

DOI: 10.13382/j.jemi.B2306358

基于傅里叶分解方法的肌肉疲劳状态分类研究*

姚贺龙 吕东浩 张 勇 张 鹏 曹 震
(内蒙古科技大学信息工程学院 包头 014010)

摘 要:由于表面肌电(sEMG)信号具有非线性和非平稳性,导致传统的肌肉疲劳分类方法存在局限性,基于此提出一种基于傅里叶分解方法(FDM)和机器学习相结合的肌肉疲劳分类方法。使用 FDM 将 sEMG 信号分解为一系列傅里叶固有频带函数(FIBF),确定最优分解水平,利用 FDM 提取各 FIBF 分量总功率占 sEMG 信号总功率的比例(FTPR)作为分类特征,对比各机器学习分类算法的有效性和数据长度对分类准确率的影响。研究表明基于 FDM 的特征提取方法能够有效的识别肌肉疲劳状态,在数据长度为 3 000 且 FDM 的 10 层分解水平下,使用支持向量机分类器,得到了 98.17% 的平均分类准确率。对每个 FIBF 分量单独进行分析,发现在第 5 个 FIBF 分量下的 FTPR 有最好的类可分性,肌肉疲劳时第 1~2 分量的 FTPR 会变大,第 4~10 分量的 FTPR 会变小,即当肌肉疲劳时 sEMG 信号 0~117 Hz 区间的频率幅度会增加,175.5~585 Hz 区间的频率幅度会下降。通过对比不同特征提取方法的肌肉疲劳分类效果,实验结果表明 FDM 和 FTPR 特征能够显著提高分类准确率。因此,所提方法可用于肌肉疲劳状态识别。

关键词: 肌肉疲劳;表面肌电信号;傅里叶分解方法;机器学习;支持向量机

中图分类号: TN911.7 **文献标识码:** A **国家标准学科分类代码:** 510.40

Study of muscle fatigue state classification based on Fourier decomposition method

Yao Helong Lyu Donghao Zhang Yong Zhang Peng Cao Zhen
(School of Information Engineering, Inner Mongolia University of Science & Technology, Baotou 014010, China)

Abstract: Due to the nonlinearity and non-smoothness of surface electromyography (sEMG) signals, which leads to the limitations of traditional muscle fatigue classification methods, a muscle fatigue classification method based on the combination of Fourier decomposition method (FDM) and machine learning is proposed based on this. The FDM is used to decompose the sEMG signal into a series of Fourier intrinsic band functions (FIBF), determine the optimal decomposition level, extract the ratio of the total power of each FIBF component to the total power of the sEMG signal (FTPR) as classification features using the FDM, and compare the effectiveness of each machine learning classification algorithm and the effect of data length on the classification accuracy. It was shown that the FDM-based feature extraction method can effectively identify muscle fatigue states, and an average classification accuracy of 98.17% was obtained using a support vector machine classifier with a data length of 3 000 and a 10-level decomposition level of FDM. Each FIBF component was analyzed individually, and it was found that the FTPR under the 5th FIBF component had the best class separability, and the FTPR of the 1st to 2nd components would become larger when muscle fatigue was present, and the FTPR of the 4th to 10th components would become smaller, i. e., the frequency amplitude of the sEMG signal in the 0~117 Hz interval would increase when muscle fatigue was present, and the frequency amplitude in the 175.5~585 Hz interval would decreases. By comparing the muscle fatigue classification effects of different feature extraction methods, the experimental results show that the FDM and FTPR features can significantly improve the classification accuracy. Therefore, the proposed method can be used for muscle fatigue state recognition.

Keywords: muscle fatigue; surface electromyography signal; Fourier decomposition method; machine learning; support vector machine

0 引言

肌肉疲劳是反映个体生理健康的指标之一。反复疲劳可导致肌肉永久性损伤,并且这种损伤不可逆。因此,肌肉疲劳的检测和分析非常重要,可以有效预防过度肌肉疲劳所造成的伤害^[1]。然而,对肌肉疲劳的理解和量化是一个还没有完全解决的问题^[2]。研究发现,表面肌电(surface electromyography, sEMG)信号可以记录肌肉收缩过程中的肌肉变化情况^[3]。因此,分析 sEMG 信号有助于评估肌肉疲劳状态。sEMG 信号由于其无创性,成为疲劳分析中最有用的技术之一。

目前,sEMG 信号的分析仍然面临一些挑战。首先,sEMG 信号是一种非线性和非平稳的生物电信号,容易受采集方法和环境条件的影响^[4-5]。此外,人与人之间的身体素质差异和日常锻炼水平的影响也将导致每个人对疲劳的反应都不同^[6]。主要表现在相同的运动量会产生不同程度的疲劳,同样程度的疲劳会产生不同频率的 sEMG 信号。

