

DOI: 10.13382/j.jemi.B2003032

# 时频广义 S 变换和 VL-MOBP 神经网络在 人体动作识别中的应用\*

尹柏强 邓 影 王署东 胡增超 李 兵 佐 磊  
(合肥工业大学 电气与自动化工程学院 合肥 230009)

**摘 要:**针对仿生假肢动作识别问题,提出基于时频广义 S 变换和 VL-MOBP 神经网络的下肢动作识别方法。首先用时频广义 S 变换对年龄在 20~40 岁,身高在 170~185 cm,体重在 50~75 kg 的 22 名男性测试者下肢 4 种表面肌电信号和膝盖弯曲度信号进行多分辨率分析,得到在时间和频率分辨率较好情况下信号时频累计特性曲线,然后提取时频累计特性曲线幅值的均值和标准差作为特征向量,用 VL-MOBP 神经网络对人体下肢的行走、站立及静坐 3 种动作进行识别。实验结果表明,提出的下肢动作识别方法能够取得很好的识别效果,平均识别准确度达 96.67%,高出小波变换约 56%,高出短时傅里叶变换约 36%,验证了该方法在动作识别中的有效性。

**关键词:**时频广义 S 变换;VL-MOBP 神经网络;表面肌电信号;动作识别

**中图分类号:** TN911.7      **文献标识码:** A      **国家标准学科分类代码:** 510.4030

## Application of time-frequency generalized S transform and VL-MOBP neural network in human motion recognition

Yin Baiqiang Deng Ying Wang Shudong Hu Zengchao Li Bing Zuo Lei  
(School of Electrical and Automation Engineering, Hefei University of Technology, Hefei 230009, China)

**Abstract:** Aiming at the needs of bionic prosthetic motion recognition, a lower limb motion recognition method based on time-frequency generalized S transform and VL-MOBP neural network was proposed. First, time-frequency generalized S-transform was used to measure 4 kinds of surface electromyographic signals and knee flexion of the lower extremities of 22 male subjects aged between 20 and 40 years old, between 170 cm and 185 cm tall and weight between 50 kg and 75 kg. Using multi-resolution analysis of the frequency signal to obtain the time-frequency cumulative characteristic curve of the signal when the time and frequency resolution were good, then extracting the mean and standard deviation of the amplitude of the time-frequency cumulative characteristic curve as the feature vector, and using the VL-MOBP neural network to recognize the three movements of human lower limbs: Walking, standing, and sitting. The experimental results showed that the proposed lower limb movement recognition method can achieve good recognition results, with an average recognition accuracy of 96.67%, which is about 56% higher than the wavelet transform and about 36% higher than the short-time Fourier transform. Effectiveness in motion recognition has been verified.

**Keywords:** time-frequency generalized S transform; VL-MOBP neural network; surface electromyographic; action recognition

## 0 引 言

我国残疾人总数约 8 500 万。而可就业年龄阶段占这一总数的 1/4 以上。如何确保残疾人的日常工作与生活已经成为当今社会所面临的一大问题。仿生假肢能够

满足残疾人日常工作与生活的基本需求,而仿生假肢动作识别一直是制作仿生假肢的难点。根据人体表面肌电信号(surface electromyography, sEMG)<sup>[1]</sup>识别肢体动作,再将该项技术移植到仿生假肢的制作过程中,对利用仿生假肢提高残疾人的生活质量具有重大价值和意义。

基于表面肌电信号动作识别方法的关键是如何提取表面肌电信号的特征值。文献[2]采用神经网络进行动作特征提取并利用 Softmax 分类器<sup>[3]</sup>对人体6种动作进行识别分类。文献[4]采用切比雪夫 I 型方法<sup>[5]</sup>对信号进行降噪并提取特征,然后送到粒子群优化支持向量机<sup>[6]</sup>中实现对6个跑动相位的识别。文献[7]提出一种基于多源信息融合的膝上假肢步态识别方法对下肢运动信息进行步态识别。文献[8]利用二维小波包分解对超宽带雷达人体9种不同动作进行分类。文献[9]提出一种基于压缩稀疏融合的动作识别方法对8种不同的人体动作进行有效识别。此外还有学者采用块稀疏贝叶斯学习<sup>[10]</sup>、短时傅里叶变换(short-time Fourier transform, STFT)<sup>[11]</sup>、小波包变换<sup>[12]</sup>等方法来辨识表面肌电信号动作模式。以上识别方法都有各自的优势。但表面肌电信号是非平稳信号,信号特征容易在提取过程中丢失,信号特征的丢失容易导致动作模式识别的准确度不高,因此需要采用更加灵活的特征提取方法来适应其非平稳特性,从而提高动作模式识别的准确度。

