doi:10.3772/j.issn.1002-0470.2024.11.007

基于分步机器学习的智能假肢步态识别①

刘 磊②* 杨 鹏③** 刘作军**

(*郑州轻工业大学建筑环境工程学院 郑州 450002)

(**河北工业大学人工智能与数据科学学院 天津 300130)

摘 要 为了改善当前智能假肢步态识别在特征值选取和使用单一分类模型进行步态识别的不足,提高智能假肢穿戴者步态识别准确率,选择表面肌电信号(sEMG)作为步态识别信号源,提出基于灰度模型系数的特征提取方法,建立基于分步机器学习的步态识别模型。该模型选取灰度模型系数作为输入特征值,运用深度瘠波神经网络对步态做出初步识别,区分出易混淆步态,最后使用基于花授粉算法优化极限学习机参数的方法对易混淆步态作进一步的区分。实验结果表明,该方法对于平地行走、上楼、下楼、上坡、下坡、起立和坐下 7 种步态的识别准确率为 98.25%,识别时间为 70.48 ms,识别准确率高于单一机器学习模型。

关键词 智能假肢;步态识别;表面肌电信号(sEMG);灰度模型;极限学习机

根据世界卫生组织统计,截至 2022 年,全球下肢截肢者约 3 600 万人[1],这一实际情况促进了智能假肢领域的迅猛发展。智能假肢给无数肢体残缺的人带来了生活的希望,安装智能假肢是目前代偿截肢者基本运动功能的重要途径。智能假肢能够根据传感信息识别假肢穿戴者步态,调整运动参数,使得患者穿戴智能假肢后的行走步态更加接近健康人的步态。市场上有商业化的智能型动力下肢假肢,如冰岛奥索公司的 REHO KNEE[2]、德国奥托博客公司的 C-leg[3]、北京工道风行公司的“风行者”[4]。智能假肢通过获取假肢穿戴者步态信号进行步态识别,表面肌电信号(surface electromyographic signal, sEMG)是人体内部肌肉动作时产生的一种电信号,直接与人体的期望动作相关,表面肌电信号具有无创伤测量和易提取处理等优点,目前已广泛应用于手势识别、假肢控制、肌肉疲劳检测等领域,因此本文选择表面肌电信号作为智能假肢步态识别的信号源。

特征提取和步态分类是假肢步态识别关键的 2 个环节。特征提取消除冗余数据,降低计算成本,国内外研究者对肌电信号的特征提取方法进行了深入的研究,肌电信号广泛应用的特征提取方法主要有时域特征分析法(time domain, TD)、频域特征分析法(frequency domain, FD)、时频域特征分析法(time-frequency domain, TFD)、非线性特征分析法和高阶谱分析法。为了避免特征值维数过高而增加计算量,研究人员采用主成分分析[5]、线性判别分析[6]等方法进行特征降维,从而选取单一分类器进行识别,如 K 最近邻[7]、支持向量机(support vector machine, SVM)[8]、隐马尔科夫模型[9]等。随着深度学习的发展,Kim 等人[10]提出针对用户间可变性的自适应运动意图解码方法,采用卷积神经网络(convolutional neural network, CNN)对肌电信号进行深度特征提取后识别 6 种手部运动,平均识别准确率在 90% 左右。苏本跃等人[11]分析运动意图短时行为样本的特征,采用改进卷积神经网络识别 13 类运动

① 国家自然科学基金(61803843),河南省教育厅重点项目(22B413012)和河南省高等学校重点科研项目(24A480010)资助。

② 男,1984 年生,博士;研究方向:假肢控制,模式识别;E-mail:liulei20060000@126.com。

③ 通信作者,E-mail:kongzhi_xueke@163.com。

(收稿日期:2024-04-22)

模式,平均识别率达到93%。然而深度学习网络需要大量训练样本进行迭代训练,在计算时间开销上会比浅层网络大很多,上述研究虽然采用不同的方法较好地解决了假肢步态识别的难题,但是对于假肢步态识别准确率仍有较大提高空间。

为了更好地解决表面肌电信号时域、频域等特征存在不稳定性的缺点,本文对表面肌电信号建模分析,提出基于灰度模型和分步机器学习的假肢步态识别方法,首先提取表面肌电信号灰度模型系数作为假肢步态识别特征值,然后利用 Relief 算法(relevant features)对特征值降维处理、最后使用深度瘠波神经网络(deep ridgelet neural network,DRNN)和花授粉算法优化极限学习机(flower pollination algorithm optimization extreme learning machine,FPA-ELM)的分步机器学习模型进行步态识别,该方法克服了单一机器学习模型容易陷入局部最优和分类效率低下的问题。实验结果表明,该方法可对平地行走、上楼、下楼、上坡、下坡、起立、坐下进行有效识别,识别准确率优于单一分类器等方法。

1　基本理论

1.1　灰度模型

sEMG 是规律性较弱的非平稳电信号,灰度模型具有可生成相关序列、样本不需要强规律性分布等特点,灰度模型可将规律性较弱的原信号经累加生成后,生成具有指数增长规律的数列,然后对新生成数列进行建模。由于一阶微分方程的解与指数增长的形式一致,因此本文对生成后的新数列建立微分方程,具体步骤如下。

已知肌电信号的特征数列与相关因素特征序列如式(1)所示,其中 n 表示数据长度。

$$\left.\begin{aligned} x_1^{(0)} &= (x_1^{(0)}(1),\ x_1^{(0)}(2),\cdots,x_1^{(0)}(n)) \\ x_2^{(0)} &= (x_2^{(0)}(1),\ x_2^{(0)}(2),\cdots,x_2^{(0)}(n)) \\ &\vdots \\ x_N^{(0)} &= (x_N^{(0)}(1),\ x_N^{(0)}(2),\cdots,x_N^{(0)}(n)) \end{aligned}\right\} \tag{1}$$

