地适应低信噪比环境,更准确地识别并去除噪声成分,从而保留更多有用的肌电信号。

3.1 卡尔曼滤波

卡尔曼滤波是一种时域分析方法,它通过状态空间模型来寻求最优滤波解决方案。所谓最优滤波,是指在保证估计误差方差最小的前提下,对信号或状态进行的最优估计^[16]。

卡尔曼滤波模型的基本结构包括 2 个方面:状态方程和观察方程,其表达形式为:

$$x_k = Ax_{k-1} + Bu_{k-1} + \omega_k \quad (2)$$

$$z_k = Cx_k + v_k \quad (3)$$

式中: x 为状态变量; A 为模型状态转移矩阵; u 为模型控制输入; z 为观测变量; B 为模型控制输入矩阵; C 为观测矩阵;假设过程噪声 ω_k 和测量噪声 v_k 相互独立,并且是高斯白噪声,服从正态分布,期望值是 0,协方差分别是 Q 和 R ,即 $\omega_k \sim N(0, Q)$ 和, $v_k \sim N(0, R)$,本文中没有控制输入 $u=0$ 。

利用卡尔曼滤波对采集的 sEMG 信号进行去噪的过程分为 2 个步骤:预测和更新。

预测:

$$\hat{x}_k^- = \mathbf{A}\hat{x}_{k-1} \quad (4)$$

$$\mathbf{P}_k^- = \mathbf{A}\mathbf{P}_{k-1}\mathbf{A}^T + \mathbf{Q} \quad (5)$$

更新:

$$\mathbf{K}_k = \mathbf{P}_k^- \mathbf{C}^T (\mathbf{C}\mathbf{P}_k^- \mathbf{C}^T + \mathbf{R})^{-1} \quad (6)$$

$$\hat{x}_k = \hat{x}_k^- + \mathbf{K}_k (z_k - \mathbf{C}\hat{x}_k^-) \quad (7)$$

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{C}) \mathbf{P}_k^- \quad (8)$$

式中: \hat{x}_{k-1} 为上一时刻的状态; \hat{x}_k^- 为当前时刻状态; \mathbf{P}_{k-1} 为上一时刻的协方差; \mathbf{P}_k^- 为先验误差协方差; \mathbf{K}_k 为卡尔曼增益; \mathbf{P}_k 为后验误差协方差; \hat{x}_k 为后验估计值。

通过不断重复预测和更新步骤,根据新的测量值和系统模型,不断优化对系统状态的估计,从带有噪声的 sEMG 信号中提取出有用的信息,降低噪声对信号的影响。

3.2 小波阈值去噪

小波变换理论在信号处理领域中应用广泛,特别是在对生物电信号这类非平稳、非线性信号的分析中,小波变换具有独特的优势^[17]。小波阈值去噪是一种基于小波系数的大小来去除噪声的方法。原始信号经小波分解后有用信号和噪声信号表现出的小波系数不同,通过选取合适的阈值甄别小波系数的大小,以此来过滤掉噪声。相关研究发现 Daubechies 小波基函数具有平滑性和多尺度分解特性,能够更好地处理 sEMG 信号^[18]。本文选取小波基函数 db45,通过实验对比选取分解层为 4 层。

硬阈值函数和软阈值函数是常用的两种小波阈值去噪算法^[19],分别由以下数学表达式定义:

$$f(\omega_{j,k}) = \begin{cases} \omega_{j,k}, & |\omega_{j,k}| \geq \lambda \\ 0, & |\omega_{j,k}| < \lambda \end{cases} \quad (9)$$

$$f(\omega_{j,k}) = \begin{cases} \text{sign}(\omega_{j,k})(|\omega_{j,k}| - \lambda), & |\omega_{j,k}| \geq \lambda \\ 0, & |\omega_{j,k}| < \lambda \end{cases} \quad (10)$$

式中: $\omega_{j,k}$ 为小波分解系数; $f(\omega_{j,k})$ 为阈值处理后的小波系数; λ 为对每层小波系数处理时的阈值,通常选取阈值 $\lambda = \sigma \sqrt{2 \lg N}$; N 为被处理信号的采样点个数。

