

基于小波降噪和时序数据图像化的表面肌电信号识别

菅小艳^{1*}, 韩素青¹, 杨红菊^{2,3}

(1. 太原师范学院 计算机科学与技术学院, 山西 晋中 030619;

2. 山西大学 计算机与信息技术学院, 山西 太原 030006;

3. 山西大学 计算智能与中文信息处理教育部重点实验室, 山西 太原 030006)

摘要:表面肌电信号(sEMG)是人体肌肉收缩时发出的信号,能很好地反映人体肌肉功能,因此被广泛应用在临床、假肢控制、康复评估等领域。由于受采集器、佩戴位置和环境等因素的影响,电脑接收的信号包含随机噪声,严重影响信号的分析研究。因此,本文提出了一种基于新的小波阈值降噪和时序数据图像化的表面肌电信号识别方法。首先,本文采集五种基本上肢运动的sEMG,并采用小波分解对其降噪。提出了一种新的阈值函数以弥补传统小波分解任务中软阈值函数的失真现象和硬阈值函数会产生振荡的缺陷,并在理论上证明了该函数在阈值处的连续性和与原小波系数的无偏差性。然后,受计算机视觉中卷积神经网络成功应用的启发,本文利用短时傅里叶变换将时序数据转换成图像数据。随后,在原始数据集和不同阈值函数降噪后的数据集上的实验表明,本文方法降噪后的数据集上分类性能更优;在降噪后的数据集上,使用二维卷积神经网络(Two Dimensional Convolutional Neural Networks, 2DCNN)模型在四个动作的数据上准确率最高、一个次高。说明本文方法可以有效提高sEMG的识别率,具有较好泛化能力。

关键词:表面肌电信号;小波降噪;时序数据;图像数据;短时傅里叶变换

中图分类号:TP391 **文献标志码:**A **文章编号:**0253-2395(2024)01-0103-09

Surface Electromyography Recognition Based on Wavelet Denoising and Time-series Imaging

JIAN Xiaoyan^{1*}, HAN Suqing¹, YANG Hongju^{2,3}

(1. School of Computer Science and Technology, Taiyuan Normal University, Jinzhong 030619, China;

2. School of Computer and Information, Shanxi University, Taiyuan 030006, China;

3. Computational Intelligence and Chinese Information Processing of Ministry of Education, Shanxi University, Taiyuan 030006, China)

Abstract: Surface Electromyography (sEMG) is the signal sent by human muscle contraction, which can well reflect human muscle function, so it is widely used in clinical, prosthesis control, and rehabilitation evaluation etc. However, due to the influence of collector, wearing position, environment and other factors, the signal received by the computer contains random noise, which seriously affects the analysis and research of the signal. In this article, we proposed a sEMG recognition method based on a new wavelet threshold denoising and time sequence data visualization. Firstly, sEMG of five basic upper limb movements were collected and denoised by improved wavelet decomposition. A new threshold function was proposed to make up for the distortion of soft threshold function and the vibration of hard threshold function in traditional wavelet decomposition, and it was proved that the function was continuous at the threshold and non-deviation from original wavelet coefficient. Then, inspired by the successful application of convolutional neural networks in computer vision, we transformed time-series data into image data using Short-time Fourier Transform. Finally,

收稿日期:2023-06-24; **接受日期:**2023-08-04

基金项目:国家自然科学基金(61976128);山西省教育厅(2022-008);山西省教育科学“十四五”规划课题(GH-220176)

* **通信作者:**菅小艳(1975-),女,山西太原人,硕士,讲师,研究方向为机器学习、数据挖掘。E-mail:jianxiaoyan@tynu.edu.cn

引文格式:菅小艳,韩素青,杨红菊.基于小波降噪和时序数据图像化的表面肌电信号识别[J].山西大学学报(自然科学版),2024,47(1):103-111. DOI:10.13451/j.sxu.ns.2023137

the experimental results on both the original datasets and the datasets denoised by different methods show that the model obtains superior classification results on the datasets denoised by the proposed method. The Two-dimensional Convolutional Neural Networks (2DCNN) model has highest accuracy on four action datasets and second highest accuracy on one action datasets. Therefore, the proposed method can effectively improve the recognition rate of sEMG and has good generalization.

Key words: surface electromyography; wavelet denoising; time-series data; image data; short-time Fourier transform

0 引言

表面肌电信号(Surface Electromyography, sEMG)是浅层肌肉收缩信号和神经干上电活动在皮肤表面的综合效应,能反映人体活动的动态特性。自从21世纪以来,随着非损伤电极的应用、计算机的发展,以及sEMG在测量上具有非入侵性、无创伤性、操作简单和信号容易获得等优点,对sEMG的研究也日益深入起来^[1]。肌电信号已逐渐被应用在人因工程、康复医学、运动检测及人机交互等领域^[2]。