研究人员使用多种方法分析肌肉疲劳状态,如时域分析中的均方根值^[7]、积分肌电值^[8]和平均绝对值^[9]等特征,以及频域分析中的平均功率频率和中值频率^[10-11]等特征。基于这些特征提出各种肌肉疲劳检测方法,文献[12]使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,支持向量机对肌肉疲劳的正确识别率最高达到了 99%。文献[13]融合 sEMG 信号时域、频域和肌肉厚度特征,使用精细树模型得到了 85% 准确率的同时,训练时长最短。文献[14]使用多维特征融合网络对 sEMG 信号的时域和频域特征进行处理并检测肌肉疲劳状态,解决了传统机器学习算法在特征提取和交叉学科应用方面的缺陷。文献[15]在常用时域和频域特征的基础上,引用带谱熵和瞬时平均频率,使用粒子群突变算法优化支持向量机对肌肉疲劳分类的准确率大于 90%。sEMG 信号除了应用在肌肉疲劳检测领域,还被应用于手势识别^[16-17]领域。

sEMG 信号的非线性和非平稳性使得传统的时域和频域分析方法不再适用,因此常常采用时频分析方法对其进行处理。文献[18]使用短时傅里叶变换(short time Fourier transform, STFT)提取中值频率特征识别肌肉疲劳,但 STFT 窗函数选定后时频分辨率固定,限制了其对非平稳 sEMG 信号的分析。文献[19]使用小波变换分析肌肉疲劳状态,发现选择适当的小波基函数能有效识别疲劳,但母小波选择不当会影响效果。经验模态分解(empirical mode decomposition, EMD)是一种自适应时频分析方法^[20],基于 EMD 的时频方法被广泛应用于 sEMG 信号的肌肉疲劳状态检测^[21-22],但其存在模态混叠、端点

效应和趋势不确定性等局限性。近年来,一些改进算法如集合 EMD、多元 EMD 和能量保持 EMD 算法已经被提出^[23],但仍无法完全弥补 EMD 的缺陷。

Singh 等^[24]提出了完全基于傅里叶理论的傅里叶分解方法(Fourier decomposition method, FDM),用于分析非线性和非平稳性的时间序列或信号。FDM 能在从信号中提取傅里叶固有频带函数(Fourier intrinsic band function, FIBF)的过程中有效的分离频带^[25]。FDM 已被用于各种领域,如识别癫痫发作^[26]、酒精中毒检测^[27]、生物医学信号的噪声消除^[28]和 2019 冠状病毒疾病大流行的建模和预测^[29]等。FDM 有严格的数学理论,能将非线性和非平稳性的信号分解为一系列 FIBF 分量和残余分量之和。与 EMD 方法相比,FDM 具有坚实的理论基础,可以有效克服 EMD 算法存在的模态混叠问题,具有正交性、完备性、局部性和自适应性。以往还没有使用 FDM 分析肌肉疲劳的先例,本文鉴于 FDM 分析非线性和非平稳性信号的优越性,使用 FDM 分析 sEMG 信号,以此判断肌肉是否发生了疲劳。此外,研究表明 sEMG 信号的频率参数与肌肉疲劳评估密切相关^[30]。以往的分析只是判断肌肉是否疲劳,缺少对 sEMG 信号在不同频率区间的变化情况的分析,本文基于 FDM 提出了 FIBF 分量总功率占 sEMG 信号总功率的比例(FIBF total power ratio, FTPR)特征,可以反映肌肉疲劳时,sEMG 信号的不同频率区间的频率幅度变化情况。针对以往方法分析非线性和非平稳性的 sEMG 信号存在局限性的问题,本文提出一种基于 FDM 和机器学习相结合的 sEMG 信号分类算法,使用 FDM 将 sEMG 信号分解为一组 FIBF 分量后,以各分量的 FTPR 作为分类特征,最后运用不同的机器学习分类算法测试所提特征的有效性,以区分肌肉的疲劳和非疲劳状态。

1 实验设计与数据采集

1.1 实验对象和实验设备

受试者为实验室研究生人员,年龄在 23~27 岁之间,体重在 65~86.5 kg 之间,身高在 150~185 cm 之间,身体状况良好,无神经肌肉骨骼类疾病,实验开始前 24 h 内没有从事剧烈运动。所有受试者在实验开始前均被告知注意事项和实验流程,并签署知情同意书。sEMG 信号采集使用干电极肌电传感器和 Arduino 控制板,设置采样频率为 1 170 Hz。实验过程中还需使用握力器和 75% 医用酒精。使用 75% 医用酒精擦拭受试者手臂的肱桡肌皮肤表面,去除皮肤表面的油脂和死皮等,降低皮肤表面对 sEMG 信号的干扰,提高采集的 sEMG 信号质量。

1.2 sEMG 信号数据采集

将肌电传感器贴在手臂的肱桡肌最隆处,使用贴布

固定,防止传感器的脱落。受试者端坐于实验桌前,背部保持挺直。实验首先采集肌肉非疲劳状态下静止的 sEMG 信号,然后受试者手持握力器(用于加速肌肉疲劳进程)进行抓握动作直至手臂疲劳无法进行抓握动作,采集肌肉疲劳状态下静止的 sEMG 信号。通过以上步骤记录非疲劳和疲劳状态下的 sEMG 信号。

2 sEMG 信号的分析方法

将使用 FDM 得到的 FIBF 分量总功率占 sEMG 信号总功率比例 (FTPR) 作为特征向量,输入到机器学习分类器中进行分类,实现流程如图 1 所示。图 2 和 4 显示了非疲劳和疲劳状态下的 sEMG 信号傅里叶分解方法过程图,图 3 和 5 分别为其各 FIBF 分量对应的频谱图。