硬阈值函数在处理信号时,由于其非连续的特性,通常在阈值 λ 附近导致重构信号出现吉布斯现象,即信号在该点附近出现不自然的剧烈变化^[20]。软阈值函数则通过其连续且平滑的特性,避免了吉布斯现象的发生,从而提供了更加自然的信号重构。然而,这种平滑处理可能会带来边缘模糊和失真的问题^[21]。为解决硬阈值函数和软阈值函数在 sEMG 信号去噪过程中存在的问题,本文从渐进性、偏差性、连续性 3 个方面对阈值函数进行改进,提出了一种改进的阈值函数,表达式为:

$$f(\omega_{j,k}) = \begin{cases} \text{sign}(\omega_{j,k}) \left(|\omega_{j,k}| - \frac{\lambda^{k+1}}{|\omega_{j,k}|^k + e^{m(|\omega_{j,k}| - \lambda)}} - 1 \right), & |\omega_{j,k}| \geq \lambda \\ 0, & |\omega_{j,k}| < \lambda \end{cases} \quad (11)$$

式中: m 为调整参数。

通过比较硬阈值、软阈值以及改进的小波阈值的函数曲线发现,改进后的小波阈值函数连续性更好,如图 3 所示。

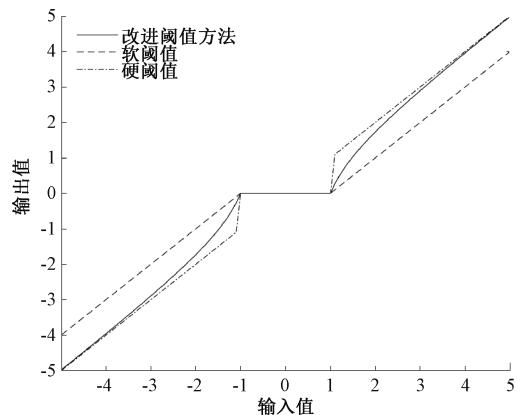


图 3 阈值函数对比曲线

当 $|\omega_{j,k}| \rightarrow \lambda$ 时, $\lim_{|\omega_{j,k}| \rightarrow \infty} (f(\omega_{j,k}) - \omega_{j,k}) = 0$, 证明改进后的小波阈值函数相较于软阈值函数偏差更小,具有能够保持原始有用信号的优点。当 $|\omega_{j,k}| \rightarrow \lambda$ 时, $\lim_{|\omega_{j,k}| \rightarrow \lambda} f(\omega_{j,k}) = 0$, 证明具有良好的连续性,改进的阈值函数优于硬阈值、软阈值函数。

3.3 联合去噪

通过利用卡尔曼滤波对 sEMG 信号进行预处理,可以有效地去除部分噪声和干扰,提高信号的信噪比。随后,再利用改进的小波阈值函数对滤波后的信号进行去噪,可以提升信号的质量。联合去噪的方法结合了卡尔曼滤波在信号平滑和去噪方面的优势以及改进的小波阈值方法在信号细节保留方面的特点,为 sEMG 信号的处理提供了一种更为有效和可靠的方案。

联合去噪方法主要包括以下步骤:首先,应用状态空间模型对采集的表面肌电信号进行滤波;其次,选取合适的小波基以及合适的分解层数,对每一层进行小波变换,获得小波系数;然后,根据改进的小波阈值函数,对小波系数进行处理,以去除噪声成分;最后,对经过改进的小波阈值函数处理的系数进行重构,可以获得降噪后的 sEMG 信号。联合去噪方法结合了小波变换和卡尔曼滤波的优点,提高了去噪效果。

3.4 特征提取

在表面肌电信号中提取的特征值对颈肩疲劳检测的准确性起着关键作用。目前,时域、频域和时频域是基于 sEMG 的信号处理中的主要类型^[22]。

本文选取时域特征常用指标均方根值(root mean square, RMS)和积分肌电值(integrated electromyography, iEMG)对 sEMG 分析。

均方根值:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (12)$$

积分肌电值:

$$iEMG = \sum_{i=1}^N |x_i| \quad (13)$$

式中: x_i 为肌电信号序列; N 为计算的序列长度。

选取频域特征常用指标平均功率频率 (mean power frequency, MPF) 和中值频率 (median frequency, MF) 对 sEMG 分析。

平均功率频率:

$$MPF = \frac{\int_0^{\infty} f PSD(f) df}{\int_0^{\infty} PSD(f) df} \quad (14)$$

中值频率:

$$MF = \frac{1}{2} \int_0^{\infty} PSD(f) df \quad (15)$$

式中: f 为 sEMG 的频率; $PSD(f)$ 为功率谱密度。

时频域特征对肌肉疲劳状态的估计至关重要, 能够在保留信号时域特性的同时反映信号的频域特性。选取瞬时平均频率 (instantaneous mean power frequency, IMPF) 和瞬时中值频率 (instantaneous median frequency, IMF) 对 sEMG 信号分析^[23]。