在信号采集的过程中,由于受采集器佩戴位置,采集器和人体皮肤之间摩擦,以及周围环境等因素的影响,电脑接收的信号中包含噪声,因此降噪处理有助于做出准确的决策。为了提高信号的质量,许多学者尝试了各种降噪技术以及降噪的质量评估^[3]。小波变换具有多分辨率的特性,在降噪的过程中能够很好地保留原有信号中有用信号的峰值和突变部分,广泛应用于各个领域^[4-5]。经离散小波分解后,高频系数包含的大部分是噪声,低频系数保存的则是有用信号,因此对高频系数重置可以有效的降低噪声^[6-7]。

为了通过重置小波系数来达到降噪的目的,JohnStone和Donoho等于1992年首次提出软阈值函数和硬阈值函数^[8-9],但是软阈值函数对小波系数重置后会出现系数偏差,重构以后有失真现象,硬阈值函数对系数重置后,在阈值处不连续,重构后会出现抖动现象。Bruce和Gao提出半软阈值方法^[10],近年来也有学者提出新的阈值函数来提高降噪能力,并取得了一定的效果。大部分的阈值函数是直接给定的,不能根据小波变换后系数分布调整参数,降噪的效果也不是很理想。针对上述问题,本文提出一种新的阈值函数,该函数不仅在阈值处是连续的,重置小波系数后与原系数的偏差更小,降低了重构以后信号失真和抖动现象,而且可以根据

不同数据集小波分解后的小波系数动态选择参数,调整阈值函数与原函数的逼近速度,使得信号降噪后最大程度地接近原信号。

目前对肌电信号识别的主要算法有随机森林(Random Forest, RF)、支持向量机(Support Vector Machine, SVM)、小波分析和深度学习等。卷积神经网络(Convolutional Neural Networks, CNN)是深度学习的代表算法之一^[11]。第一个卷积神经网络是1987年由Waibele提出的时间延迟网络(Time Delay Neural Network, TDNN)^[12]。Lecun等于20世纪90年代将卷积神经网络应用于图像、语音等领域^[13]。由于卷积神经网络共享权值的网络结构和局部感知的特点,能够降低神经网络的运算复杂度,对数据的局部特征提取,已经成为图像识别和自然语言处理(Natural Language Processing, NLP)领域热门算法之一。卷积神经网络的输入层可以处理多维数据,但是目前卷积神经网络的应用主要还是用在处理二维数据,在二维卷积神经网络(Two Dimensional Convolutional Neural Networks, 2DCNN)领域有大量的方法和改进措施。因此将时序数据转换成图像数据也得到了更多的关注^[14-16],文献^[15]介绍了利用格拉米角场(GAFs)方法将时间序列转换成图像,WANG等利用马尔可夫变迁场(MIF)通过转移矩阵把时间序列转换成图像数据^[17],1987年Eckmam等提出了递归图(recurrence plot, RP),可以解释时间序列的内部结构,特别适合短时时序数据。受短时傅里叶(Short-time Fourier Transform, STFT)思想的启发,本文通过窗的大小和步长调整图像的大小,将时序数据转换成图像数据,使用2DCNN作为分类模型^[18]。在原始采集的数据和软阈值函数、硬阈值函数及本文提出的阈值函数降噪后的数据上的实验结果表明,利用本文提出的阈值函数降噪后使用图像数据能提

升整体动作的识别率。

具体流程如图 1 所示。

1 小波降噪

小波分析通过使用尺度 (scale) 和平移 (translation) 控制小波函数的收缩和平移,可以得到与原始信号的重合。离散非周期性时序信号的小波变换为:

$$W(a, b) = \sum_{t=1}^{+\infty} s(t) \psi\left(\frac{t-b}{a}\right), \quad (1)$$

其中, $\psi(t)$ 为基本小波函数, b 为时间平移, a 为不同的尺度。小波系数 $W(a, b)$ 先将基本小波函数 $\psi(t)$ 进行时间平移, 再进行尺度伸缩, 并在不同尺度下与待分析信号进行内积处理。小波分解将信号分解为近似系数 ca 和细节系数 cd , 近似系数 ca 代表信号的低频部分, 保存的是有用信号; 细节系数 cd 代表信号的高频部分, 保存的是噪声数据。因此删除绝对值小于给定阈值的细节系数就能有效的保留有用信号, 去除噪声信号^[19]。本文采用分层计算阈值的方法, 在每个分解尺度上计算阈值 $\lambda = \frac{\text{middle}(|W_j|)}{0.6745}$ 。

$\sqrt{2 \log N}$, 其中 N 表示当前分解层次小波系数的长度, W_j 表示小波分解后的小波系数。

常用的阈值函数有软阈值函数和硬阈值函数。 \hat{W}_j 表示重置后的小波系数, 则软阈值函数和硬阈值函数表达式如下:

软阈值函数:

$$\hat{W}_j = \begin{cases} \text{sgn}(W_j)(|W_j| - \lambda), & |W_j| > \lambda, \\ 0, & |W_j| \leq \lambda. \end{cases} \quad (2)$$

硬阈值函数:

$$\hat{W}_j = \begin{cases} W_j, & |W_j| > \lambda, \\ 0, & |W_j| \leq \lambda. \end{cases} \quad (3)$$