针对表面肌电信号的非平稳特性,本文采用改造后的 S 变换<sup>[13-16]</sup>,即时频广义 S 变换用于表面肌电信号的特征提取。时频广义 S 变换是在参数取值  $\gamma > 1, \rho > 1$ , 即时间分辨率较好情况下及  $\gamma > 1, \rho < 1$ , 即频率分辨率

较好情况下对原始信号做两次变换。时频广义 S 变换采用宽度随频率呈反比变化的高斯窗函数,在低频段的时窗较宽,可以获得较高的频率分辨率;而高频段的时窗较窄,可以获得较高的时间分辨率。相比于 STFT 固定的变换窗口,时频广义 S 变换的高斯窗可以根据原始信号频率的变化而变化。相比于小波变换基函数如何选择的难题,时频广义 S 变换采用高斯函数作为变换的基函数。因为时频广义 S 变换引入两个调节参数  $\gamma$  和  $\rho$ , 相比于 S 变换中高斯窗口宽度随原始信号频率变换的固定速率,时频广义 S 变换不仅能够根据原始信号的频率来改变高斯窗的宽度,还能根据该频率来改变高斯窗宽度随频率变化的速率。时频广义 S 变换灵活多变的高斯窗也使得该变换比 STFT、小波变换及 S 变换等传统时频分析方法具有更强的时频表征能力,对非平稳的表面肌电信号特征提取有明显优势,从而实现更好的分类效果。

对采集到的人体下肢表面肌电信号和膝盖弯曲度信号用时频广义 S 变换进行多分辨率分析,得到信号的时频累计特性曲线,提取累计特性曲线幅值的均值和标准差作为特征向量,送到学习率可变动量反向传播(variable learning rate momentum backpropagation, VL-MOBP)<sup>[17]</sup>神经网络中进行识别分类。本文结构框图如图1所示。




图1 结构框图

Fig.1 Structure diagram

## 1 时频广义 S 变换

假设  $x(t)$  是测试的原始表面肌电信号,则该信号的 S 变换定义式如下:

$$S(\tau, f) = \int_{-\infty}^{\infty} x(t) \left\{ \frac{|f|}{\sqrt{2\pi}} e^{-\frac{\tau^2(\tau-t)^2}{2}} e^{-i2\pi ft} \right\} dt \quad (1)$$

式中:  $f$  为原始表面肌电信号的频率;  $\tau$  用于控制时间轴上高斯窗函数的位置。

时频广义 S 变换是对 S 变换的高斯窗函数进行改造,通过引入两个调节参数  $\gamma$  和  $\rho$ , 能灵活地改变窗函数形状和宽度,使得时窗能适应实际信号频率的不断变化,从而获得理想的时频分辨率<sup>[18]</sup>。时频广义 S 变换的表达式为:

$$S(\tau, f) = \int_{-\infty}^{\infty} x(t) \left\{ \frac{|\gamma| |f|^\rho}{\sqrt{2\pi}} e^{-\frac{\gamma^2 2^\rho (\tau-t)^2}{2}} e^{-i2\pi ft} \right\} dt \quad (2)$$

式中:  $\rho \in [1/2, 3/2]$ ,  $\gamma$  是调节因子。选定  $\rho$  后,当  $|\gamma| > 1$  时,信号的时间分辨率将被提高,当  $|\gamma| < 1$  时信号的频率分辨率将被提高<sup>[19]</sup>。根据海森堡测不准原理,时间分辨率和频率分辨率是互相矛盾的,在取得较好时间分辨率的同时频率分辨率会下降,所以如何选择时间分辨率和频率分辨率应该从处理的实际问题出发,根据实际需求来选取想要的变换结果。

图2所示时频广义 S 变换的高斯窗函数( $f$  是原始表面肌电信号的频率,  $\tau$  用于控制时间轴上高斯窗函数的位置),当选定  $\rho = 1$  时,不难看出当  $\gamma$  取 0.5 时,时频广义 S 变换在时域上移动的高斯窗随着频率增大而变窄的速率比较缓慢,当  $\gamma = 1$  时,该速率所有加快,当  $\gamma = 2$  时,

该速率要比  $\gamma$  取 0.5 和 1 时的更快,根据时频广义 S 变换高斯窗口的特性,在实际问题中,根据不同需求来改变高斯窗宽度随频率呈反比变化的速率,这样更有助于信号的分析 and 处理。




图 2 时频广义 S 变换高斯窗

Fig. 2 Time-frequency generalized S transform Gaussian window

2 VL-MOBP 神经网络

BP (back propagation) 神经网络是神经网络家族中的一员,它是感知器和自适应线性神经网络的发展。该网络是将误差反向传播算法融入到神经网络中得到的一种广泛用于函数逼近、模式识别 (分类)、数据压缩的神经网络。

BP 神经网络的神经元与感知器类似,只不过 BP 神经网络的传输函数是非线性的,常用的有  $\log\sin$  函数和  $\tan\ sig$  函数,有的时候会用  $purelin$  函数。其输出表达式为:

a = purelin(Wp + b) (3)