瞬时平均频率:

$$IMPF = \frac{\int_0^{\infty} f PSD(t, f) df}{\int_0^{\infty} PSD(t, f) df} \quad (16)$$

瞬时中值频率:

$$IMF = \frac{1}{2} \int_0^{\infty} PSD(t, f) df \quad (17)$$

式中: $PSD(t, f)$ 为频率和时间的二维函数。

4 疲劳分类模型

4.1 ELM 极限学习机

极限学习机 (extreme learning machine, ELM) 是一种单隐层前馈神经网络, 其结构包括 3 个主要部分: 输入层、隐含层和输出层^[24], 如图 4 所示。与其他传统前馈神经网络相比, ELM 最大的优点是训练时间短, 不需要复杂的人为介入。ELM 的输入层的权重、隐藏层的阈值均为随机生成, 从而提高了算法的学习效率和泛化性能^[25]。

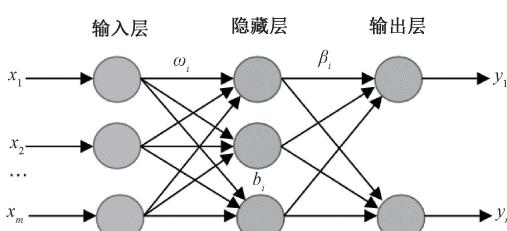


图 4 极限学习机算法结构

ELM 分类模型为:

$$\mathbf{Y} = \sum_{i=1}^L \beta_i g(\omega_i \mathbf{X} + b_i) \quad (18)$$

式中: $g(x)$ 为激活函数; 第 i 个输入层与隐含层之间的输入权值用 ω_i 表示; 第 i 个隐含层的阈值用 b_i ; 隐含层和输出层之间的权值用 β_i 表示; $\mathbf{X} = (x_1, x_2, \dots, x_m)^T$, \mathbf{X} 为训练样本的输入; $\mathbf{Y} = (y_1, y_2, \dots, y_n)^T$, \mathbf{Y} 为训练样本的输出。

4.2 WOA 鲸鱼优化算法

鲸鱼优化算法 (whale optimization algorithm, WOA) 是一种新型群体智能优化搜索策略^[26]。与其他群体智能优化算法相比, WOA 具有搜索能力强、参数设置简单的优点。其核心在于 3 个机制: 包围猎物、捕食猎物、搜索猎物^[27-28]。

1) 包围猎物

鲸群可以相互配合, 通过不断更新位置接近猎物, 收缩包围圈, 当 $p < 0.5$ 且 $|\mathbf{A}| < 1$, 通过当前最优候选解的位置更新目标猎物的搜索位置。公式如下:

$$D_1 = |\mathbf{C} \cdot \mathbf{X}^*(t) - \mathbf{X}(t)| \quad (19)$$

$$\mathbf{X}(t+1) = \mathbf{X}^*(t) - \mathbf{A}D_1 \quad (20)$$

式中: t 为当前迭代; \mathbf{X} 为位置向量; \mathbf{X}^* 表示当前最优解的位置向量; $\mathbf{A} = 2ar_1 - a$; $\mathbf{C} = 2r_2$; $a = 2 - \frac{2t}{t_{\max}}$; r_1 和 r_2 为 $[0, 1]$ 中的随机向量; a 为从 2 线性递减到 0 的收敛因子; t_{\max} 为最大迭代次数。

2) 捕食猎物

当 $p \geq 0.5$, 鲸鱼根据螺旋轨迹来完成位置更新并包围猎物, 更新公式如下:

$$D_2 = |\mathbf{X}^*(t) - \mathbf{X}(t)| \quad (21)$$

$$\mathbf{X}(t+1) = D_2 \cdot e^{bL} \cdot \cos(2\pi L) + \mathbf{X}^*(t) \quad (22)$$

式中: D_2 为鲸鱼到猎物之间的距离; b 为用来描述鲸鱼捕猎路径的常数; L 为 $[-1, 1]$ 的随机数。

3) 搜索猎物

当更新概率 $p < 0.5$ 且 $|\mathbf{A}| \geq 1$ 时, 猎物在鲸鱼攻击范围外, 则鲸鱼会游向随机鲸, 此时采用随机搜索方法, 公式如下:

$$D_3 = |\mathbf{C} \cdot \mathbf{X}_{rand}(t) - \mathbf{X}(t)| \quad (23)$$

$$\mathbf{X}(t+1) = \mathbf{X}_{rand}(t) - \mathbf{A}D_3 \quad (24)$$

式中: D_3 为当前鲸鱼与随机鲸鱼之间的距离; \mathbf{X}_{rand} 为当前随机鲸鱼的位置。

WOA 相比灰狼优化算法 (grey wolf optimization, GWO)、粒子群优化算法 (particle swarm optimization, PSO) 和遗传算法 (genetic algorithm, GA), 其优化速度更快、精度更高^[29]。但是 WOA 算法存在局部最优和收敛缓慢的问题。针对这一问题, 本文采用一种新的混合策略对鲸鱼算法进行改进, 通过对其收敛因子进行优化, 并在此基础上引入自适应权值, 使其具有更快的收敛性和更强的寻优能力。