令 $x_i^{(0)}(i=1,2,\cdots,N)$ 累加生成序列 $x_i^{(1)}$,本文将数列 $x_i^{(1)}$ 的时刻 $k=1,2,\cdots,n$ 看做连续的变量 t,那么数列 $x_i^{(1)}$ 可看作时间 t 的函数,即 $x_i^{(1)}=x_i^{(1)}(t)$。

$$x_i^{(1)} = \left(x_i^{(0)}(1),\ \sum_{m=1}^{2} x_i^{(0)}(m),\cdots,\sum_{m=1}^{n} x_i^{(0)}(m)\right) \tag{2}$$

其中,m 表示序列个数。

$x_i^{(1)}$ 序列满足一阶线性微分方程模型

$$\frac{\mathrm{d}x_1^{(1)}}{\mathrm{d}t} + ax_1^{(1)} = b_1x_2^{(1)} + b_2x_3^{(1)} + \cdots + b_{N-1}x_N^{(1)} \tag{3}$$

其中,a、b_1 和 b_{N-1} 分别表示微分方程模型第1项、第2项和最后一项系数。

根据导数定义,有:

$$\frac{\mathrm{d}x_1^{(1)}}{\mathrm{d}t} = \lim_{\Delta t\to 0}\frac{x_1^{(1)}(t+\Delta t) - x_1^{(1)}(t)}{\Delta t} = x_1^{(0)}(k+1) \tag{4}$$

生成紧邻均值序列 $Z^{(1)}$,即 $x_1^{(1)}$ 取 k 与 $k+1$ 时刻的平均值,如式(5)所示。

$$x_1^{(0)}(k+1) + \alpha Z^{(1)}(k) = \sum_{i=2}^{N} b_{i-1}x_i^{(1)}(k+1) \tag{5}$$

式(3)的离散形式可表示为式(6),其中,α 表示发展系数,b_{i-1} 表示驱动系数。$b_{i-1}x_1^{(1)}(k+1)$ 表示驱动项。

$$Z^{(1)}(k) = \frac{1}{2}[x_1^{(1)}(k) + x_1^{(1)}(k+1)],\quad k=1,2,\cdots,n-1 \tag{6}$$

令

$$\boldsymbol{B} = \begin{bmatrix} -Z^{(1)}(1) & x_2^{(1)}(2) & \cdots & x_N^{(1)}(2) \\ -Z^{(1)}(2) & x_2^{(1)}(3) & \cdots & x_N^{(1)}(3) \\ \cdots & \cdots & \ddots & \cdots \\ -Z^{(1)}(n-1) & x_2^{(1)}(n) & \cdots & x_N^{(1)}(n) \end{bmatrix} \tag{7}$$

$$\boldsymbol{Y} = [x_1^{(0)}(2),\ x_1^{(0)}(3),\cdots,\ x_1^{(0)}(n)]^{\mathrm{T}} \tag{8}$$

$$\boldsymbol{\beta} = [\alpha,\ b_1,\ b_2,\cdots,\ b_{N-1}]^{\mathrm{T}} \tag{9}$$

式(6)简写成式(10)。

$$\boldsymbol{Y} = \boldsymbol{B}\times\boldsymbol{\beta} \tag{10}$$

其中,$\boldsymbol{Y}$ 与 $\boldsymbol{B}$ 为已知量,$\boldsymbol{\beta}$ 为待定参数,根据最小二乘估计得到近似解如式(11)所示,$\hat{\boldsymbol{\beta}}$ 表示求得的解。

$$\hat{\boldsymbol{\beta}} = (\boldsymbol{B}^{\mathrm{T}}\boldsymbol{B})^{-1}\boldsymbol{B}^{\mathrm{T}}\boldsymbol{Y} = [\hat{\alpha}, \hat{b}_1, \cdots, \hat{b}_{N-1}]^{\mathrm{T}} \quad (11)$$

把 $\boldsymbol{\beta}$ 代回式(3)时,解得 $GM(1,N)$ 时间响应函数模型如(12)所示。

$$\hat{x}_1^{(1)}(k+1) = \left[x_1^{(0)}(1) - \frac{1}{\hat{a}}\sum_{i=2}^{N}\hat{b}_{(i-1)}x_i^{(1)}(k+1)\right]\mathrm{e}^{-\hat{a}k} + \frac{1}{\hat{a}}\sum_{i=2}^{N}\hat{b}_{(i-1)}x_i^{(1)}(k+1) \quad (12)$$

对式(12)做累减还原式,得到原始数列的分类模型如式(13)所示。

$$\hat{x}_1^{(0)}(k+1) = \hat{x}_1^{(1)}(k+1) - \hat{x}_1^{(1)}(k) \quad (13)$$

1.2 DRNN 分类模型

DRNN 分类模型将脊波变换函数作为该模型中各隐含层神经元的激励函数,增强了网络模型对非线性肌电信号数据的优化处理能力,多隐含层结构使 DRNN 能够更好地描述肌电信号,因此本文使用 DRNN 作为步态分类器。图 1 给出了 DRNN 分类模型结构图,DRNN 分类模型由输入层、4 层隐含层和输出层共 6 层结构组成,其中 m 维列向量 $[x_1, x_2, \cdots, x_m]$ 表示 DRNN 模型的输入向量,$[w_1, w_2, w_3, w_4]$ 为 DRNN 模型中各层神经元之间的连接权重矩阵。DRNN 的隐含层中各层神经元节点个数为 C_1、C_2、C_3、C_4,且其神经元的激励函数采用脊波变换函数 $\varphi_\gamma(\cdot)$,DRNN 的输出层节点个数为 1。