图 1 信号处理流程

Fig. 1 Signal processing flow chart




图 2 非疲劳状态下表面肌电信号的傅里叶分解方法过程

Fig. 2 Fourier decomposition method process of sEMG signal under non-fatigue condition

2.1 sEMG 信号预处理

sEMG 信号是微弱生物电信号,有用信息分布在 0~500 Hz 频率范围^[31],主要能量部分分布在 50~150 Hz 频率范围之间,容易受到干扰。预处理首先对 sEMG 信号进行去除趋势处理,然后对 sEMG 信号进行 50 Hz 及其谐波分量的陷波滤波器处理以及 10~580 Hz 的带通滤波器处理。

数据分析设备为 Windows 10 系统笔记本电脑,仿真程序的编程在 MATLAB 2020a 上进行。

2.2 傅里叶分解方法

FDM 是一种新的非线性、非平稳信号处理方法。在实践中,连续时间信号通常被离散化以供计算机设备进

一步处理。因此,在本节中将介绍离散信号的 FDM,该算法使用快速傅里叶变换 (fast Fourier transform, FFT) 算法实现,从而提高计算效率。设 $x[n]$ 是任何长度为 N 的离散实时信号。使用离散傅里叶变换 (discrete Fourier transform, DFT), $x[n]$ 可以定义^[24-25]为:

$$x[n] = \sum_{k=0}^{N-1} X[k] \exp\left(\frac{j2\pi kn}{N}\right) \quad (1)$$

其中:

$$X[k] = \frac{1}{N} \sum_{n=0}^{N-1} x[n] \exp\left(-\frac{j2\pi kn}{N}\right) \quad (2)$$

式 (2) 是 $x[n]$ 的 DFT。设 N 为偶数 (当 N 为奇数时,可以类似的方式进行),则 $X[0]$ 和 $X[N/2]$ 为实数,可以写 $x[n]$ 为:




图3 非疲劳状态下各 FIBF 分量对应的频谱图

Fig. 3 Spectrogram of each FIBF component under non-fatigue condition

$$x[n] = X[0] + \sum_{k=1}^{N/2-1} X[k] \exp\left(\frac{j2\pi kn}{N}\right) + X\left[\frac{N}{2}\right] \exp(j\pi n) + \sum_{k=N/2+1}^{N-1} X[k] \exp\left(\frac{j2\pi kn}{N}\right) \quad (3)$$

由于 $x[n]$ 是实信号。因此,该方程中的第2项是第4项的复共轭,可以将方程改写为:

$$x[n] = X[0] + 2\operatorname{Re}\{z[n]\} + X\left[\frac{N}{2}\right](-1)^n \quad (4)$$

其中: $\operatorname{Re}\{z[n]\}$ 表示 $z[n]$ 的实部。写出解析信号 $z[n]$ 为:

$$z[n] = \sum_{k=1}^{N/2-1} X[k] \exp\left(\frac{j2\pi kn}{N}\right) =$$

$$\sum_{i=1}^M a_i[n] \exp(j\theta_i[n]) \quad (5)$$

式中: $M \ll N$ 。这里 FIBF 解析函数形式(analytic FIBF, AFIBF)的获得选用从低频到高频搜索方式如式(5)所示,此关系表示时间序列的广义傅里叶展开, $a_i[n] \exp(j\theta_i[n])$ 的实部被称为 FIBF,其中 $a_i[n]$ 和 $\theta_i[n]$ 分别代表瞬时振幅和瞬时相位。

$$a_i[n] \exp(j\theta_i[n]) = \sum_{k=N_{i-1}+1}^{N_i} X[k] \exp\left(\frac{j2\pi kn}{N}\right) \quad (6)$$

式中: $N_0 = 0$ 和 $N_M = (N/2 - 1)$ 。




图4 疲劳状态下表面肌电信号的傅里叶分解方法过程

Fig. 4 Fourier decomposition method process of sEMG signals under fatigue condition




图 5 疲劳状态下各 FIBF 分量对应的频谱图

Fig. 5 Spectrogram of each FIBF component under fatigue condition

2.3 特征提取

频域分析可以表征 sEMG 信号的内部信息,使用 FFT 获得 sEMG 信号的功率谱。基于功率谱 (power spectrum, PS) 求取 sEMG 信号的总功率 (total power, TP), TP 的计算公式如下:

$$TP = \int_0^{\infty} PS(f) df \quad (7)$$

式中: f 为 sEMG 信号的频率, $PS(f)$ 为 sEMG 信号的功率谱函数。求取每个 FIBF 分量的总功率,计算公式如下:

$$FIBFTP_i = \int_0^{\infty} PS(f)_i df \quad (8)$$

式中: i 表示为第 i 个 FIBF 分量, $PS(f)_i$ 表示为第 i 个 FIBF 分量的功率谱函数, $FIBFTP_i$ 表示为第 i 个 FIBF 分量的总功率。求取每个 FIBF 分量的 FTPR 特征,计算公式如下:

$$FTPR_i = \frac{FIBFTP_i}{TP} \quad (9)$$

式中: $FTPR_i$ 表示为第 i 个 FIBF 分量的 FTPR 特征。

2.4 归一化处理

不同受试者的 sEMG 信号特征参数会出现一定的差异性,并且同一个受试者每次测量的 sEMG 信号特征参数也不一样, sEMG 信号分析会受到影响。因此,有必要对特征的数据集进行归一化,以使每个特征参数处于相同的数量级。采用的标准化方法是最大-最小值标准化,公式为:

$$x = \frac{A - \min A}{\max A - \min A} \quad (10)$$

式中: A 为原始特征值, $\min A$ 和 $\max A$ 分别为特征值 A 的最小值、最大值, x 为归一化后的特征值,式 (10) 将原始特征数据 A 映射到 $[0, 1]$ 区间。