传统鲸鱼优化算法的性能很大程度取决于系数矩阵 \mathbf{A} 。收敛因子 a 决定 \mathbf{A} 的取值, 并且 a 是线性下降的。为了提高 WOA 算法的收敛性, 提出了一种非线性函数, 并对

其计算公式进行了改正:

$$a^* = \left(2 - \frac{2t}{t_{\max}}\right) \left(1 - \sin\left(\frac{\pi}{2} \cdot \frac{t}{t_{\max}}\right)\right) \quad (25)$$

在鲸鱼位置更新时,为避免陷入局部最优,从而引入一种自适应权值。改进后的鲸鱼位置更新公式为:

$$X(t+1) =$$

$$\begin{cases} \delta X^*(t) - AD_1, & p < 0.5, |A| < 1 \\ \epsilon X^*(t) + D_2 \cdot e^{BL} \cdot \cos(2\pi L), & p \geq 0.5 \end{cases} \quad (26)$$

$$\delta = \sin\left(\frac{\pi}{2} \cdot \frac{t}{t_{\max}}\right) \quad (27)$$

$$\epsilon = 1 - \sin\left(\frac{\pi}{2} \cdot \frac{t}{t_{\max}}\right) \quad (28)$$

式中: δ, ϵ 为自适应权重系数。 $p < 0.5$ 时,随迭代次数的增加, δ 呈增大趋势,从而包围猎物阶段充分利用最优解 X^* ; $p \geq 0.5$ 时,随迭代次数的增加, ϵ 呈减小趋势,使得鲸鱼在捕食猎物阶段更容易接近猎物。

4.3 IWOA-ELM 分类模型

针对 ELM 模型在训练过程中因随机性导致的稳定性问题,本文提出一种 IWOA-ELM 分类模型。在该模型中,优化 WOA 算法的收敛因子并且引入自适应权值提高了算法的性能。改进后的 WOA 算法优化 ELM 模型的输入层权值以及隐含层阈值。改进后的 WOA 算法通过其 3 个机制,不断迭代更新鲸鱼的位置向量,并在每一步中确保鲸鱼位置的最优性。最终,利用改进后的 WOA 算法寻找出具有最优适应性的最优解,并将其作为模型的输入层权值和隐藏层阈值,以获得 IWOA-ELM 模型的分类结果。模型流程如图 5 所示。

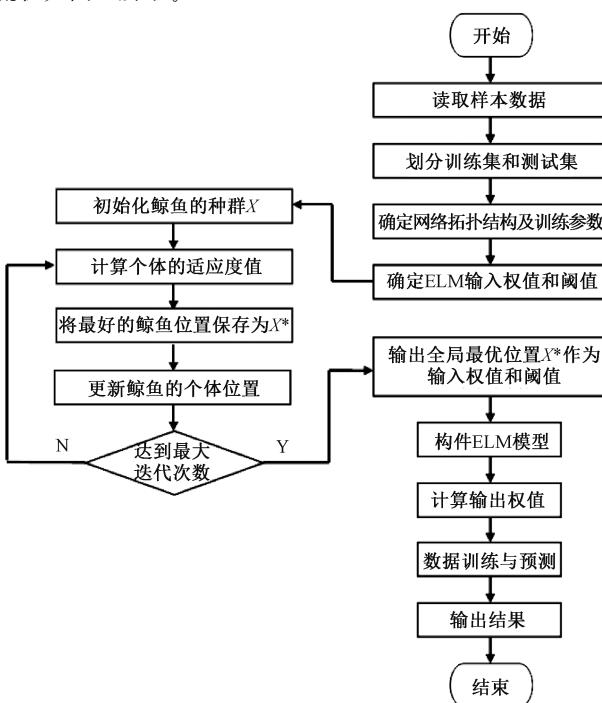


图 5 IWOA-ELM 模型流程图

5 结果与讨论

5.1 信号去噪对比

为了对传统阈值函数与提出的联合去噪方法在滤波效果上进行对比研究,选用正弦波信号作为原始信号,在正弦波信号中加入高斯白噪声模拟噪声干扰。如图 6 所示,原始正弦信号、加入高斯白噪声后的信号,以及经过 3 种去噪方法滤波后的信号对比。为准确评估各种去噪方法的性能,采用信噪比 (signal to noise ratio, SNR)、均方误差 (mean squared error, MSE) 和互相关系数 (normalized cross correlation, NCC) 作为评价指标,如表 2 所示。