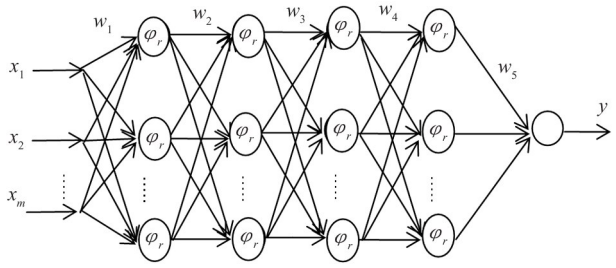

图 1 深度瘠波神经网络分类模型结构图

1.3 花授粉算法优化极限学习机参数

极限学习机(extreme learning machine,ELM)由文献[12]提出,目前在假肢步态识别等领域得到了广泛应用。ELM 方法中隐藏节点个数是较为重要的参数,隐藏节点个数的选择对 ELM 的性能起着决定性的影响。在实际应用中,隐藏节点个数都是依靠经验选择,具有较大的随机性,不利于识别准确率的提高。花授粉算法(flower pollination algorithm,FPA)具有良好的全部和局部搜索能力,稳定性优于遗传算法、粒子群等算法[13],因此本文引入 FPA 对 ELM 分类器进行优化,确定最优隐藏层节点个数。具体步骤如下。

(1)设定最大迭代次数 Max、种群个体数 N、转换概率 p 等参数。

(2)寻优参数为 ELM 隐藏层节点个数,维数为 1,计算初始种群的适应度,选定适应度最优个体为当前种群最优解 t^*。适应度公式为

$$fitness = \frac{\text{识别正确的样本数目}}{\text{测试的所有样本数目}} \quad (14)$$

(3)随机产生一个在区间[0,1]上的数字 $rand$。若 $rand < p$,则进行全局授粉;否则进行局部授粉。全局授粉为

$$X_i^{t+1} = X_i^t + \gamma W(X_j^t - t^*) \quad (15)$$

式中,X_i^{t+1} 表示第 t 次迭代时花粉 i 的位置,γ 表示步长缩放因子,W 表示符合 Levy 分布的因子。局部授粉过程为

$$X_i^{t+1} = X_i^t + \varepsilon(X_j^t - X_i^t) \quad (16)$$

式中,变异因子 ε 符合均匀分布且在区间[0,1]上的随机数,X_j^t 表示第 t 次迭代不同花朵 j 的花粉位置。

(4)利用式(14)确定新解是否为最优解,如果新解优于当前解,则新解进入下一代种群,否则当前解进入下一代种群,作为当前最优解 t^*。

(5)判断是否满足终止条件,输出全局种群最优解 g^*,否则转入步骤(3)。

2 基于分步机器学习的下肢假肢步态识别模型

基于灰度模型和分步机器学习的假肢步态识别具体步骤如下:(1)表面肌电信号的采集以及提取 4 块肌肉的灰度模型系数作为特征值参数,并用 Relief 算法对特征值进行降维处理;(2)对降维后的特征值归一化到[0,1]作为 DRNN 分类器的输入特征值;(3)数据集合中选择 80% 数据训练 DRNN,训练过程中需要设置 4 个隐藏层节点数目 C_1、C_2、C_3、C_4,数据集合中 20% 数据作为测试数据检验 DRNN 分类器的性能;(4)将 DRNN 能够识别的步态类型

直接得出识别结果,不能识别的步态类型标记为“易混淆步态”;(5)将易混淆步态由 FPA-ELM 做进一步识别;(6)得到步态分类最终结果。基于灰度模型和分步机器学习的假肢步态识别模型流程图如图 2所示。