式中:  $p$  和  $a$  是网络的输入和输出;  $W$  和  $b$  是网络的权值和偏置。BP 神经网络一般是多层神经网络,信息从输入层传向输出层,网络的学习就是对权值  $W$  和阈值  $b$  进行修正,使得输入和输出满足一定的映射关系。标准 BP 神经网络的学习算法为梯度下降法,其权值和阈值的修正沿着误差性能函数梯度方向的反方向进行的。标准 BP 算法在函数训练过程中容易陷入局部最小值和振荡,使得最终的输出结果误差偏大。本文对标准 BP 算法进行改进,在梯度下降法的基础上引进动量因子  $\mu$ :

\Delta x(k+1) = \mu \Delta x(k) + \alpha(1-\mu) \partial E(k) / \partial x(k) (4)

x(k+1) = x(k) + \Delta x(k+1) (5)

其中  $0 < \mu < 1$ ,  $\Delta x$  为权值或阈值的修正量,  $k$  为网络训练次数,  $\alpha$  是学习率,  $\partial E(k) / \partial x(k)$  是误差性能函数对权值或阈值的梯度。该算法是用前一次的修正结果来影响本次的修正结果,当前一次修正量过大时,式(4)中第 2 项符号将与前一次的修正量符号相反,使得本次的修正量减小,当前一次修正量较小时,式(4)中第 2 项符号将与前一次的修正量符号相同,使得本次的修正量增加。

学习率对一个算法的收敛性至关重要。学习率过

大,容易导致算法不收敛,不能达到理想的训练效果。学习率过小,收敛速度慢,算法的实时性差,而要在训练之前选择一个最佳学习率是很难的。本文提出的 VL-MOBP 算法则能很好地解决这个问题。当误差以减小的方式趋于目标误差时,说明修正方向正确,此时将学习率乘以增量因子  $k_{inc}$ ,增大学习率,当误差超过了设定值时,说明修正方向错误,此时将学习率乘以减量因子  $k_{dec}$ ,使学习率减小,并且舍弃上一步权值和阈值的修正。即:

\alpha(k+1) = \begin{cases} k\_{inc} \alpha(k), & E(k+1) < E(k) \\ k\_{dec} \alpha(k), & E(k+1) > E(k) \end{cases} (6)

同时引入动量因子  $\mu$ 、增量因子  $k_{inc}$  和减量因子  $k_{dec}$ ,不仅能够获得较快的收敛速率,还能够防止在训练过程中出现局部最小值及振荡问题。

3 实验仿真与训练

3.1 表面肌电信号数据

本实验使用表面肌电传感器来采集人体下肢表面肌电信号,该传感器是一种主动感应传感器,操作简单,能提供极高质量的信号。让该传感器与移动便携 DataLOG 系统直接连接使用进行信号的传输。该系统一共有 8 个数字通道和 4 个模拟通道,其中 4 个数字通道用于表面肌电信号的采样,1 个模拟通道用于测量膝盖角度。这些数据通过蓝牙适配器在实时数据记录软件中传输,14 位分辨率,采样频率为 1 000 Hz。

该实验对 22 名男性测试者进行实验,这 22 名男性测试者的年龄在 20~40 岁,身高在 170~185 cm,体重在 50~75 kg,其中 11 个人是由专家诊断过的膝关节异常患者,另外 11 位是正常测试者。让这 22 名测试者分别进行行走、站立及静坐 3 种动作,在这过程中使用 4 个数字通道采集 RF、BF、VM 和 ST 的电信号,然后用一个模拟通道采集从坐姿伸直腿和向上弯曲腿过程中腿的角度变化,即 FX 的电信号。由于数据较多,本文截取了第一个正常人在行走、站立及静坐 3 种不同动作下 4 种肌肉电信号和膝盖弯曲度电信号数据样本的一部分,数据如表 1 所示。

表 1 第 1 个正常人的数据样本

Table 1 Data sample of the first normal person


| 动作 | RF/mV    | BF/mV    | VM/mV    | ST/mV    | FX/(°)   |
|----|----------|----------|----------|----------|----------|
| 行走 | 0.000 7  | -0.008 3 | 0.004 5  | -0.009 1 | 57.600 0 |
|    | -0.000 8 | -0.003 8 | 0.000 7  | -0.004 6 | 57.500 0 |
|    | -0.000 8 | -0.006 8 | 0.001 5  | -0.002 3 | 57.300 0 |
| 站立 | 0.001 5  | -0.000 8 | -0.004 6 | 0.000 7  | 3.000 0  |
|    | 0.003 0  | 0.004 5  | -0.015 8 | -0.000 8 | 3.000 0  |
|    | 0.003 7  | 0.004 5  | -0.016 5 | -0.008 0 | 3.000 0  |
| 静坐 | 0.000 7  | -0.000 8 | 0.003 0  | 0.000 0  | 70.100 0 |
|    | -0.000 8 | -0.001 5 | 0.002 2  | 0.000 7  | 70.100 0 |
|    | -0.000 8 | -0.003 0 | 0.000 0  | 0.000 0  | 70.100 0 |