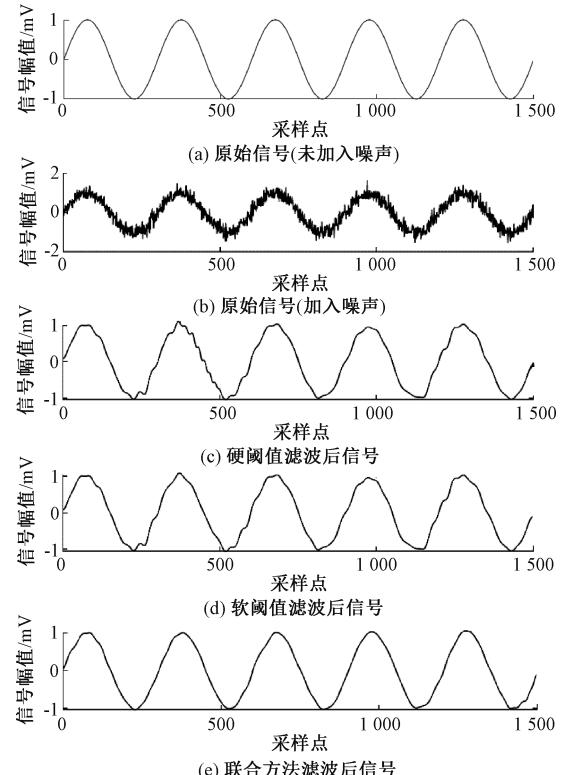


图 6 对正弦信号去噪效果

表 2 去噪方法的评价指标

去噪方法	SNR	MSE	NCC
硬阈值函数去噪	19.198	0.003 6	0.87
软阈值函数去噪	20.064	0.003 9	0.89
联合方法去噪	23.988	0.002 5	0.997

由图 6 可知,采用联合方法去噪后的信号与原始信号重合度最高。从表 2 可以看出,联合去噪的方法比硬阈值函数、软阈值函数的 SNR 最高, MSE 最低, NCC 最大,证明所提出的去噪方法优于传统阈值去噪。

设置采样频率为 1 000 Hz, 使用卡尔曼滤波的小波阈值函数与传统硬阈值、软阈值函数 3 种去噪方法对采集的 sEMG 信号进行滤波,如图 7~10 所示。通过对比发现,联