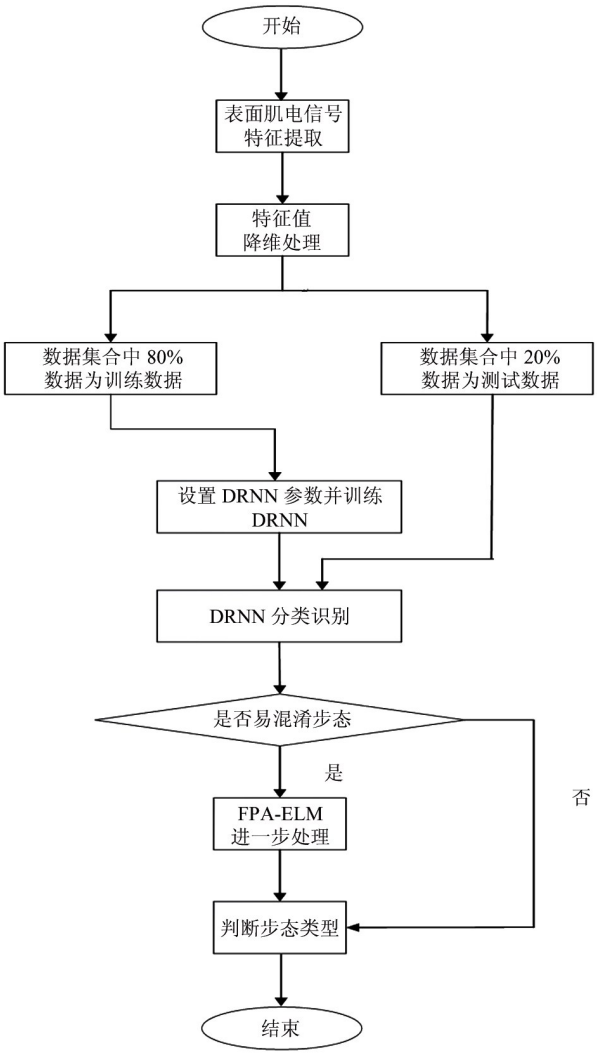

图 2　基于分步机器学习的步态识别流程图

3　实验分析

本文招募了 15 名智能假肢穿戴志愿者作为实验对象,基本资料如表 1 所示。实验前所有实验对象均签署了知情同意书,熟悉实验的目的与过程,本文主要针对上楼、下楼、上坡、下坡、平地行走、起立和坐下进行识别。表面肌电信号的采集使用的设备为 Delsys 公司的 Trigno 无线 sEMG 采集系统,采样频率为 1 024 Hz,图 3 为肌电信号传感器采集模块,采集实验对象残肢侧臀中肌、股外侧肌、股内侧肌和腓肠肌外侧肌四路肌电信号[14-17]。本文在普通的接受腔制作基础上放入了传感器模具,内嵌式传感器系统能够紧密贴合皮肤,同时不会对皮肤和传感器带来挤压,成型的内嵌式传感器系统如图 4 所示,实验对象在24 h内均没有过剧烈运动,确保实验数据的准确性。对肌电信号开始采集前,用少量浓度为 75% 的医用酒精清理待测肌肉附近皮肤表面。模拟不同步态的实验平台如图5所示,楼梯的高度

表 1　实验对象的基本资料

编号	性别	年龄	残肢长度比例/%	残疾人被测腿	穿戴时间/月	假肢型号
1	男	27	31.3	左	18	奥托 3E80
2	男	32	33.6	右	34	迈迪
3	男	25	27.5	右	4	德林 JB810
4	男	26	32.0	左	32	奥托 3E80
5	男	34	51.5	右	9	奥托 3R78
6	男	37	40.7	左	12	C-Leg
7	女	40	37.9	左	36	奥索七轴
8	女	38	41.4	左	24	德林 JB810
9	女	42	33.6	右	15	迈迪
10	女	44	30.5	右	8	C-Leg
11	男	50	31.4	左	32	德林 JB810
12	女	48	25.3	右	3	迈迪
13	男	52	30.0	左	30	德林 JB810
14	男	55	35.6	左	34	奥托 3E80
15	男	51	40.8	右	26	德林 JB810

图 3　传感器模块

图 4　成型的内嵌式传感器系统

图 5　模拟不同步态的实验台

是 0.15 m,坡的长度是 3.50 m,倾斜角为 15 °,每一个完整步态从双腿站立开始,结束于双腿站立。实验对象进行自然步态行走,尽量保持行走速度的一致性,每个实验对象每种步态共进行 10 组实验数据采集,每采集完 1 组实验休息 10 min,放松下肢肌肉,防止肌肉疲劳对肌电信号产生影响。图 6 给出了平地行走的表面肌电信号图,平地行走、上楼、下楼、上坡、下坡、起立、坐下共采集 15 × 7 × 10 个样本。每种步态设置 1 个标签,以方便对识别的结果进行观察分析,每种步态对应的标签如表 2 所示。每位实验对象的每种步态滑动窗口都截取 128 个数据点,增量窗选择 32 个数据点,每采集 64 点后进行一次灰度模型系数计算,通过滑动窗获得 3 组数据,共得到特征值(4 块肌肉 × 10 次实验数据采集 × 3)120 组。所有对象的每种步态中 120 × 15 组特征值作为训练集与测试集的数据集合,随机选取数据集合中 80% 的数据作为训练数据,20% 的数据作为测试数据。

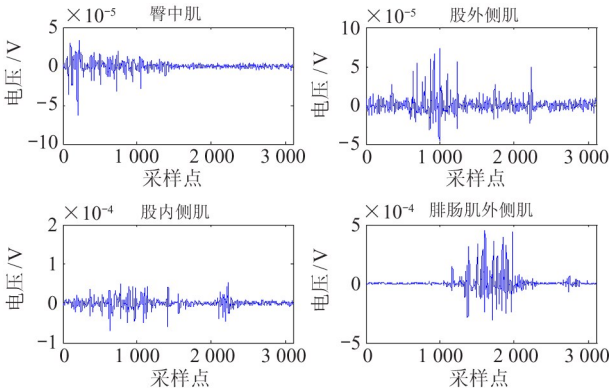

图 6　平地行走的表面肌电信号

表 2　步态识别标签

步态	平地行走	上楼	下楼	上坡	下坡	起立	坐下
标签	1	2	3	4	5	6	7

发展系数 α 对识别准确率有很大影响,图 7 给出了不同发展系数取值对应的识别准确率,其中横坐标为发展系数,纵坐标表示步态识别准确率。发展系数过小,肌电信号特征表述不全面,当发展系数为 3 时,识别准确率达到最低,随着发展系数的增加,识别准确率逐渐提高;当发展系数增至 6 时,识别准确率达到最高,当发展系数继续增大时,识别准确率基本保持不变,但波动较为明显。本文选用发

展系数为6对应的灰度模型系数作为肌电信号特征值,此特征值作为DRNN分类器的输入,特征值维数过高会影响分类器训练的效率,本文采用Relief算法对多维特征值进行降维处理,并使用DRNN分类器对筛选的特征进行分类验证,选择对识别准确率贡献最大的特征,实验结果如图8所示。由图8可知,前9个特征与前20个特征识别准确率最高且相等,如果选择前20个肌电特征作为DRNN分类器的输入,会增加DRNN分类器的运算量,因此本文选择前9个肌电特征作为DRNN分类器的输入。