图3所示为第1个正常测试者分别进行行走、站立及静坐3种动作时其股直肌电信号图和膝盖弯曲度的信号图。


观察股直肌电信号图(其他3种肌肉信号图与其类似)和膝盖弯曲度图,不难发现,在3种不同状态下它们的幅值大小及振动频率不一样,所以,可以采用时频广义S变换,将时域信号图转换为时频图,通过提取信号在时频图下的特征值,来对3种动作进行识别分类。

### 3.2 将信号做时频广义S变换

本文采用时频广义S变换将时域下的信号图转换到




(a) Electromyogram of recto femoral



(b) Electromyogram of flexion at the knee


图3 肌电信号原始信号图

Fig. 3 EMG signal original signal diagram




(a) 原始股直肌信号图

(a) Original rectus femoris signal




(b)  $\gamma=1, \rho=1$ 时RF的三维图

(b) RF Three-dimensional image when  $\gamma=1, \rho=1$



(c)  $\gamma=2, \rho=1.5$ 时RF的三维图

(c) RF Three-dimensional image when  $\gamma=2, \rho=1.5$



(d)  $\gamma=2, \rho=0.5$ 时RF的三维图

(d) RF Three-dimensional image when  $\gamma=2, \rho=0.5$

图4 股直肌在不同分辨率下的三维图

Fig. 4 3D images of RF at different resolutions

时间-频率下的时频图。时频广义S变换中不同 $\gamma$ 和 $\rho$ 的取值,会得到不同的时间分辨率和频率分辨率。现在就以第一个正常人在行走时股直肌电信号为例,在3种不同的取值下即 $\gamma=1, \rho=1$ ;  $\gamma=2, \rho=1.5$ ;  $\gamma=2, \rho=0.5$ 对该信号进行分析,并画出它们的时频广义S变换三维图及时频累计特性曲线,如图4所示。其中,图4(a)、(b)中 $P1$ 、 $P2$ 、 $P3$ 为股直肌信号图对称三点;图4(c)中 $P1t$ 、 $P2t$ 、 $P3t$ 为图4(b)中未能识别出的点;图4(d)中 $P1f$ 、 $P2f$ 、 $P3f$ 为图4(b)中未能识别出的点。



图 4(a) 是第 1 个正常人在行走时股直肌的原始电信号图, 由图中  $P1(0.20, 0.11)$ 、 $P2(2.74, 0.09)$  和  $P3(5.30, 0.10)$  三点的坐标可以看出, 该电信号呈周期性, 并且在每个周期最高点对应的电压幅值大小基本相等。将该信号在不同  $\gamma$  和  $\rho$  的取值下做时频广义 S 变换, 得到相应的时频矩阵, 其时频矩阵的三维图如图 4(b) ~ (d) 所示。由图 4(b) 可知, 在  $\gamma = 1, \rho = 1$  时, 信号的时间分辨率和频率分辨率是中性状态, 而其点  $P1$ 、 $P2$  和  $P3$  与图 4(a) 相对应。当时间分辨率设置较高时, 即  $\gamma = 2, \rho =$

1.5, 此时时间轴能够很清晰的分辨出各种时域成分, 在三维图上体现为图 4(c) 中出现了很多在图 4(b) 中未能检测出来的时域成分如  $P1t(1.44, 432.10)$ 、 $P2t(3.52, 400.10)$  和  $P3t(5.247, 470.70)$ 。当设置频率分辨率较高时, 即  $\gamma = 2, \rho = 0.5$ , 此时能够分辨出在原始信号中存在的非常小的频率, 即图 4(d) 中出现了很多图 4(b) 中没有检测出来的频率成分如  $P1f(0.05, 223.60)$ 、 $P2f(0.06, 19.190)$  和  $P3f(5.68, 9.153)$ 。下面从时频累计特性曲线的角度来分析。




图 5 不同分辨率下时频累计特性曲线

Fig. 5 Time-frequency cumulative characteristic curves at different resolutions

图 5 所示为股直肌信号在不同分辨率下时域和频域累计特性曲线。图 5(a)、(c) 是  $\gamma = 1, \rho = 1$  和  $\gamma = 2, \rho = 1.5$  的时频广义 S 变换时域累计特性曲线, 由相同区域放大的图形 1、2 可知, 图 5(c) 的波峰要比图 5(a) 的更尖更窄, 因此取  $\gamma = 2, \rho = 1.5$  时, 时频广义 S 变换在时间轴上能将信号分析得更加精确。图 5(b)、(d) 是  $\gamma = 1, \rho = 1$  和  $\gamma = 2, \rho = 0.5$  的时频广义 S 变换频域累计特性曲线, 由相同区域放大的图形 3、4 可知, 图 5(b) 的波峰要比图 5(d) 的更尖更窄, 故取  $\gamma = 2, \rho = 0.5$  时, 时频广义 S 变换有更高的频率分辨率。根据上面的特征, 分别取在时间和频率分辨率较好情况下信号时频累计特性曲线幅值的均值和标准差作为第 1 个正常人在行走时股直肌信号的