软阈值函数虽然在 $W_j = \pm\lambda$ 处连续, 但是当 $|W_j| \geq \lambda$ 时发生了系数值大小的偏差, 重构信号后会出现失真现象; 硬阈值函数在 $W_j = \pm\lambda$ 处不连续, 这样重构的信号会产生振荡。

定义 1 令 W_j 是小波分解后的小波系数, \hat{W}_j 为重置后的小波系数, λ 为阈值, 定义新的阈值函数:

$$\hat{W}_j = \begin{cases} \frac{W_j(1 - e^{-\mu(|W_j| - \lambda)})}{1 + e^{-\mu(|W_j| - \lambda)}}, & |W_j| > \lambda \\ 0, & |W_j| \leq \lambda, \end{cases} \quad (4)$$

其中, μ 是收缩因子。

定理 1 新的阈值函数在 $W_j = \pm\lambda$ 时是连续, 且当 $|W_j| \rightarrow +\infty$ 时, 重置后的系数 \hat{W}_j 和原系数 W_j 的偏差趋于 0。

证 由于该函数是奇函数, 所以只需证明该函数在 $W_j > 0$ 时候的连续性和无偏差性, 根据奇函数关于原点对称, 就可以得到 $W_j < 0$ 时候也是满足的。

(1) 连续性:

当 $W_j \rightarrow \lambda^-$ 时, 函数的极限为:

$$\lim_{W_j \rightarrow \lambda^-} \hat{W}_j = \lim_{W_j \rightarrow \lambda^-} 0 = 0;$$

当 $W_j \rightarrow \lambda^+$ 时, 函数的极限为:

$$\lim_{W_j \rightarrow \lambda^+} \hat{W}_j = \lim_{W_j \rightarrow \lambda^+} \frac{W_j(1 - e^{-\mu(W_j - \lambda)})}{1 + e^{-\mu(W_j - \lambda)}} = 0;$$

函数在 $W_j = \lambda$ 的函数值 $\hat{W}_j|_{W_j=\lambda} = 0$ 。

即函数当 $W_j = \lambda$ 时左右极限和函数值相等, 所以函数在 $W_j = \lambda$ 是连续的。

(2) 逼近性:

$$\begin{aligned} \lim_{W_j \rightarrow +\infty} \frac{\hat{W}_j}{W_j} &= \lim_{W_j \rightarrow +\infty} \frac{W_j(1 - e^{-\mu(W_j - \lambda)})}{W_j(1 + e^{-\mu(W_j - \lambda)})} = \\ \lim_{W_j \rightarrow +\infty} \frac{1 - e^{-\mu(W_j - \lambda)}}{1 + e^{-\mu(W_j - \lambda)}} &= \lim_{W_j \rightarrow +\infty} \frac{W_j(1 - e^{-\mu(W_j - \lambda)})}{W_j(1 + e^{-\mu(W_j - \lambda)})} = 1. \end{aligned}$$

当 W_j 取值越大, \hat{W}_j 与 W_j 之间的偏差就越小, 当 $W_j \rightarrow +\infty$ 时二者商的极限为 1。证毕。

图 2 为 $\lambda = 2$ 时软阈值函数、硬阈值函数和新的阈值函数中 $\mu = 5, 0.8, 20$ 的曲线, 图 2 中显示 μ 的取值越大, 逼近的速度越快, 当 μ 的取值很大的时候, 和硬阈值函数基本拟合; μ 的取



图 1 流程图

Fig. 1 Flow chart




图2 各种阈值函数图形

Fig. 2 Graphic of threshold function

值越小,逼近的速度越缓。因此在具体应用中, μ 可以根据数据集的特点和维数进行选择。

为了验证新的阈值函数的有效性,通过正弦函数加入高斯噪声后做了仿真实验,分别计算了利用软阈值函数、硬阈值函数和新的阈值函数降噪后的信噪比。为了观察参数 μ 不同取值的降噪效果, μ 从0到20取值,步长0.5,5次实验取平均值,并且以软阈值函数降噪后的信噪比为标准归一化,信噪比结果如图3所示。从图中可以观察到,在该仿真实验中,本文提出的方法在 $\mu=6$ 的时候降噪效果较好。

图4为分别利用软阈值函数、硬阈值函数和新的阈值函数对仿真数据降噪后与原正弦函数拟合的效果图,其中 μ 的取值分别为0.5,6和15。从图中可以观察到,在该仿真实验中,软阈值函数和硬阈值函数降噪后有一定程度的失真和抖动,但新的阈值函数中当 $\mu=6$ 的时候降噪效果较好, $\mu=0.5$ 的时候会出现失真现象, $\mu=15$ 时出现抖动。该次实验中五种方法降噪后的信噪比分别为15.57,16.18,15.01,17.58和16.59,随着噪声分布的不同, μ 会在不同值时取得较高的信噪比。

2 短时傅里叶变换

STFT是Gabor于1946年提出的,通过加窗的方法解决了傅里叶变换不能同时解决时频的问题^[20]。窗函数的大小是固定的,通过对时序信号加窗,滑动窗口可以将原始信号分割成多个片段,然后对每个片段做快速傅里叶变换,从而得到时域信号的分段频率信息。