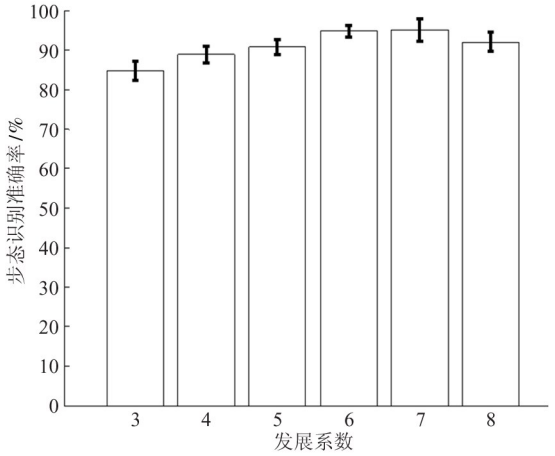

图7　不同发展系数时的识别准确率

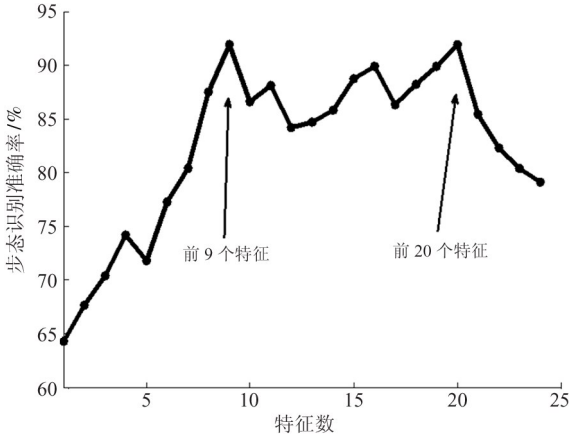

图8　前 K 个特征的识别准确率

DRNN的隐含层节点数 C_1、C_2、C_3、C_4 影响分类器性能的好坏。C_1、C_2、C_3、C_4 节点数太少,网络不能很好地学习,需要增加训练次数,训练精度也受影响;C_1、C_2、C_3 和 C_4 节点数太多,训练时间增加,DRNN容易过拟合。采用十折交叉验证的方式对数据集合进行划分,每次随机取1/10数据作为测试集,其余9/10的数据作为训练集,取10次实验的平均值作为最终结果,当 $C_1=9$、$C_2=12$、$C_3=9$、$C_4=8$ 时,识别准确率最高。本文DRNN模型的隐藏层神经元数目设置为 $C_1=9$、$C_2=12$、$C_3=9$、$C_4=8$。

特征提取滑动窗口和增量窗的大小是影响识别性能的主要因素,为了研究滑动窗和增量窗大小对识别性能的影响。本文采用滑动窗长度和增量窗都以2的倍数进行增长,最小为32个数据点,最大为512个数据点,利用DRNN对灰度模型系数特征特征值进行分类识别。表3给出了基于不同滑动窗与增量窗的步态识别准确率,不难看出,随着增量窗长度的增加,分类准确率逐渐下降,分类准确率的最小值发生在滑动窗为128个数据点、增量窗为128个数据点时,仅有78.09%的准确率,此时参与分类的滑动窗口个数较少,且由滑动窗口构成的特征值不够明显,导致识别准确率较低;在滑动窗口长度较大,且增量窗长度较小时,动作分类准确率较高,滑动窗与增量窗分别设置为128个采样点和32个采样点时,7种步态的识别准确率高达96.63%。根据实验所得结果,本文选择滑动窗为128、增量窗为32作为最优滑动窗进行特征提取。

从每种步态数据120组样本中分别选取96组作为训练集,剩余24组作为测试集,DRNN模型参

表3　不同滑动窗与增量窗的步态识别准确率

识别准确率/%　增量窗 / 滑动窗	32	64	128	256	512
32	95.36	96.18	96.63	95.54	91.83
64		94.25	94.81	90.37	91.83
128			78.09	87.84	91.83
256				82.62	91.83
512					91.83

数设置如下：$C1=9$、$C2=12$、$C3=9$、$C4=8$。基于灰度模型和 DRNN 的假肢步态识别结果如图 9 所示，平地行走用 1 表示、上楼用 2 表示、下楼用 3 表示、上坡用 4 表示、下坡用 5 表示、起立用 6 表示、坐下用 7 表示，空心圆表示理想步态，十字符号表示 DRNN 识别步态；假如两者重合则表示识别准确，若不重合则表示识别错误。DRNN 分类模型在 168 组测试数据中共识别出 150 组，总体识别率为 87.00%，起立、坐下、上楼、下楼测试样本分类准确率为 100.00%；上坡的 20 个测试样本中 6 个样本被误判为平地行走；下坡的 20 个测试样本中 5 个被误判为上坡，2 个被误判为下楼。平地行走的 20 个测试样本中 5 个被误判为下坡，可以看出，DRNN 对步态 2、3、6、7 具有较准确的识别能力，但是不能准确识别步态 1、4、5，需要进一步识别。