2.5 分类器的选择

支持向量机是由 Cortes 等^[32] 首先提出。核心策略是寻找最优的超平面,使支持向量到超平面的距离最大。选取适当的核函数可以用于解决非线性分类问题,是一种经典的二分类模型。

以二分类问题为例,给定训练样本集 (x_i, y_i) , $i = 1, 2, \dots, l$, $x \in R^n$, $y \in \{\pm 1\}$, 超平面记作 $(w \cdot x) + b = 0$, 为使所有训练集样本正确分类,则要求满足式 (11)^[33]:

$$y_i [(w \cdot x_i) + b] \geq 1 \quad i = 1, 2, \dots, l \quad (11)$$

计算出分类间隔为 $2 / \|w\|$, 于是构造最优超平面的问题就转化为在约束式 (11) 下的最小值问题:

$$\min \theta(w) = \frac{1}{2} \|w\|^2 = \frac{1}{2} (w' \cdot w) \quad (12)$$

为解决此约束优化问题,引入 Lagrange 函数:

$$L(w, b, a) = \frac{1}{2} \|w\|^2 -$$

$$\sum_{i=1}^l a_i (y_i ((w \cdot x_i) + b) - 1) \quad (13)$$

式中: $a_i > 0$ 为 Lagrange 乘数。使用 KKT 条件和对偶条件把最大间隔问题转为相应的对偶问题即:

$$\max Q(a) = \sum_{j=1}^l a_j - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l a_i a_j y_i y_j (x_i \cdot x_j) \quad (14)$$

$$\text{s. t. } \sum_{j=1}^l a_j y_j = 0 \quad a_j \geq 0, j = 1, 2, \dots, l$$

解得最优解 $a^* = (a_1^*, a_2^*, \dots, a_l^*)^T$ 。

计算得到,最优权值向量 $\mathbf{w}^*$ 和最优偏置 b^* 分别为:

$$\mathbf{w}^* = \sum_{j=1}^l a_j^* y_j x_j \quad (15)$$

$$b^* = y_i - \sum_{j=1}^l y_j a_j^* (x_j \cdot x_i) \quad (16)$$

式中:下标 $j \in \{j | a_j^* > 0\}$ 。从而得到最优分类超平面 $(\mathbf{w}^* \cdot \mathbf{x}) + b^* = 0$,而最优分类函数为:

$$f(x) = \text{sgn}\{(\mathbf{w}^* \cdot \mathbf{x}) + b^*\} = \text{sgn}\left\{\left(\sum_{j=1}^l a_j^* y_j (x_j \cdot x_i)\right) + b^*\right\}, \mathbf{x} \in R^n \quad (17)$$

相同的特征在不同机器学习分类器下得到的识别准确率相差也比较大,本文采用决策树(decision tree, DT)、线性判别分析(linear discriminant analysis, LDA)、朴素贝叶斯(naive bayes, NB)、支持向量机(support vector machine, SVM)和K-最近邻(k-nearest neighbor, KNN) 5个分类器进行对比验证。在SVM算法中,对比线性、二次、三次和高斯核函数,对sEMG信号特征集进行分析,发现SVM算法选择二次核函数取得了最好的分类效果,所以本文选择二次核函数的SVM分类器。KNN算法根据分类精度, K 值取为5,使用的距离公式为欧几里得距离。NB算法选取具有高斯分布的NB模型。DT算法模型选择为精细树模型。

在本文工作中,采用5倍交叉验证方案来训练所有的分类器。特征数据集随机化,选择70%数据用于训练分类器,剩下的30%用于测试,重复20次,求取20次的平均结果作为最终结果。

2.6 分类器性能

计算了3个性能指标,即准确率(Acc)、灵敏度(Sen)和特指度(Spec)来衡量分类器的性能。这些参数定义如下:

$$\begin{cases} \text{Sen} = \frac{TP}{TP + FN} \\ \text{Spec} = \frac{TN}{TN + FP} \\ \text{Acc} = \frac{TP + TN}{TP + TN + FP + FN} \end{cases} \quad (18)$$