设 $x=(x_1, x_2, \dots, x_n)$ 为一条长度为 n 的时序数据,将其转换为 $m \times k$ 的二维图像数据的过程如下(其中 m 表示时间维度, k 表示频率长度, $wimm$ 表示窗大小, s 表示滑动步长):


第一步, n 是否小于 $wimm$,如果小于,则 $m=1$,否则 $m = \text{int}\left(\frac{n+s-wimm}{s}\right)$;

第二步,将 x 切割成 m 个长度为 $wimm$ 的帧信号,如果最后一帧长度小于 $wimm$,后面补零得到帧片段矩阵 $X_{m \times wimm}$;

第三步,帧片段矩阵与窗函数做点集运算,得到帧信号矩阵 $X_{m \times wimm}$;

第四步, $X_{m \times wimm}$ 补零扩充为 $W_{m \times 2k}$,补零增加维度以提高数据分辨率;

第五步,帧信号矩阵 $W_{m \times 2k}$ 进行快速傅里叶变换,取一半维度得到矩阵 $X_{m \times k}$;

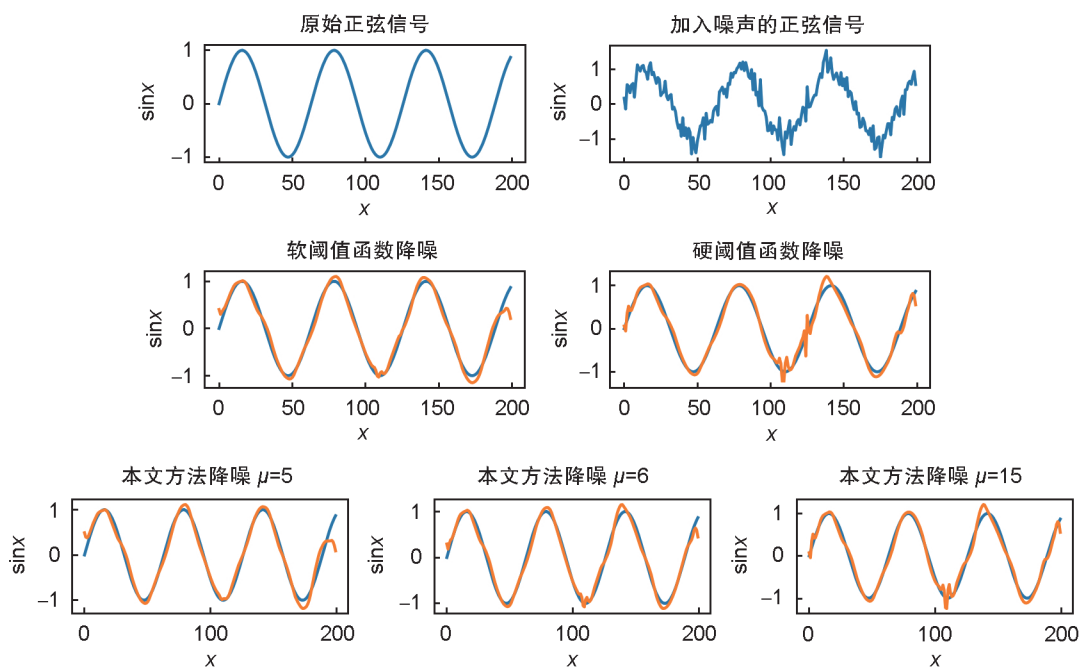


阈值函数及 μ 值

注:横坐标表示不同的阈值函数以及本文阈值函数中 μ 的不同取值;纵坐标为以软阈值函数降噪后的信噪比作为标准归一化值。

图3 信噪比折线图

Fig. 3 Line chart of signal to noise ratio



注:蓝色为原始正弦信号,黄色为降噪后信号

图4 正弦函数降噪仿真实验

Fig. 4 Simulation experiment of noise reduction in sin function

第六步,返回 $X_{m \times k}$ 。

3 卷积神经网络

CNN基本结构是由如下几部分组成的:输入层、卷积层、池化层和全连接层。卷积层中的每个卷积过滤器重复作用于输入数据,提取数据的局部特征,卷积核的尺寸越小提取的细节越细微。池化层是一种非线性降采样方法,接收卷积层的输出,可以通过池化函数计算输入矩阵小块连续区域的聚合值实现规模缩减。池化函数一般取最大值函数,池的大小一般是正方形输入,如果图数据在微小平移下是不变的,那么池化操作的效果是很明显的。池化层

不仅可以减小来自上层的计算复杂度,同时保持了提取特征平移不变性。

本文借鉴了VGG网络的思想,采用小的卷积核和池化核,在深度上做了削减,降低了模型的训练成本^[21]。针对时序数据搭建了一维卷积神经网络(1DCNN)框架,如图5所示,卷积层分别采用了32、64和128个 1×3 的过滤器,步长为1;池化层大小为 1×3 ;全连接层包含两个隐藏层和一个输出层,第一个隐藏层有256个神经元,第二个隐藏层有512个神经元;输出层有5个神经元。针对图像数据搭建了2DCNN框架,如图6所示,共有三层卷积层,每层包括128个 3×3 的过滤器,步长为1;池化