合去噪方法相较于硬阈值函数、软阈值函数去噪效果更好,去噪后的信号含噪声较少,保留了较多的有用信息。

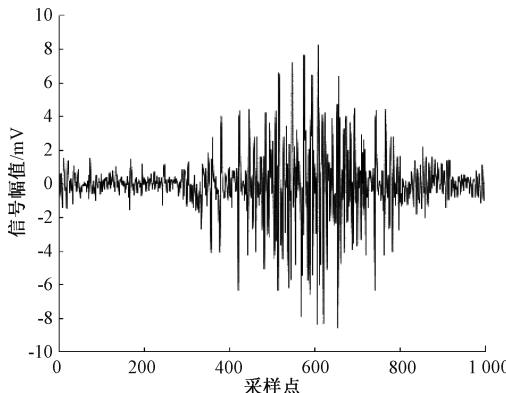


图 7 原始信号

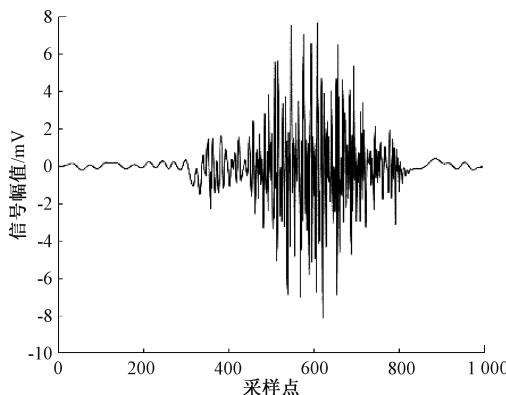


图 8 硬阈值函数去噪

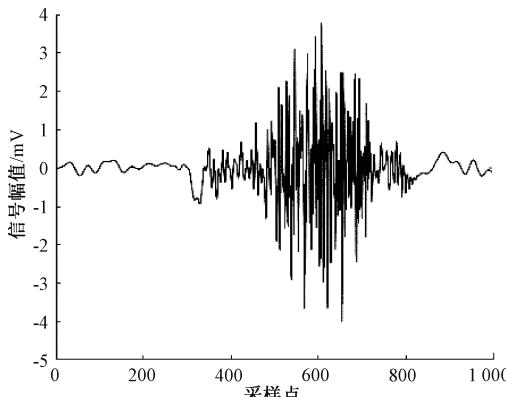


图 9 软阈值函数去噪

5.2 特征值相关性分析

为验证特征值与肌肉 pH 值划分的肌肉疲劳等级之间的相关性,对提取 sEMG 的时域、频域、时频域特征值数据进行皮尔逊相关性检验^[30],如表 3 所示。

由表 3 可知,相关系数 r 均大于 0.5,所以提取的 6 个特征值与划分的肌肉疲劳等级存在相关性。

5.3 分类模型评价

为验证所提出的 IWOA-ELM 分类模型的性能,将数

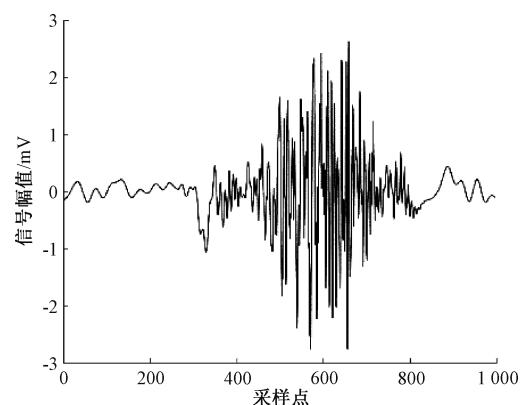
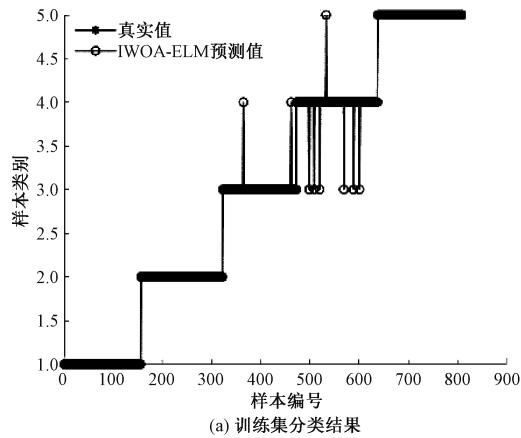


图 10 联合方法去噪

表 3 特征值与疲劳等级相关系数

特征值	r
iEMG	0.86
RMS	0.90
MF	0.86
MPF	0.85
IMPF	0.89
IMF	0.87

据样本划分为训练集和测试集,其比例为 3:1。训练集与测试集分类结果如图 11(a)、(b) 所示。



(a) 训练集分类结果

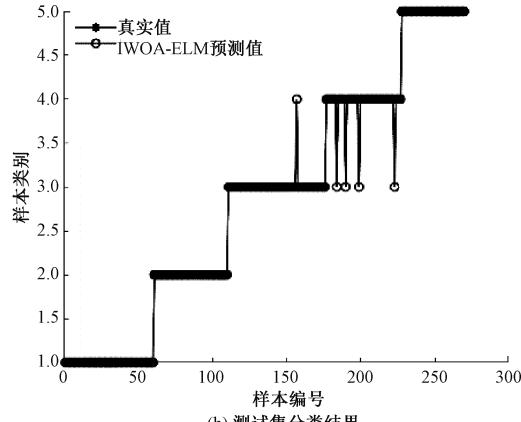


图 11 分类结果对比

将所提的IWOA-ELM分类模型与WOA-ELM、GWO-ELM、PSO-ELM、GA-ELM分类模型进行了比较,如表4所示。

表4 不同模型对比

模型	训练准确率/%	测试准确率/%	RMSE
IWOA-ELM	96.3	97.5	1.108
WOA-ELM	94.3	95.1	1.218
GWO-ELM	89.3	89.5	1.349
PSO-ELM	88.3	88.4	1.285
GA-ELM	87.3	87.9	1.326

从表4中可以看出,IWOA-ELM分类模型训练集准确率为96.3%和测试集准确率为97.5%,均方根误差为1.108,说明IWOA-ELM准确性优于其他分类模型。为验证不同受试者在分类模型下的准确性,将5种不同的分类模型应用到6位受试者并计算分类准确性,以进行详细比较,如图12所示。