特征向量, 因此股直肌的特征向量有 4 个。实验中测试了 4 种肌肉信号和一个膝盖弯曲度信号, 所以第 1 个正常人在行走动作下有 20 个特征值, 表 2 是第 1 个正常人在 3 种不同动作下的 20 个特征值。通过观察在行走、站立及静坐 3 种动作下的膝盖弯曲度电信号图, 发现在站立动作下信号图的初始状态更接近于  $0^\circ$ , 而在行走及静坐动作下更接近于一定的角度, 因此将膝盖弯曲度信号的第一个取值的绝对值也作为一个特征量, 综上所述, 一个人在一种动作下的特征量是包含 21 个数据的一维矩阵。

### 3.3 训练网络及分类识别

本次训练使用的工具是 MATLABR2018b, 用于训练

的样本是提取的 60 组特征向量,在训练的过程中,将 20 组行走的特征向量标记为 0,20 组站立的特征向量标记

为 1,20 组静坐的特征向量标记为 2。随后将 6 组特征向量输入网络进行分类测试,训练流程如图 6 所示。

表 2 第 1 个正常人在 3 种不同动作下的 20 个特征值  
Table 2 20 eigenvalues of the first normal person in three different action

| 肌肉 | 维度 | 行走         |            | 站立          |             | 静坐          |             |
|----|----|------------|------------|-------------|-------------|-------------|-------------|
| RF | 时间 | 41.508     | 50.553     | 38.143      | 44.055      | 139.715     | 159.209     |
|    | 频率 | 50.553     | 1.252      | 0.734       | 0.703       | 2.057       | 3.018       |
| BF | 时间 | 20.495     | 26.657     | 236.469     | 369.762     | 29.979      | 26.330      |
|    | 频率 | 0.555      | 0.601      | 5.977       | 5.361       | 0.518       | 0.546       |
| VM | 时间 | 73.877     | 73.208     | 60.435      | 53.458      | 222.280     | 246.706     |
|    | 频率 | 1.270      | 1.855      | 0.983       | 1.106       | 2.963       | 4.964       |
| ST | 时间 | 25.877     | 34.770     | 527.332     | 882.034     | 26.660      | 20.615      |
|    | 频率 | 0.775      | 0.838      | 10.403      | 14.757      | 0.380       | 0.527       |
| FX | 时间 | 76 498.771 | 70 378.202 | 604 387.940 | 410 242.214 | 614 177.927 | 240 426.846 |
|    | 频率 | 208.691    | 2 454.278  | 262.142     | 10 108.317  | 185.580     | 9 316.330   |




图 6 训练流程  
Fig. 6 Training flowchart

网络训练中选用归一化均方误差 (mean squared error, MSE) 函数,初始学习率设为 0.05。图 7 所示为训练过程中的性能函数曲线。

由图 7 可以看出,当训练 80000 次时,最小均方误差出现在 79 997 次,为  $3.2 \times 10^{-8}$ 。分别将两个行走、两个




图 7 性能函数曲线  
Fig. 7 Performance function graph

站立及两个静坐特征值送到已经训练好的网络中测试,得到的结果分别为 0.067 0、0.000 6、0.841 5、1.011 8、1.760 2、1.873 2,假设允许误差为  $\pm 0.25$ ,从测试结果看,6 个测试样本分类均正确。由此也验证了该分类方法的有效性。在相同的误差标准下,本文还使用小波变换、短时傅里叶变换、离散傅里叶变换等方法提取特征值,并送到 VL-MOBP 神经网络中进行分类识别,结果如表 3 所示,表 3 加粗部分表示分类错误样本。

表 4 列出了本文使用的特征提取方法和其他文献中的特征提取方法对人体动作进行识别的平均识别准确度,由表 4 可知,本文使用的方法平均识别准确率为 96.67%,比较其他方法的准确率可知使用时频广义 S 变换和 VL-MOBP 神经网络对人体动作识别的准确率最高,故验证了该识别方法的有效性。