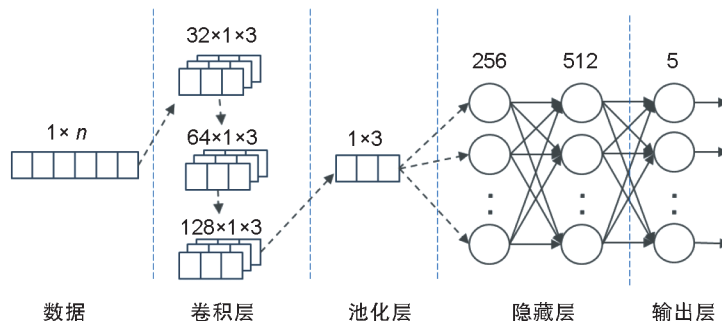


图5 1DCNN框架

Fig. 5 Framework of 1DCNN

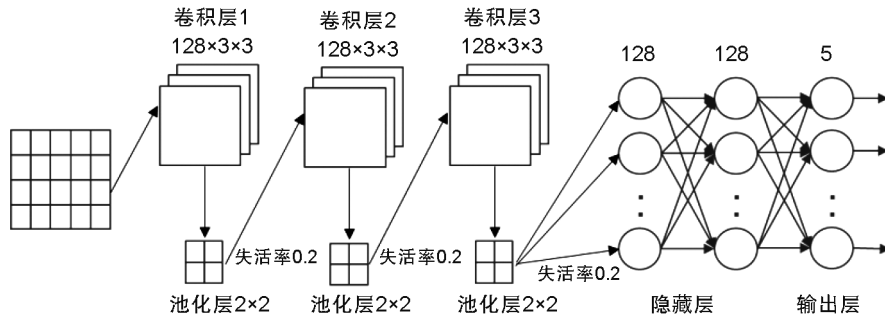


图6 2DCNN框架

Fig. 6 Framework of 2DCNN

层大小为 2×2 , 失活率取 0.2; 隐藏层有两层, 分别有 128 个神经元; 输出层有 5 个神经元。

4 实验及结果分析

4.1 数据采集

本文以上肢运动为例, 针对上肢运动的五个基本动作进行数据采集: 上举(AU)、平举(AF)、扩胸(CE)、向后甩胳膊(TH)和弯腰触地(BTF)。采用无创伤可穿戴信号的采集器, 结合人体运动力学原理: 人类上肢的活动是由大臂抬起带动小臂发力的过程。因此将肌电信号采集设备捆绑在小臂上, 每当肌肉活动的时候, 就会产生电活动, 被穿戴在身上的数据采集器记录下来, 经表面电极引导、放大并传输到电脑获得时间序列信号, 振幅约为 $0 \sim 5\,000 \mu\text{V}$, 频率为 $30 \sim 350 \text{ Hz}$ 。

本实验的实验对象为 8 名在校学生 10 天内

上肢运动所产生的信号。为了避免周围环境的干扰, 测试者中午在自习室进行了数据采集, 信号的采样时间设置为 3.5 s, 一共采集了 3 688 个动作的信号, 每个信号的长度为 2 000。图 7 显示的是同一个受测者五个动作的时序信号, 根据图中显示可以看出, 不同的上肢运动的 sEMG 存在着很明显的肌肉用力时间和力度的差异。

4.2 性能评估

定义 TP, FP, FN, TN 如表 1 所示。

本文主要使用精确率 ($Precision, P$), 召回率 ($Recall, R$), $F1$ 值 ($F1$) 和准确率 ($Accuracy$,

表1 混淆矩阵

Table 1 Confusion matrix

	Predicted Positive	Predicted Negative
Actual Positive	TP	FN
Actual Negative	FP	TN