式中: TP 表示真阳性事件, TN 表示真阴性事件, FP 表示假阳性事件, FN 表示假阴性事件。ROC曲线是评估分类器性能的有效工具,描述了真阳性率(Sen)和假阳性率($1 - \text{Spec}$)之间的关系。第4个性能指标,ROC曲线下面积(AUC)公式如下:

$$\text{AUC} = \int_0^1 \text{Sen}(x) dx \quad (19)$$

其中, $x = 1 - \text{Spec}$ 。

3 结果与分析

sEMG信号的频率成分随时间发生变化,为了观察到肌肉从非疲劳状态到疲劳状态的不同频率区间的频率幅度变化情况,使用FDM将sEMG信号分解为固定数量的FIBF分量。从低频到高频搜索AFIBF,从图2和4可以看出各FIBF分量从低频到高频排列,图3和5更加清晰的显示出了该变化。FDM是从频域角度出发对sEMG信号进行分解,把分解得到的各FIBF分量对应的频谱图绘制在一起,就是其所对应的sEMG信号的频谱图如图6和7所示,从图中可以看出肌肉从非疲劳到疲劳状态的不同频率区间的频率幅度变化情况,当肌肉疲劳时,频谱向低频方向移动。




图6 非疲劳状态下表面肌电信号的频谱图

Fig. 6 Spectrogram of sEMG signal under non-fatigue condition




图7 疲劳状态下表面肌电信号的频谱图

Fig. 7 Spectrogram of sEMG signal under fatigue condition

本文提出了一种基于FDM的肌肉疲劳分类方法,使用FDM将sEMG信号分解为 M 个FIBF分量,分别计算 M 个FIBF分量的FTPR特征,在特征数据集上评估了算

法的性能,并使用这些结果选择了各种参数,如最佳分解水平 M 和性能最佳的分类器。表 1 给出了 FDM 的不同分解水平下使用不同分类器的平均分类准确率对比,其中平均分类准确率是把特征数据集随机划分为训练集和测试集,然后运行 20 次,得到的最终结果。从表 1 可以看出在 FDM 的任何分解水平下使用 SVM 模型的平均分类准确率均高于其他分类器模型,同时在 FDM 的 10 层分解水平下使用 SVM 模型得到 98.17% 的最佳平均分类准确率。表 2 指出在 FDM 的 10 层分解水平下各机器学习分类器的 ROC 曲线下的 AUC 值。从表 2 中可以看出 SVM 的 AUC 值为 1,表明 SVM 分类器的性能高于其他分类器模型。因此在本文中使用 FDM 将 sEMG 信号分解为 10 个 FIBF 分量并选取 SVM 分类器。

表 1 FDM 的不同分解水平下不同分类器
平均分类准确率对比

Table 1 Comparison of average classification accuracy of different classifiers under different decomposition levels of FDM (%)					
i-FIBF	DT	LDA	NB	SVM	KNN
6-FIBF	89.17	86.00	87.50	96.50	94.17
7-FIBF	82.50	84.83	83.67	96.33	94.17
8-FIBF	90.50	88.50	86.83	96.67	96.00
9-FIBF	95.00	87.50	87.50	96.17	92.83
10-FIBF	92.17	92.00	87.67	98.17	94.33
11-FIBF	89.83	87.50	87.83	96.67	93.33
12-FIBF	95.67	89.00	88.17	96.5	93.83
13-FIBF	89.33	85.50	87.00	96.83	93.17
14-FIBF	85.17	87.17	86.50	93.83	92.33
15-FIBF	86.83	88.50	86.17	94.33	92.17
16-FIBF	89.00	87.67	87.50	95.83	91.83

表 2 分类器的 AUC 对比

Table 2 AUC comparison of classifiers	
分类器	ROC (AUC)
DT	0.92
LDA	0.95
NB	0.97
SVM	1.00
KNN	0.97

在本文中,还考虑了不同的数据长度对分类准确率的影响。从表 3 中可以看出当数据长度为 3 000 时,得到的平均分类准确率为 98.17%、平均灵敏度为 96.77% 和平均特指度为 99.62%。其中数据太短或数据太长都会使分类准确率降低。原因是肌肉疲劳下的 sEMG 信号是在手臂静止下测量的,数据太短不能准确的体现出 sEMG 信号内在的频率信息,数据太长表明采集 sEMG 信号时间长以至于肌肉疲劳状态有所恢复致使分类准确率降低。

表 3 数据长度对 SVM 分类器性能的影响
Table 3 Effect of data length on the performance of SVM classifier

数据长度	Sen/%	Spec/%	Acc/%
1 000	85.81	81.52	83.83
2 000	94.17	95.73	95.00
3 000	96.77	99.62	98.17
4 000	96.65	97.05	97.50
5 000	94.47	98.95	96.67
6 000	93.90	94.97	94.83

使用 FDM 得到的每个 FIBF 分量的对应频率范围分别为 0~58.5 Hz、58.5~117 Hz、117~175.5 Hz、175.5~234 Hz、234~292.5 Hz、292.5~351 Hz、351~409.5 Hz、409.5~468 Hz、468~526.5 Hz、526.5~585 Hz,图 8 展示了肌肉从非疲劳到疲劳状态时各分量的 FTPR 特征变化情况。从图 8 可以看出肌肉从不疲劳到疲劳状态时第 1~2 分量的 FTPR 会变大,第 4~10 分量的 FTPR 会变小,第 3 个分量的 FTPR 变化不明显,即当肌肉疲劳时 sEMG 信号 0~117 Hz 区间的频率幅度会增加,175.5~585 Hz 区间的频率幅度会下降。