表 3 训练仿真结果  
Table 3 Raining simulation results

| 方法 |         | MSE                    | 输出结果            |                 |                |                |                |                | 错误数 | 正确率/% |
|----|---------|------------------------|-----------------|-----------------|----------------|----------------|----------------|----------------|-----|-------|
| 1  | 本文方法    | $3.20 \times 10^{-8}$  | 0.067 0         | 0.000 6         | 0.841 5        | 1.011 8        | 1.760 2        | 1.873 2        | 0   | 100   |
|    | 小波变换    | $1.16 \times 10^{-10}$ | <b>-0.279 7</b> | <b>0.533 4</b>  | 0.942 0        | <b>0.703 8</b> | <b>1.358 7</b> | 1.877 9        | 4   | 33.33 |
|    | 短时傅里叶变换 | $3.16 \times 10^{-6}$  | <b>-0.541 9</b> | 0.069 8         | 0.872 0        | <b>0.749 4</b> | 2.231 5        | 1.788 2        | 2   | 66.67 |
|    | 离散傅里叶变换 | $2.11 \times 10^{-4}$  | <b>0.312 6</b>  | <b>0.451 7</b>  | 1.028 5        | 1.160 9        | <b>2.259 4</b> | 2.031 7        | 3   | 50    |
| 2  | 本文方法    | $1.66 \times 10^{-9}$  | 0.073 7         | 0.242 0         | 0.877 4        | 0.922 5        | 1.970 4        | 2.215 1        | 0   | 100   |
|    | 小波变换    | $1.40 \times 10^{-10}$ | <b>0.455 5</b>  | 0.014 8         | <b>1.274 8</b> | <b>0.690 6</b> | <b>1.503 0</b> | 1.756 5        | 4   | 33.33 |
|    | 短时傅里叶变换 | $6.61 \times 10^{-5}$  | 0.010 5         | <b>0.429 3</b>  | 1.175 6        | 0.869 0        | 2.190 9        | <b>1.609 7</b> | 2   | 66.67 |
|    | 离散傅里叶变换 | $3.38 \times 10^{-6}$  | <b>-0.384 4</b> | <b>-0.398 5</b> | <b>0.662 6</b> | 0.793 2        | 1.907 9        | <b>1.743 9</b> | 4   | 33.33 |
| 3  | 本文方法    | $9.02 \times 10^{-7}$  | -0.032 5        | <b>0.336 2</b>  | 1.032 5        | 0.911 4        | 1.775 6        | 2.043 9        | 1   | 83.33 |
|    | 小波变换    | $1.59 \times 10^{-8}$  | -0.246 2        | <b>0.304 9</b>  | 0.807 6        | 0.938 6        | <b>1.640 6</b> | <b>1.623 2</b> | 3   | 50    |
|    | 短时傅里叶变换 | $6.59 \times 10^{-8}$  | -0.218 5        | <b>-0.346 3</b> | 0.914 5        | 0.884 6        | 1.981 6        | <b>1.688 0</b> | 2   | 66.67 |
|    | 离散傅里叶变换 | $1.44 \times 10^{-6}$  | <b>-0.273 0</b> | -0.052 6        | <b>0.397 3</b> | 0.910 9        | 1.881 6        | <b>1.743 5</b> | 3   | 50    |
| 4  | 本文方法    | $6.68 \times 10^{-6}$  | 0.024 8         | 0.108 6         | 0.861 3        | 0.761 7        | 1.854 8        | 2.195 5        | 0   | 100   |
|    | 小波变换    | $9.00 \times 10^{-5}$  | <b>-0.493 9</b> | 0.208 4         | <b>0.672 3</b> | <b>0.153 6</b> | <b>1.737 9</b> | 1.981 8        | 4   | 33.33 |
|    | 短时傅里叶变换 | $9.68 \times 10^{-6}$  | -0.168 7        | <b>-0.605 1</b> | 1.048 1        | <b>0.659 0</b> | <b>1.699 7</b> | 1.852 0        | 3   | 50    |
|    | 离散傅里叶变换 | $9.00 \times 10^{-5}$  | 0.129 9         | <b>0.346 9</b>  | 1.217 2        | <b>0.683 3</b> | 1.775 3        | <b>1.462 9</b> | 3   | 50    |
| 5  | 本文方法    | $1.99 \times 10^{-6}$  | 0.027 7         | -0.054 6        | 0.917 3        | 1.181 9        | 1.988 1        | 2.068 1        | 0   | 100   |
|    | 小波变换    | $9.67 \times 10^{-11}$ | <b>0.317 3</b>  | -0.119 5        | <b>0.202 0</b> | 0.799 1        | <b>1.694 1</b> | 2.128 4        | 3   | 50    |
|    | 短时傅里叶变换 | $8.43 \times 10^{-7}$  | -0.069 7        | <b>0.748 2</b>  | 1.064 6        | 1.094 1        | <b>1.723 9</b> | <b>1.736 6</b> | 3   | 50    |
|    | 离散傅里叶变换 | $8.01 \times 10^{-3}$  | 0.133 0         | 0.199 8         | 0.781 9        | <b>0.476 0</b> | 1.857 3        | <b>1.666 9</b> | 2   | 66.67 |