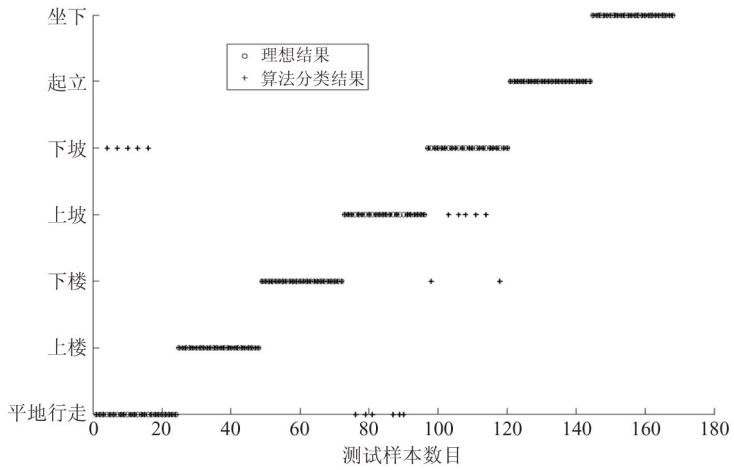

图 9　DRNN 分类器分类结果

将 1、4、5 标记为易混淆步态，代入 FPA-ELM 做进一步识别，实验参数设置如下：$N=20$、最大迭代次数 100、步长缩放因子 3.50、转换概率 0.45，随机选取 80.00% 数据作为训练数据，剩下的 20.00% 作为测试数据。图 10 给出了 FPA 进化曲线，横坐标为迭代次数，纵坐标为适应度，适应度函数为步态识别准确率，FPA 迭代 15 次即可找到 ELM 参数的最优解。图 11 为 FPA 优化 ELM 对平地行走、上坡、下坡 3 种易混淆步态的分类结果，FPA-ELM 对平地行走和下坡能够进行准确识别，对上坡有 2 例误识别，此时易混淆步态的分类结果的准确率为 98.25%。

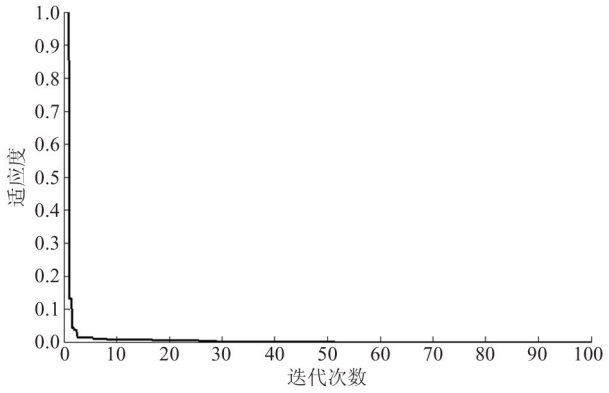

图 10　FPA 的适应度曲线

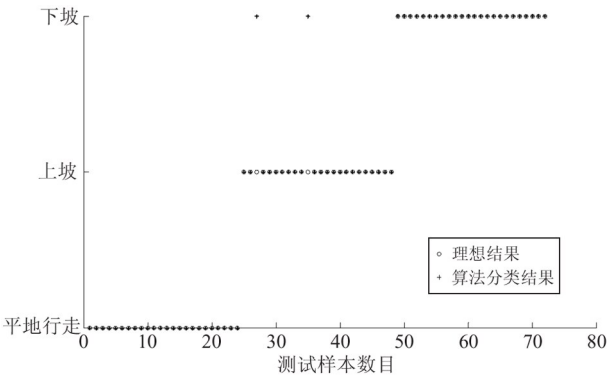

图 11　FPA 优化 ELM 分类结果

考虑到不同年龄段的假肢穿戴者在步态重复性上可能存在差异，本文对不同人群的识别结果进行讨论。本文将 15 名实验对象按年龄的大小分成 3 段：第 1 段为 18～35 岁、第 2 段为 36～50 岁、第 3 段为 51～65 岁，使用灰度模型系数和分布机器学习

算法对各年龄段实验对象的7种步态进行识别,识别准确率如表4所示。

从表4中可以发现,对于同一年龄段,识别上楼、下楼的准确率要略高于上坡和下坡,而识别起立和坐下的准确率相近,对于同一步态识别3种年龄段实验对象执行动作的结果各不相同。识别36~50岁年龄段的实验对象的实验结果与18~35岁年龄段的结果相近,而识别51~65岁年龄段实验对象的结果与18~35岁年龄段的结果相差较大,平均识别准确率相差2.6%。年龄段为51~65岁的实验对象步态的识别准确率相对较低,年龄稍长的实验对象会对算法的识别结果产生一定的影响。步态识别准确率较低主要是因为年龄稍长的实验对象,其肢体运动较为缓慢,下肢运动的肌电信号幅度较小,而使得识别准确率偏低。

表4　不同年龄段人群的识别准确率/%

	平地行走	上楼	下楼	上坡	下坡	起立	坐下
18~35岁	98.72	100.00	100.00	95.36	95.87	99.26	98.35
36~50岁	98.32	100.00	100.00	95.92	96.48	98.75	97.64
51~65岁	95.85	97.88	96.54	93.88	94.92	97.45	97.96

sEMG时域特征具有特征提取相对简单、计算速度快等优点,在假肢步态识别领域时域得到广泛应用。时域特征主要包括均方根(root mean square, RMS)、方差(variance, VAR)等,均方根在一定程度上反映了一段表面肌电信号的有效值,具体定义如下:

$$RMS = \sqrt{\frac{\sum_{i=1}^{N} x_i^2}{N}} \tag{17}$$

式中,N表示表面肌电信号的采集点数,x_i表示选取的表面肌电信号中第i个采样点位置处的电压幅值。方差具有直接的物理意义,反映了表面肌电信号在人体下肢运动过程中的变化范围以及幅度变化的剧烈程度,具体定义如下:

$$VAR = \frac{1}{N-1}\sum_{i=1}^{N}(x_i - \bar{x})^2 \tag{18}$$

式中,N表示表面肌电信号的采集点数,x_i表示选取的表面肌电信号中第i个采样点位置处的电压幅值,$\bar{x}$表示表面肌电信号样本的平均值。

频域特征主要是对各个频率能量的分布情况进行分析,频域特征其优势在于特征平稳度较好,平均频率(mean frequency, MNF)和中值频率(median frequency, MDF)常用于描述sEMG的频域特性,平均频率和中值频率2种频域具体定义如下:

$$MNF = \frac{\int_0^{\infty} f\mathrm{PSD}(f)\,\mathrm{d}f}{\int_0^{\infty} \mathrm{PSD}(f)\,\mathrm{d}f} \tag{19}$$

$$MDF = \frac{1}{2}\int_0^{\infty} \mathrm{PSD}(f)\,\mathrm{d}f \tag{20}$$

式中,f表示sEMG的频率,$\mathrm{PSD}(f)$表示sEMG的功率谱密度函数。

为了验证灰度模型系数特征更适合肌电信号特征提取,将灰度模型系数特征与均方根、方差、中值频率和平均频率等特征对比分析,分类器采用本文提出的分布机器学习方法,表5给出了不同特征值的识别准确率,2种常用的时域特征识别准确率最高的是均方根特征为86.38%,远低于灰度模型特征的识别准确率。时域特征操作简单,当肌肉收缩力大小稍有变化时,时域特征变化较大且不稳定,中值频率和平均频率平均识别准确率为85.20%和90.10%。而频域特征经过傅里叶变换后,比时域特征相对稳定,识别准确率虽然高于时域特征,但当步态种类增多、动作较相似时,识别准确率较低。灰度模型系数可以很好地区分腿部肌电信号,上楼、下楼、上坡、下坡、平地行走、起立和坐下等7个步态的识别率分别为97.94%、100.00%、94.79%、97.28%、96.84%、100.00%和100.00%,平均识别率达到了98.25%,表明灰度模型系数区分性更好,相对于方差、均方根、平均频率、中值频率等特征更适用于假肢步态识别研究中肌电信号的特征提取。

为了进一步验证本文提出的分布机器学习模型

表 5 不同特征值的步态识别准确率/%

	方差	均方根	平均频率	中值频率	灰度模型系数
平地行走	77.6	83.7	79.9	92.5	97.9
上楼	82.4	88.1	84.2	89.7	100.0
下楼	76.5	90.2	85.4	92.4	95.7
上坡	84.9	85.4	87.6	87.1	97.2
下坡	73.7	79.6	89.3	87.6	96.8
起立	77.9	89.5	81.8	93.8	100.0
坐下	80.4	88.2	88.1	88.2	100.0

的可靠性,将相同的训练数据分别输入隐马尔科夫模型(hidden Markov model, HMM)[9]、支持向量机[8]、ELM[12]这 3 种常用分类算法中对相同的实验数据进行训练和测试并计算平均识别准确率作为结果。HMM、SVM 训练方法采用文献[9]的方法,ELM 训练方法采用文献[12]的方法,其中 SVM 核函数使用径向基函数内核,在选择核函数系数 $g>0$ 与惩罚因子 Q 时,对 Q 与 g 的取值范围进行预设,然后计算各个参数下的识别准确率,最后确定 $Q=18$、$g=0.007\,5$。ELM 方法中多次实验后隐藏节点个数设置为 500,既能较快地训练模型,又可确保模型的准确度;HMM 方法中表面肌电信号 6 阶灰度模型系数特征值组成观测值向量,HMM 的隐状态数量设定为 2,得到的观测序列用于 HMM 的训练,4 种分类器识别结果如表 6 所示。利用分布机器学习分类器得到的平地行走、上坡、上楼和下楼的识别率均高于95.00%,上楼和下楼的识别率甚至高达 100.00%,说明了本方法对假肢步态识别具有良好的识别效果,虽然下坡的识别率偏低只有 94.70%,但总体上来看,本文方法可以满足智能假肢穿戴者步态识别要求。本文方法分别比 ELM、HMM、SVM 这 3 个单一分类器高出 3.48%、6.42% 和 8.29%,这是由于对于多分类问题,单一的机器学习方法存在局限性,而分布机器学习模型综合多个基分类器的输出特征,具有更好的泛化能力,从而达到提高识别准确率的效果。

表 6 本文方法与 ELM、HMM 与 SVM 方法识别准确率实验结果对比/%

	平地行走	上楼	下楼	上坡	下坡	起立	坐下
SVM	85.6	87.4	88.1	84.3	88.9	90.7	91.2
HMM	88.1	90.7	92.5	85.8	88.2	94.3	95.6
ELM	90.3	92.4	94.1	87.6	90.5	96.8	97.3
本文方法	97.9	100.0	100.0	97.2	94.7	100.0	100.0

图 12 给出了本文方法、ELM、HMM 与 SVM 的训练时间和测试时间。本文方法与 ELM、HMM 与 SVM 方法训练时间分别为 75.30 ± 1.70 ms、84.70 ± 4.20 ms、122.35 ± 2.99 ms、172.75 ± 3.65 ms,测试时间分别为 40.05 ± 3.78 ms、51.36 ± 2.65 ms、60.94 ± 2.49 ms、70.48 ± 2.62 ms。采用分布机器学习分类器所需时间高于传统分类器,这主要是由于分布学习增加了分类时间。在智能假肢实际应用中,时间成本是一个极其重要的考虑因素,为了实现对假肢步态的实时性识别,需保证在300.00ms内