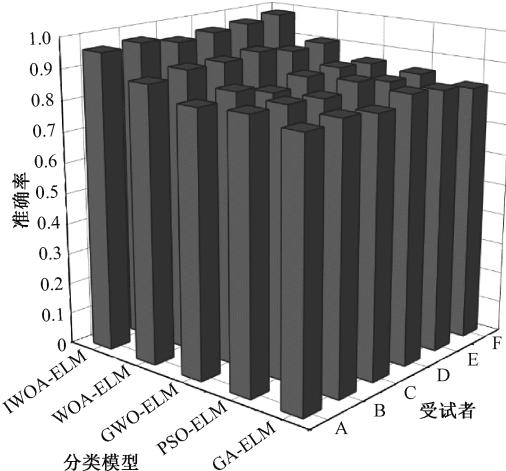


图12 分类模型的准确性

从图中可以得出,所提出的IWOA-ELM分类模型在颈肩肌肉疲劳分类方面具有最佳的分类性能,准确率均高于95%。表明IWOA可以快速地找出最适合ELM的权值和阈值,从而实现肌肉疲劳分类模型的最优性能。所提出的IWOA-ELM模型可用于各种运动的肌肉疲劳状态进行分类,同时,在康复训练、运动检测等相关应用中具有重要作用。

6 结论

针对采集的表面肌电信号噪声干扰多,以及缺少颈肩肌肉疲劳状态划分标准和分类模型的问题,本文提出了一种基于联合去噪和改进的鲸鱼优化算法优化极限学习机的颈肩肌肉疲劳分类方法。利用AnyBody建立颈肩骨骼肌肉模型,分析颈肩肌肉力,同时改进肌肉疲劳状态划分方式,将肌肉划分为轻松态、负重态、疲劳过渡态、深度疲劳

态、疲劳态,为后续的疲劳分析提供了更为精细的划分标准。结合卡尔曼滤波和改进的小波阈值函数进行联合去噪,研究表明,该方法去噪效果更好,显著提高了信号的质量,为后续分析提供了更为准确的数据基础。提取去噪后信号的时域特征、频域特征以及时频域特征参数,并作为分类模型的输入。建立的IWOA-ELM分类模型相较于WOA-ELM、GWO-ELM、PSO-ELM、GA-ELM具有更优的分类性能,还为后续的颈肩肌肉疲劳监测和预防提供了更为有效的工具。本文主要关注颈肩肌肉疲劳状态,下一步是将对身体各个部位的肌肉疲劳状态进行准确分析,并探索肌肉疲劳分类在康复机器人中的应用。

参考文献

- [1] KAZEMINASAB S, NEJADGHADERI S A, AMIRI P, et al. Neck pain: Global epidemiology, trends and risk factors [J]. BMC Musculoskeletal Disorders, 2022, 23(1):1-13.
- [2] ZHENG M, CROUCH M S, EGGLESTON M S. Surface electromyography as a natural human-machine interface: A review[J]. IEEE Sensors Journal, 2022, 22(10): 9198-9214.
- [3] KARTHICK P A, NAVANEETHAKRISHNA M, PUNITHA N, et al. Analysis of muscle fatigue conditions using time-frequency images and GLCM features [J]. Current Directions in Biomedical Engineering, 2016, 2(1): 483-487.
- [4] 姚贺龙,吕东瀛,张勇,等.基于傅里叶分解方法的肌肉疲劳状态分类研究[J].电子测量与仪器学报,2023,37(6):48-58.
- [5] AI-MULLA R M, SEPULVEDA F, COLLEY M. An autonomous wearable system for predicting and detecting localised muscle fatigue[J]. Sensors, 2011, 11(2): 1542.
- [6] 苑尧尧,曹佃国,李聪,等.融合心电与表面肌电特征的下肢康复疲劳估计方法[J].生物医学工程学杂志,2020,37(6):1056-1064.
- [7] OUYANG C Y, CAI L M, LIU B, et al. An improved wavelet threshold denoising approach for surface electromyography signal [J]. EURASIP Journal on Advances in Signal Processing, 2023, 2023(1): 108.
- [8] DANDUMAHANTI B P, SUBRAMANIYAM M. Wireless sEMG sensor for neck muscle activity measurement and posture classification using machine learning[J]. IEEE Sensors Journal, 2023, 23 (24): 31220-31228.
- [9] 王君洪,孙少明,孙怡宁,等.基于改进小波去噪和长短时记忆网络的肌肉疲劳识别模型研究[J].生物医学工程学杂志,2022,39(3):507-515.
- [10] 刘光达,董梦坤,张守伟,等.基于KPCA-SVM的表面