图 8 特征对比图
Fig. 8 Feature comparison chart

为进一步对每个 FIBF 分量下的特征进行评估,选用箱型图进行描述,如图 9 所示。图 9 中“工”字型虚线表示了分别对每个 FIBF 分量下的 FTPR 特征独立进行 20 次测试的识别精度分布范围。箱型的上下限分别代表了 20 次识别精度的上下四分位数(即按从大到小的顺序排列,处于 25% 和 75% 位置上的值),箱型中的直线代表实验结果的中位数。总体上来看大部分频带下的特征都可以区分肌肉的非疲劳和疲劳状态,第 5 个 FIBF 分量下的 FTPR 分类效果最好,其识别精度范围主要集中在 90%~96.67%。第 3 个 FIBF 分量下的 FTPR 分类效果最差,不能很好的区分肌肉非疲劳和疲劳状态,考虑删除该特征,

选取剩余的 9 个特征进行模型训练,发现在相同的训练集和测试集下平均分类准确率为 97%,相比于选取全部特征准确率下降了 1.17%。在考虑所有特征的情况下,所有特征值相加为 1,是统一的整体且相互影响,全部的 FTPR 特征分布在 sEMG 信号的整个频率区间,所以选取全部的 FTPR 特征取得了比较好的分类效果。




图 9 不同模型特征识别精度统计

Fig. 9 Different models feature recognition accuracy statistics

为了评估 FDM 和 FTPR 特征的有效性,实验对比如表 4 所示。时域和频域方法分别提取 sEMG 信号的均方根值(root mean square, RMS)和总功率特征。EMD 是一种自适应信号分解算法,被广泛应用于分析非线性和非平稳性的信号,因此选用 EMD 方法作为参考,把信号分解为 10 个固有模式函数(intrinsic mode function, IMF)分量,计算各分量的 FTPR 特征,以验证本文提出方法的有效性。图 10 和 11 分别为使用 EMD 方法得到的各 IMF 分量的频谱图,从图中可以看出,当肌肉疲劳时 IMF 分量的频谱会向低频方向移动,指明 EMD 方法分析肌肉疲劳的有效性。使用同样的训练集和测试集,分别将 RMS、总功率、EMD-FTPR、FDM-RMS 和 FDM-FTPR 特征输入到 SVM 分类器,对比不同方法的准确率,取 20 次平均结果作为最终结果。实验结果如表 4 所示, FDM 处理后, RMS 特征的平均训练准确率为 93.36%, 平均分类准确率为 93.17%, 相比于单独使用 RMS 特征, 使用 FDM 处理后的准确率分别提升了 14.77% 和 13.84%, 这证明了 FDM 在处理 sEMG 信号中的有效性。此外, 经过 FDM 处理后的 FTPR 特征表现更加优异, 其平均训练准确率和平均分类准确率均优于 RMS 特征, 其中平均训练准确率为 95%, 平均分类准确率为 98.17%, 相比于 FDM 处理后的 RMS 特征, 两项指标分别提升了 1.64% 和 5%, 进一步展示了 FTPR 特征的有效性。当使用 EMD 处理后的 FTPR 特征时, 平均分类准确率为 87.33%, 相比较于频域方法, 准确率提升了 16.16%, 表现出了很好的分类性能。经过 FDM 处理后的 FTPR 特征表现更加突出, 平均训练

准确率和平均分类准确率均优于 EMD 处理后的 FTPR 特征,准确率分别提升了 8.68% 和 10.84%,从另一个角度也证明了 FDM 的有效性。综合表 4 的数据分析,可以得出结论:FDM 和 FTPR 特征在处理 sEMG 信号时具有显著优势。因此,本文提出的将 FDM 和 FTPR 特征与 SVM 分类器结合使用是一种可靠的肌肉疲劳分类算法。

表 4 方法对比

Table 4 Comparison of methods			
方法	特征	平均训练准确率/%	平均分类准确率/%
时域方法	RMS	78.59	79.33
频域方法	总功率	72.97	71.17
EMD	FTPR	86.32	87.33
FDM	RMS	93.36	93.17
FDM	FTPR	95.00	98.17




图 10 非疲劳状态下各 IMF 分量对应的频谱图

Fig. 10 Spectrogram of each IMF component under non-fatigue condition




图 11 疲劳状态下各 IMF 分量对应的频谱图

Fig. 11 Spectrogram of each IMF component under fatigue condition

4 结 论

FDM 是处理非线性和非平稳性信号的一种自适应信号分解方法,能够有效分离信号的频带,其各 FIBF 分量的 FTPR 特征中含有丰富的类别信息。本文提出一种 FDM 和机器学习相结合的肌肉疲劳分类方法,选择合适的 FDM 分解水平、分类器和数据长度可实现对样本的有效分类。本文方法可以观察到肌肉从非疲劳到疲劳状态时,sEMG 信号每个频率区间的频率幅度和 FTPR 特征变化情况,且 234~292.5 Hz 对应的分量具有最好的类可分性,117~175.5 Hz 对应的分量分类效果最不明显。理论分析和实测结果表明应用 FDM 对 sEMG 信号进行分解,可以避免 EMD 的模式混叠与端点效应,对比时域、频域