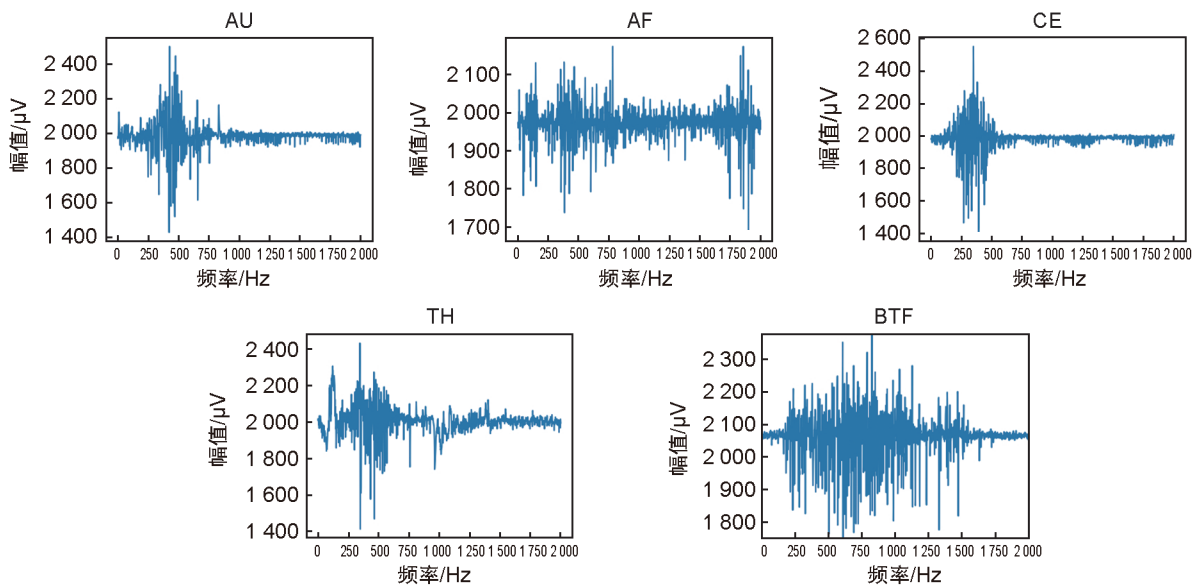


图7 五种不同动作肌电信号

Fig. 7 sEMG of five different movements

Acc)作为模型的估指标:

P :指在所有系统判定的“真”的样本中,确实是真的占比。

$$P = \frac{TP}{TP + FP} \quad (5)$$

R :指在所有确实为真的样本中,被判为的“真”的占比。

$$R = \frac{TP}{TP + FN} \quad (6)$$

$F1$:为了综合权衡 P 和 R ,引入了 $F1$ 并在本文中使用 $\beta=1$ 作为评估标准。

$$F1 = (1 + \beta^2) \frac{P \cdot R}{\beta^2 \cdot P + R} \quad (7)$$

Acc :指在所有预测的样本中,识别正确的占比。

$$Acc = \frac{TP + TN}{TP + FN + TN + FP} \quad (8)$$

4.3 信号降噪

本实验采用4层小波分解,利用软阈值函数、硬阈值函数和新的阈值函数对 cd 中的小波系数重置,然后重构信号得到降噪后的信号。图8为同一信号利用不同的阈值函数降噪后局部放大图,通过实验本文数据集新阈值函数中参数 $\mu = 0.5$ 。




图8 不同阈值函数降噪后信号的局部放大图

Fig. 8 Local amplification of signals after denoising by different threshold function

4.4 时序数据图像化

利用短时傅里叶变换将时序数据转换成图像数据,窗函数使用hamming函数,通过调整窗口和步长的大小,可以生成不同大小的图像数据。为了选择合适大小的图像,分别令 $winn =$

100、150、200、300, 步长 $s = 50、100、150$, $epochs = 50$ 来测试窗口大小、步长与准确率之间的关系。如图9所示,通过实验本文最终采用窗口大小 $winn = 200$, $s = 50$, 图像数据大小为 37×500 , 图10为两个不同信号的图像数据。

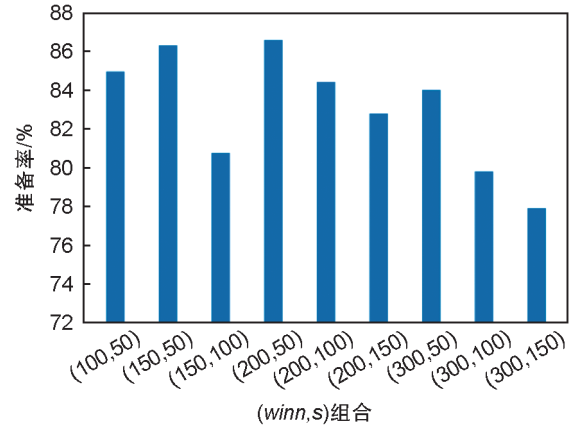


图9 不同窗口大小 $winn$ 和步长 s 图像化后识别准确率

Fig. 9 Recognition accuracy of image data using different window sizes $winn$ and step sizes s

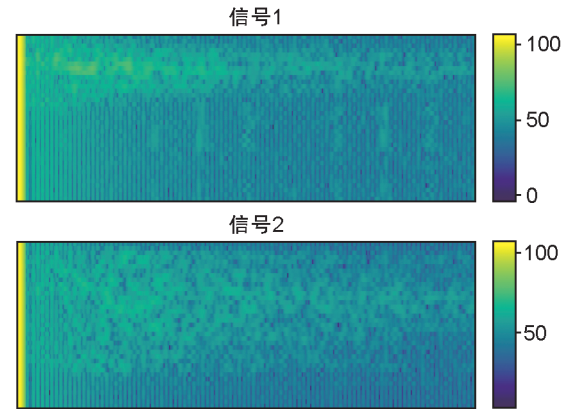


图10 两个不同时序信号转换成的图像数据

Fig. 10 Image data converted from two different timing signals

4.5 实验结果与分析

对采集的3688组5种不同动作的肌电信号数据,按照8:2的比例将数据集划分为训练集与测试集. 其中用于训练的数据共有2950组,用于测试的数据共有738组. 使用交叉熵损失函数 (categorical_crossentropy) 作为该训练模型的损失函数:

$$L = - \sum_{i=1}^M y_i \log \hat{y}_i \quad (9)$$

其中, M 表示样本个数, y_i 表示真实标签, \hat{y}_i 表示预测的概率。

表2 数据降噪后性能对比

Table 2 Comparison of performance after data denoising

	P/%				R/%				F1/%			
	原始数据	软阈值	硬阈值	本文方法	原始数据	软阈值	硬阈值	本文方法	原始数据	软阈值	硬阈值	本文方法
AU	84.1	88.12	88.81	90.16	50.52	52.97	40	<u>51.03</u>	52.6	58.97	67.14	68.97
AF	96.77	96.35	96.56	97.32	89.64	91.33	90.95	91.91	91.36	93.66	93.63	93.89
CE	89.72	94.2	92.43	<u>93.87</u>	95.7	94.79	96.25	97.08	93.73	94.54	94.28	95
TH	70.63	67.34	69.13	74.74	79.66	81.07	85.16	<u>84.95</u>	77.47	78.47	75.3	<u>78.18</u>
BTF	66.8	69.31	67.96	<u>68.99</u>	79.74	85.99	86.55	86.55	75.98	76.74	74.03	76.77
平均	81.60	83.06	82.98	85.02	80.65	81.83	79.78	82.10	78.23	80.48	80.88	82.56

注:粗体表示最优结果,下划线表示次优结果。

表2为利用2DCNN作为分类模型,在原始数据和不同阈值函数降噪后的数据下的各指标对比,通过表2可以看出P,R和F1值最好的情况分别为97.32,97.08和93.89,其中BTF和AU两个动作的识别率较低,可能存在数据采集器位置不正确等因素。新的阈值函数在使用2DCNN时P,R和F1都有一定的提高。

表3为采用新的阈值函数降噪的图像数据作为数据集的混淆矩阵,每一列代表了预测类别,每一列的总数表示预测为该类别的数据的数目,每一行代表了数据的真实归属类别,每一行的数据总数表示该类别的数据实例的数目。

表3 不同动作结果混淆矩阵

Table 3 Confusion matrix for different action recognition results

	AU	AF	CE	TH	BTF
AU	108	0	0	11	12
AF	0	163	9	1	0
CE	1	3	155	1	0
TH	8	0	1	139	7
BTF	3	0	0	7	109

表4为使用RF、SVM、MLP、1DCNN和2DCNN模型的不同动作识别精确率对比,其中前四个模型使用的是时序数据。可以看出2DCNN模型在四个动作数据上的准确率和平均准确率都表现为最优,SVM模型表现最差。

5 结论

本文利用采集器采集五种基本的上肢运动的表面肌电信号,利用离散小波分解的方法对信号降噪和重构,利用加窗傅里叶的方法将时序数据转换为图像数据,搭建了2DCNN。通过

表4 不同模型精确率比较

Table 4 Comparison of precision between different models

	RF	SVM	MLP	1DCNN	2DCNN
AU	90.03	57.32	53.33	70.54	90.16
AF	40.3	53.78	93.38	90.9	97.32
CE	90.63	66.98	88.24	91.14	93.87
TH	72.77	56.78	69.88	72.22	74.74
BTF	86.67	54.06	80.58	80.29	81.99
平均准确率/%	76.28	57.78	77.08	82.22	85.02

实验结果表明,本文提出的新的阈值函数可以针对不同的数据集调整收缩因子,选择适合的阈值函数,克服软阈值函数失真和硬阈值函数抖动的现象。通过多种模型准确率的比较得出,2DCNN能有效的提高识别率。对肌电信号的研究结果可以使用在医疗领域,有效的对病人上肢状况做出正确的评估。

参考文献:

[1] YU Y P, FAN L C, KUANG S L, *et al.* The Research of sEMG Movement Pattern Classification Based on Multiple Fused Wavelet Function[C]//2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER). 2015: 487-491. DOI: 10.1109/CYBER.2015.7287987.

[2] 吴冬梅,孙欣,张志成,等.表面肌电信号的分析和特征提取[J].中国组织工程研究与临床康复,2010(43):8073-8076. DOI:10.3969/j.issn.1673-8225.2010.43.024.

WU D M, SUN X, ZHANG Z C, *et al.* Feature Collection and Analysis of Surface Electromyography Signals[J]. *J Clin Rehabil Tissue Eng Res*, 2010(43): 8073-8076. DOI: 10.3969/j.issn.1673-8225.2010.43.024.

[3] MALLESWARI P N, HIMA B C, SATYA P K. An Improved Denoising of Electrocardiogram Signals Based on Wavelet Thresholding[J]. *J Biomim Biomater Biomed Eng*, 2021, **51**: 117-129. DOI: 10.4028/www.scientific.net/jbbbe.51.117.