表 4 准确度比较  
Table 4 Accuracy comparison

| 来源     | 信号   | 特征值提取方法   | 分类方法          | 对象         | 平均识别准确度/% |
|--------|------|-----------|---------------|------------|-----------|
| 本文     | sEMG | 时频广义 S 变换 | VL-MOBP 神经网络  | 下肢 3 种动作识别 | 96.67     |
| 本文     | sEMG | 小波变换      | VL-MOBP 神经网络  | 下肢 3 种动作识别 | 40.00     |
| 本文     | sEMG | 短时傅里叶变换   | VL-MOBP 神经网络  | 下肢 3 种动作识别 | 60.00     |
| 本文     | sEMG | 离散傅里叶变换   | VL-MOBP 神经网络  | 下肢 3 种动作识别 | 50.00     |
| 文献[2]  | sEMG | 神经网络      | Softmax 分类器   | 人体 6 类动作识别 | 93.89     |
| 文献[8]  | sEMG | 小波变换      | BP 神经网络/有限状态机 | 步态识别       | 95.00     |
| 文献[10] | sEMG | 块稀疏贝叶斯学习  | -             | 6 类手指动作识别  | 92.90     |
| 文献[20] | sEMG | 小波包       | BP 神经网络       | 20 种手部动作   | 90.90     |

4 结 论

针对仿生假肢动作识别的需要,本文提出了一种基于时频广义 S 变换和 VL-MOBP 神经网络的动作识别方法,分析了表面肌电信号在二维时频域下的基本特性,讨论了时频广义 S 变换在不同  $\gamma, \rho$  取值下对肌电信号特征值的影响,实现了对人体下肢行走、站立及静坐 3 种动作的分类识别。理论分析与仿真实验结果表明,与文献[8,20]提取特征值的方法相比,基于时频广义 S 变换的特征值提取方法更好地保留了原始信号的特征信息。与传统的时频分析方法相比,时频广义 S 变换不仅可以

根据实际信号频率的变化来改变高斯窗口宽度,而且还能根据实际信号的特点和分析侧重点来改变高斯窗口宽度随频率变化的速率。

在数据测试过程中,不仅测试了正常人的肌电信号,

也测试了膝盖异常者的肌电信号,从训练的结果来看,不管是正常测试者还是膝盖异常测试者,在一定误差范围内,都能够准确识别。但由于本文用于识别分类的网络为 BP 神经网络,该网络在训练过程中需要较长时间才能够达到理想的分类效果,所以该网络目前并不适用于在线识别分类,如需实现在线识别分类,则需要使用更加优化的神经网络来对特征向量进行识别。下一步的工作将是使用更加完善的神经网络来对特征值进行分类识别,从而实现人体动作在线识别分类的目标。

参考文献

[ 1 ] CHENG J, CHEN X, LIU A P, et al. A novel phonology- and radical-coded chinese sign language recognition framework using accelerometer and surface electromyography sensors [ J ]. Sensors ( Basel, Switzerland ), 2015, 15(9) :23303-23324.