和 EMD 特征提取方法,本文提出的基于 FDM 的 FTPR 特征提取方法更能准确的对肌肉疲劳状态进行识别与分类。

参考文献

- [1] ZHOU F, ALSAID A, BLOMMER M, et al. Driver fatigue transition prediction in highly automated driving using physiological features [J]. *Expert Systems with Applications*, 2020, 147: 113204.
- [2] RAMPICHINI S, VIEIRA T M, CASTIGLIONI P, et al. Complexity analysis of surface electromyography for assessing the myoelectric manifestation of muscle fatigue: A review[J]. *Entropy*, 2020, 22(5): 529.
- [3] KARTHICK P A, GHOSH D M, RAMAKRISHNAN S. Surface electromyography based muscle fatigue detection using high-resolution time-frequency methods and machine learning algorithms[J]. *Computer Methods and Programs in Biomedicine*, 2018, 154: 45-56.
- [4] SUN Z, XI X, YUAN C, et al. Surface electromyography signal denoising via EEMD and improved wavelet thresholds [J]. *Mathematical Biosciences and Engineering*, 2020, 17(6): 6945-6962.
- [5] ROCHA V A, DO CARMO J C, NASCIMENTO F A O. Weighted-cumulated S-EMG muscle fatigue estimator[J]. *IEEE Journal of Biomedical and Health Informatics*, 2017, 22(6): 1854-1862.
- [6] VAN CUTSEM J, MARCORA S, DE PAUW K, et al. The effects of mental fatigue on physical performance: A systematic review[J]. *Sports Medicine*, 2017, 47(8): 1569-1588.
- [7] PITT B, DOTAN R, MILLAR J, et al. The electromyographic threshold in boys and men [J]. *European Journal of Applied Physiology*, 2015, 115(6): 1273-1281.
- [8] WU Q, XI C, DING L, et al. Classification of EMG signals by BFA-optimized GSVM for diagnosis of fatigue status[J]. *IEEE Transactions on Automation Science and Engineering*, 2016, 14(2): 915-930.
- [9] WANG S, TANG H, WANG B, et al. A novel approach to detecting muscle fatigue based on sEMG by using neural architecture search framework [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021(99): 1-12.
- [10] LIU Q, LIU Y, ZHANG C, et al. sEMG-based dynamic muscle fatigue classification using svm with improved whale optimization algorithm[J]. *IEEE Internet of Things Journal*, 2021, 8(23): 16835-16844.
- [11] THONGPANJA S, PHINYOMARK A, PHUKPATTARANONT P, et al. A feasibility study of

- fatigue and muscle contraction indices based on EMG time-dependent spectral analysis [J]. *Procedia Engineering*, 2012, 32: 239-245.
- [12] 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.
- LIU G D, DONG M K, ZHANG SH W, et al. Research on fatigue classification of surface EMG signal based on KPCA and SVM[J]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35(10): 1-8.
- [13] 张亚龙, 张世武, 孙帅帅, 等. 融合肌电信号与 A 型超声的新型肌肉疲劳检测方法[J]. *电子测量与仪器学报*, 2022, 36(6): 13-21.
- ZHANG Y L, ZHANG SH W, SUN SH SH, et al. Muscle fatigue detection method with fusion of EMG signal and A-type ultrasound[J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(6): 13-21.
- [14] ZHANG Y, CHEN S, CAO W, et al. Mffnet: Multi-dimensional feature fusion network based on attention mechanism for sEMG analysis to detect muscle fatigue[J]. *Expert Systems with Applications*, 2021, 185: 115639.
- [15] 曹昂, 张坤嘉, 刘睿, 等. 基于表面肌电信号的肌肉疲劳状态分类系统[J]. *计算机应用*, 2018, 38(6): 1801-1808.
- CAO ANG, ZHANG SH J, LIU R, et al. Muscle fatigue state classification system based on surface electromyography signal [J]. *Journal of Computer Applications*, 2018, 38(6): 1801-1808.
- [16] 张松, 李江涛, 别东洋, 等. 一种基于单通道 sEMG 分解与 LSTM 神经网络相结合的手势识别方法[J]. *仪器仪表学报*, 2021, 42(4): 228-235.
- ZHANG S, LI J T, BIE D Y, et al. Gesture recognition by single-channel sEMG decomposition and LSTM network[J]. *Chinese Journal of Scientific Instrument*, 2021, 42(4): 228-235.
- [17] 刘闯闯, 朱正伟. 基于 HPSO-SVM 的多传感器手语识别方法研究[J]. *电子测量技术*, 2021, 44(10): 57-65.
- LIU CH CH, ZHU ZH W. Research on multi-sensor sign language recognition method based on HPSO-SVM[J]. *Electronic Measurement Technology*, 2021, 44(10): 57-65.
- [18] BOYER M, BOUYER L, ROY J S, et al. A real-time algorithm to estimate shoulder muscle fatigue based on surface EMG signal for static and dynamic upper limb tasks[C]. 2021 43rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE, 2021: 100-106.
- [19] CHOWDHURY R, REAZ M B I, ISLAM M T. Wavelet transform to recognize muscle fatigue[C]. 2012 Third Asian Himalayas International Conference on Internet. IEEE, 2012: 1-5.
- [20] ASHRAF H, WARIS A, GILANI S O, et al. Threshold parameters selection for empirical mode decomposition-based EMG signal denoising[J]. *Intelligent Automation and Soft Computing*, 2021, 27(3): 799-815.
- [21] FAN X, XU H, HUANG W, et al. Muscle fatigue recognition based on sEMG characteristics [C]. *International Conference on Electrical, Control, Automation and Robotics (ECAR)*, 2018, 307: 493-497.
- [22] HONG T, ZHANG X, MA H, et al. Fatiguing effects on the multi-scale entropy of surface electromyography in children with cerebral palsy [J]. *Entropy*, 2016, 18(5): 177.
- [23] SINGH P, JOSHI S D, PATNEY R K, et al. The Hilbert spectrum and the energy preserving empirical mode decomposition [J]. *arXiv preprint arXiv: 1504.04104*, 2015.
- [24] SINGH P, JOSHI S D, PATNEY R K, et al. The Fourier decomposition method for nonlinear and non-stationary time series analysis[J]. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 2017, 473(2199): 20160871.
- [25] SINGH P. Novel Fourier quadrature transforms and analytic signal representations for nonlinear and non-stationary time-series analysis[J]. *Royal Society Open Science*, 2018, 5(11): 181131.
- [26] MEHLA V K, SINGHAL A, SINGH P, et al. An efficient method for identification of epileptic seizures from EEG signals using Fourier analysis[J]. *Physical and Engineering Sciences in Medicine*, 2021, 44(2): 443-456.
- [27] MEHLA V K, SINGHAL A, SINGH P. A novel approach for automated alcoholism detection using Fourier decomposition method [J]. *Journal of Neuroscience Methods*, 2020, 346: 108945.
- [28] SINGHAL A, SINGH P, FATIMAH B, et al. An efficient removal of power-line interference and baseline wander from ECG signals by employing Fourier decomposition technique [J]. *Biomedical Signal Processing and Control*, 2020, 57: 101741.
- [29] SINGHAL A, SINGH P, LALL B, et al. Modeling and prediction of COVID-19 pandemic using Gaussian mixture model [J]. *Chaos, Solitons & Fractals*, 2020,