- 肌电信号疲劳分类研究[J]. 电子测量与仪器学报, 2021, 35(10):1-8.
- [11] KRISHNAMANI D B, KARTHICK P A, SWAMINATHAN R. Variational mode decomposition based differentiation of fatigue conditions in muscles using surface electromyography signals[J]. IET Signal Processing, 2020, 14(10): 745-753.
- [12] 赵娟. 表面肌电信号的去噪及肌疲劳评价研究[D]. 武汉: 中国地质大学, 2023.
- [13] JEBELLI H, SEO J O, HWANG S, et al. Physiology-based dynamic muscle fatigue model for upper limbs during construction tasks [J]. International Journal of Industrial Ergonomics, 2020, 78:102984.
- [14] NI W G, ZHANG Y X, LI X Y, et al. A study on the relationship between RPE and sEMG in dynamic contraction based on the GPR method[J]. Electronics, 2022, 11(5): 691.
- [15] 张锐浩, 李昀泽, 党立志, 等. 基于 AD8232 的表面肌电信号采集系统设计[J]. 电子测量技术, 2023, 46(6): 173-177.
- [16] 刘芬, 范洪强, 吕涛, 等. 基于卡尔曼滤波的含噪声小样本数据处理方法[J]. 上海大学学报, 2022, 28(3): 427-439.
- [17] 王振宇, 向泽锐, 支锦亦, 等. 多谱自适应小波和盲源分离耦合的生理信号降噪方法[J]. 北京航空航天大学学报, 2024, DOI:10.13700/j.bh.1001-5965.2023-0179.
- [18] 张亚奇. 基于表面肌电信号的语音识别研究[D]. 南京: 南京邮电大学, 2023.
- [19] 黄健, 宋树祥, 杨军, 等. 基于 EEMD—小波阈值的分布式测温系统的研究[J]. 电子测量技术, 2022, 45(11): 104-108.
- [20] 杨承金, 聂春燕, 王慧宇, 等. 基于小波改进阈值的肌电干扰降噪研究与效果评估[J]. 电子测量技术, 2021, 44(22): 80-86.
- [21] GUO H, YUE L H, SONG P, et al. Denoising of an ultraviolet light received signal based on improved wavelet transform threshold and threshold function[J]. Applied Optics, 2021, 60(28): 8938-8990.
- [22] SUN J Q, LIU G D, SUN Y B, et al. Application of surface electromyography in exercise fatigue: a review[J]. Frontiers in Systems Neuroscience, 2022, DOI: 10.3389/fnsys.2022.893275.
- [23] YOUSIF H, NORASMADI A R, SALLEH A F, et al. Assessment of muscles fatigue during 400-meters running strategies based on the surface EMG signals[J]. Journal of Biomimetics, Biomaterials and Biomedical Engineering, 2019, 42: 1-13.
- [24] 吴飞, 李霆, 张航, 等. 基于 CWOA-ELM 的短期电力负荷预测研究[J]. 电子测量技术, 2020, 43(4): 88-92.
- [25] 刘美容, 曾黎, 何怡刚, 等. 基于 LMD 多尺度熵和极限学习机的模拟电路故障诊断[J]. 电子测量与仪器学报, 2017, 31(4): 530-536.
- [26] 张志勇, 陆金桂, 张猛. 基于 WOA-BP 神经网络的磨煤机出粉量估算[J]. 电子测量技术, 2022, 45(22): 157-161.
- [27] 许德刚, 王再庆, 郭奕欣, 等. 鲸鱼优化算法研究综述[J]. 计算机应用研究, 2023, 40(2): 328-336.
- [28] 张国治, 陈康, 方荣行, 等. 基于 DGA 与鲸鱼算法优化 LogitBoost-决策树的变压器故障诊断方法[J]. 电力系统保护与控制, 2023, 51(7): 63-72.
- [29] 惠阿丽, 鹿伟强, 荣相, 等. 基于 Park-WPT 和 WOA-LSSVM 的异步电动机故障诊断方法[J]. 工矿自动化, 2021, 47(12): 106-113.
- [30] 钟旭, 张弼, 李纪桅, 等. 面向外骨骼的下肢多模态协同量化分析与康复评估方法[J]. 生物医学工程学杂志, 2023, 40(5): 953-964.

作者简介

隋修武(通信作者), 博士, 副教授, 主要研究方向为智能控制、人机交互、康复机器人等。

E-mail:13073183855@163.com