[ 2 ] 沈西挺,于晟,董瑶,等. 基于深度学习的人体动作识

- 别方法[J]. 计算机工程与设计, 2020, 41(4): 1153-1157.
- SHEN X T, YU SH, DONG Y, et al. Human motion recognition method based on deep learning[J]. Computer Engineering and Design, 2020, 41(4): 1153-1157.
- [3] SUN Y X, WEN G H. Ensemble softmax regression model for speech emotion recognition[J]. Multimedia Tools and Applications, 2017, 76(6): 8305-8328.
- [4] 刘作军, 高新智, 赵晓东, 等. 下肢假肢穿戴者跑步步态识别与膝关节控制策略研究[J]. 仪器仪表学报, 2018, 39(7): 74-82.
- LIU Z J, GAO X ZH, ZHAO X D, et al. Research on running gait recognition and motion control strategy for lower limb prosthesis wearer[J]. Chinese Journal of Scientific Instrument, 2018, 39(7): 74-82.
- [5] CHEN X L, LIU X J, ZHAO Y L. New family of Abelian integrals satisfying Chebyshev property[J]. Journal of Differential Equations, 2020, 268(12): 7561-7581.
- [6] TANG X C, MA Z W, HU Q S, et al. A real-time arrhythmia heartbeats classification algorithm using parallel delta modulations and rotated linear-kernel support vector machines[J]. IEEE Transactions on Bio-Medical Engineering, 2020, 67(4): 978-986.
- [7] 高云园, 余青山, 孟明, 等. 基于多源信息融合的膝上假肢步态识别方法[J]. 仪器仪表学报, 2010, 31(12): 2682-2688.
- GAO Y Y, SHE Q SH, MENG M, et al. Gait recognition method for knee prosthesis based on multi-source information fusion[J]. Chinese Journal of Scientific Instrument, 2010, 31(12): 2682-2688.
- [8] 蒋留兵, 李骥, 车俐. 利用二维小波包分解实现超宽带雷达人体动作识别[J]. 电子测量与仪器学报, 2018, 32(8): 69-75.
- JIANG L B, LI C, CHE L. Human motion recognition of ultra-wideband radar using two-dimensional wavelet packet decomposition[J]. Journal of Electronic Measurement and Instrument, 2018, 32(8): 69-75.
- [9] 于宗泽, 方勇, 李兆元. 基于压缩稀疏融合的动作识别方法[J]. 电子测量技术, 2016, 39(11): 155-159, 172.
- YU Z Z, FANG Y, LI ZH Y. Action recognition method based on compression and sparse fusion[J]. Electronic Measurement Technology, 2016, 39(11): 155-159, 172.
- [10] 丁帅, 王亮. 基于块稀疏贝叶斯学习的肌电信号特征提取[J]. 仪器仪表学报, 2014, 35(12): 2731-2738.
- DING SH, WANG L. Feature extraction of EMG signals based on block sparse Bayesian learning[J]. Chinese Journal of Scientific Instrument, 2014, 35(12): 2731-2738.
- [11] LIU Z K, PENG C, YANG X Q. Research and analysis of the wheeled vehicle load spectrum editing method based on short-time Fourier transform[J]. Proceedings of the Institution of Mechanical Engineers, 2019, 233(14): 3671-3683.
- [12] RIMI P, ANINDITA S. Design and application of discrete wavelet packet transform based multiresolution controller for liquid level system[J]. ISA transactions, 2017, 71(Pt 2): 585-598.
- [13] CHENG Y, LI Y, ZHANG C. First-break picking for microseismic data based on cascading use of Shearlet and Stockwell transforms[J]. Geophysical Prospecting, 2019, 67(1): 85-96.
- [14] LI J H, MA J Q. Seismic surface wave suppression based on the generalized S transform[J]. International Journal of Digital Content Technology and its Applications, 2013, 7(7): 554-560.
- [15] ZHANG J, PENG Z M, ZHANG Q H, et al. Dim target detection based on image features analysis in generalized S-transform domain[C]. 2010 International Conference on Intelligent Computation Technology and Automation, 2010: 122-125.
- [16] YIN B Q, HE Y G. A fast matrix inverse s-transform algorithm for MCG denoise[C]. 12th IEEE International Conference on Electronic Measurement & Instruments, 2015: 315-319.
- [17] WANG W L, ZHAO S L, JIAO L M, et al. Estimation of PM2.5 concentrations in China using a spatial back propagation neural network[J]. Scientific Reports, 2019, 9(1): 13788.
- [18] 韩兵. 基于广义S变换的地震信号时频分析[J]. 内蒙古石油化工, 2016, 42(Z2): 57-60.
- HAN B. Time-frequency analysis of seismic signals based on generalized S transform[J]. Inner Mongolia Petrochemical Industry, 2016, 42(Z2): 57-60.
- [19] 徐永干, 冉恒, 苟鑫, 等. 基于广义S变换和QPSO-SVM的水电机组振动故障诊断方法[J]. 智慧电力, 2020, 48(2): 38-44, 84.
- XU Y G, RAN H, GOU X, et al. Vibration fault diagnosis for hydroelectric generating unit based on generalized S transform and QPSO-SVM[J]. Smart Power, 2020, 48(2): 38-44, 84.
- [20] 都明宇, 王志恒, 苟一, 等. 多模式人手动作分类识别方法[J]. 中国机械工程, 2019, 30(12): 1474-1479.
- DOU M Y, WANG ZH H, XUN Y, et al. Multi-pattern human hand classification and recognition method[J]. China Mechanical Engineering, 2019, 30(12): 1474-1479.



作者简介



尹柏强,2008 年于南华大学获得学士学位,2010 年于湖南大学获得硕士学位,2014 年于湖南大学获得博士学位,现为合肥工业大学副教授,主要研究方向为智能电网、物联网关键技术及应用、复杂电磁环境模拟、分析与评估;

E-mail:yinbaiqiang123@163.com

**Yin Baiqiang** received his B. Sc. degree from University of South China in 2008, M. Sc. degree from Hunan University in 2010, Ph. D. degree from Hunan University in 2014. Now he is an associate professor at Hefei University of Technology. His main research interests include complex signal analysis and

processing, radio frequency identification technology and numerical optimization algorithm.



邓影(通信作者),2018 年于安徽理工大学获得学士学位,现为合肥工业大学硕士研究生,主要研究方向为数字信号处理和深度学习。

E-mail:Dy19951128@163.com

**Deng Ying** (Corresponding author) received his B. Sc. degree from Anhui University of Science & Technology in 2018. Now he is a M. Sc. candidate at Hefei University of Technology. His main research interests include digital signal processing and deep learning.