- [4] SHI Y B, ZHANG J J, JIAO J J, *et al.* Calibration Analysis of High-G MEMS Accelerometer Sensor Based on Wavelet and Wavelet Packet Denoising[J]. *Sensors*, 2021, **21**(4): 1231. DOI: 10.3390/s21041231.
- [5] 李晋斐, 赵冬青, 王栋民, 等. 一种基于组合赋权法的小波去噪质量评价方法[J]. 北京航空航天大学学报, 2023, **49**(3): 718–725. DOI: 10.13700/j. bh. 1001-5965.2021.0303.
LI J F, ZHAO D Q, WANG D M, *et al.* A Quality Evaluation Method for Wavelet Denoising Based on Combinatorial Weighting Method[J]. *J Beijing Univ Aeronaut Astronaut*, 2023, **49**(3): 718–725. DOI: 10.13700/j. bh. 1001-5965.2021.0303.
- [6] MALLAT S. A Wavelet Tour of Signal Processing[M]. San Diego, CA: Academic Press, 1997.
- [7] 刘恒冰, 韩世勤, 刘晶. 基于新阈值函数及最优尺度的小波去噪研究[J]. 计算机工程与应用, 2007, **43**(24): 72–74. DOI: 10.3321/j.issn: 1002-8331.2007.24.019.
LIU H B, HAN S Q, LIU J. Wavelet De-noising Based on Novel Thresholding Function and Best Decomposition Scale [J]. *Comput Eng Appl*, 2007, **43**(24): 72–74. DOI: 10.3321/j.issn: 1002-8331.2007.24.019.
- [8] DONOHO D L. De-noising by Soft-thresholding[J]. *IEEE Trans Inf Theory*, 1995, **41**(3): 613–627. DOI: 10.1109/18.382009.
- [9] DONOHO D L, JOHNSTONE I M. Ideal Spatial Adaptation by Wavelet Shrinkage[J]. *Biometrika*, 1994, **81**(3): 425–455. DOI: 10.1093/biomet/81.3.425.
- [10] BRUCE A G, GAO H Y. Wave Shrink with Firm Shrinkage [J]. *Statistica Sinica*, 1997, **7**(4): 855–874. DOI: 10.1007/s004400050133.
- [11] GU J X, WANG Z H, KUEN J, *et al.* Recent Advances in Convolutional Neural Networks[J]. *Pattern Recognit*, 2018, **77**: 354–377. DOI: 10.1016/j.patcog.2017.10.013.
- [12] WAIBEL A. Phoneme Recognition using Time-delay Neural Networks[C]//Meeting of the Institute of Electrical Information and Communication Engineers (IEICE). Tokyo, Japan, 1987.
- [13] LECUN Y, BENGIO Y. Convolutional Networks for Images, Speech, and Time Series[M]. Cambridge: MIT Press, 1995.
- [14] MUNIR M, SIDDIQUI S A, DENGEL A, *et al.* DeepAnT: a Deep Learning Approach for Unsupervised Anomaly Detection in Time Series[J]. *IEEE Access*, 2018, **7**: 1991–2005. DOI: 10.1109/ACCESS.2018.2886457.
- [15] WANG Z G, OATES T. Imaging Time-series to Improve Classification and Imputation[C]//Proceedings of the 24th International Conference on Artificial Intelligence. New York: ACM, 2015: 3939–3945. DOI: 10.5555/2832747.2832798.
- [16] 骆俊锦, 王万良, 王铮, 等. 基于时序二维化和卷积特征融合的表面肌电信号分类方法[J]. 模式识别与人工智能, 2020, **33**(7): 588–599. DOI: 10.16451/j. cnki. issn1003-6059.202007002.
LUO J J, WANG W L, WANG Z, *et al.* Surface Electromyography Classification Method Based on Temporal Two-dimensionalization and Convolution Feature Fusion[J]. *Pattern Recognit Artif Intell*, 2020, **33**(7): 588–599. DOI: 10.16451/j. cnki. issn1003-6059.202007002.
- [17] WANG Z G, OATES T. Encoding Time Series as Images for Visual Inspection and Classification Using Tiled Convolutional Neural Networks[C]// Workshops at the Twenty-ninth AAAI Conference on Artificial Intelligence. 2015.
- [18] 王新平, 夏春明, 颜建军. 基于肌音信号图像化和卷积神经网络的手语识别研究[J]. 计算机科学, 2021, **48**(11): 242–249. DOI: 10.11896/jsjx.201000019.
WANG X P, XIA C M, YAN J J. Sign Language Recognition Based on Image-interpreted Mechanomyography and Convolution Neural Network[J]. *Comput Sci*, 2021, **48**(11): 242–249. DOI: 10.11896/jsjx.201000019.
- [19] WANG C L, ZHANG C L, ZHANG P T. Denoising Algorithm Based on Wavelet Adaptive Threshold[J]. *Phys Procedia*, 2012, **24**: 678–685. DOI: 10.1016/j. phpro.2012.02.100.
- [20] 胡广书. 数字信号处理导论[M]. 2版. 北京: 清华大学出版社, 2013: 88–178.
HU G S. Introduction to Digital Signal Processing[M]. 2nd ed. Beijing: Tsinghua University Press, 2013: 88–178.
- [21] SIMONYAN K, ZISSERMAN A. Very Deep Convolutional Networks for Large-scale Image Recognition[J]. arXiv Preprint: 1409.1556, 2014.