138; 110023.

- [30] GONZÁLEZ-ZAMORA P, BENITEZ V H, PACHECO J. A feature-based processing framework for real-time implementation of muscle fatigue measurement [J]. Cluster Computing, 2023, 26(1): 385-394.
- [31] EMAYAVARAMBAN G, DIVYAPRIYA S, MANSOOR V M, et al. SEMG based classification of hand gestures using artificial neural network [J]. Materials Today: Proceedings, 2021, 37: 2591-2598.
- [32] CORTES C, VAPNIK V. Support-vector networks [J]. Machine Learning, 1995, 20: 273-297.
- [33] ZHANG Y. Support vector machine classification algorithm and its application [J]. Information Computing and Applications, 2012, 308: 179-186.

作者简介



姚贺龙, 2019 年于北方民族大学获得学士学位, 现为内蒙古科技大学硕士研究生, 主要研究方向为生物医学电信号分析与处理。

E-mail: 1956674830@qq.com

Yao Helong received his B. Sc. degree from North Minzu University in 2019. Now he is a M. Sc. candidate at Inner Mongolia University of Science & Technology. His main research interests include biomedical electrical signal analysis and processing.



吕东瀚(通信作者), 2010 年于内蒙古工业大学获得学士学位, 2013 年于天津理工大学获得硕士学位, 2016 年于南开大学获得博士学位, 现为内蒙古科技大学副教授, 主要研究方向为生物医学电信号分析与处理。

E-mail: wslhdh2016957@imust.edu.cn

Lyu Donghao (Corresponding author) received his B. Sc. degree from Inner Mongolia University of Technology in 2010, M. Sc. degree from Tianjin University of Technology in 2013 and

Ph. D. degree from Nankai University in 2016. Now he is an associate professor at Inner Mongolia University of Science & Technology. His main research interests include biomedical electrical signal analysis and processing.



张勇, 2004 年于东北石油大学获得学士学位, 2007 年于江南大学获得硕士学位, 2022 年于东北大学获得博士学位, 现为内蒙古科技大学教授, 主要研究方向为复杂系统建模与优化。

E-mail: yinghuzhangyong@163.com


Zhang Yong received his B. Sc. degree from Northeast Petroleum University in 2004, M. Sc. degree from Jiangnan University in 2007, and Ph. D. degree from Northeastern University in 2022. Now he is a professor at Inner Mongolia University of Science & Technology. His main research interests include complex system modeling and optimization.



张鹏, 2019 年于商丘师范学院获得学士学位, 现为内蒙古科技大学研究生, 主要研究方向为生物信号分析与处理。

E-mail: 615932491@qq.com

Zhang Peng received his B. Sc. degree from Shangqiu Normal University in 2019. Now he is a M. Sc. candidate at Inner Mongolia University of Science & Technology. His main research interests include biological signal analysis and processing.



曹震, 2019 年于山东交通学院获得学士学位, 现为内蒙古科技大学研究生, 主要研究方向为生物信号分析与处理。

E-mail: 962912395@qq.com

Cao Zhen received his B. Sc. degree from ShanDong JiaoTong University in 2019. Now he is a M. Sc. candidate at Inner Mongolia University of Science & Technology. His main research interests include biological signal analysis and processing.