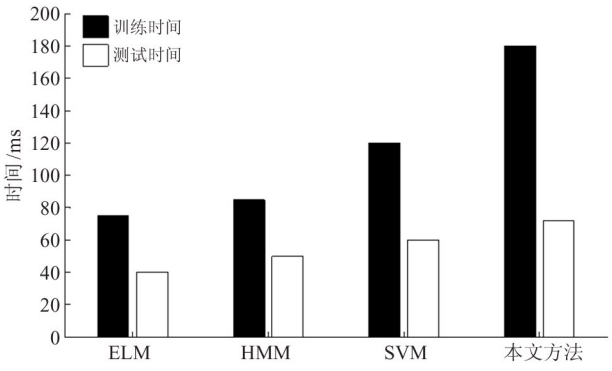

图 12 本文方法与其他分类器的训练时间与测试时间

实现对步态的识别,相比于ELM、HMM与SVM等方法,分布机器学习方法的识别时间虽然较长,但是仍然满足要求。为了验证分布机器学习方法的鲁棒性,本文选择ELM、HMM和SVM作为对比算法,对本文分类算法、ELM、HMM和SVM算法的鲁棒性进行了比较,图13给出了实验结果,横坐标表示实验次数,纵坐标表示平均识别准确率。4种步态分类算法中,分布机器学习方法的鲁棒性最好,10次实验中,分布机器学习方法的识别准确率均高于ELM、HMM和SVM方法的识别准确率,本文提出的分布机器学习方法更适合于假肢步态识别。

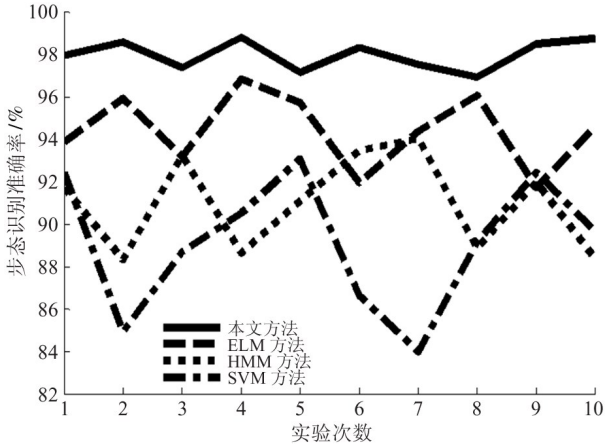

图13　本文方法与ELM、HMM与SVM方法鲁棒性实验结果对比

表7给出了本文方法与文献[17-20]方法的对比。文献[17]将表征时间序列特性的高阶过零分析方法应用于不同步态下的肌电信号的特征提取,最终对15名假肢穿戴者获得到了约96.28%的识别准确率,低于本文提出基于分部机器学习所达到的98.25%。尽管文献[18]和文献[19]使用卷积神经网络和高斯量子粒子群算法优化模糊加权核极限学习机实现了非常高的识别准确率,但步态的数量分别只有5个和3个。文献[20]研究了4种步态获得了94.00%的准确率,尽管步态的数量是本文研究的一半左右,但准确率仍低于本文4.20%。本文采用单一肌电传感器识别7种步态,识别准确率优于文献[17-20]的方法,表明了灰度模型系数作为步态特征、利用分布机器学习分类识别方法的有效性。

表7　本文方法与参考文献方法的对比

方法	信号源	步态数目	特征提取方法	分类器	识别准确率/%
文献[17]	肌电信号	5	高阶过零特征值	蝙蝠算法优化相关向量机	93.28
文献[18]	肌电信号	5	时域频域	卷积神经网络	93.27
文献[19]	肌电信号	3	时域频域	高斯量子粒子群算法优化模糊加权核极限学习机	94.60
文献[20]	加速度与角度传感器信号	4	平均值与偏度	灰狼算法优化的支持向量机	94.00
本文	肌电信号	7	灰度模型系数	DRNN + FPA优化ELM	98.20

4　结　论

(1)根据灰度模型的可生成强相关数列、样本不需要规律性分布等特性,提出灰度模型系数特征对步态数据分类识别,平均识别准确率达98.25%,高于幅值绝对值均值、标准差、均方根、过零点数、平均频率等时域、频域特征。

(2)提出基于深度瘠波神经网络和花授粉优化极限学习机的分步机器学习模型,克服了单一机器学习步态识别准确率低的缺点,该研究可以为假肢步态识别模型选择提供参考。

(3)虽然本研究取得不错的步态识别准确率,但是考虑到本文采用的是离线数据集,后续工作将研究在线采集肌电信号,实时对假肢穿戴者的步态进行识别。

参考文献

[1] 曹梦琳,陈宇豪,王珏,等. 基于表面肌电图的人体运动意图识别研究进展[J]. 中国康复理论与实践,2021,27(5):595-603.

[2] HARRISON L B, SHANE T K, et al. A semi-powered ankle prosthesis and unified controller for level and sloped walking[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2021,29:320-329.

[3] STEVE C C, LEO G V, MICHAEL G. A power-capable knee prosthesis with ballistic swing-phase[J]. IEEE Transactions on Medical Robotics and Bionics, 2022, 4(4):1034-1045.
[4] 汪晓铭, 黎林荣, 陈长龙, 等. 人-机-环境共融的智能假肢膝关节研究进展[J]. 中国生物医学工程学报, 2023, 42(4):486-501.
[5] 张鹏, 张峻霞, 刘瑞恒, 等. 基于 GA-RBF 神经网络和 sEMG 的下肢动作识别方法研究[J]. 中国生物医学工程学报, 2022, 41(1):41-47.
[6] ANDREA P, CHIARA L, EMILIO T, et al. Real-time locomotion recognition algorithm for an active pelvis orthosis to assist lower-limb amputees[J]. IEEE Robotics and Automation Letters, 2022, 39(1):7487-7494.
[7] 唐易, 陈奕希, 喻洪流, 等. 一种面向下肢假肢的运动意图识别方法及验证[J]. 信息与控制, 2023, 52(5): 598-606.
[8] 曾德政, 吕继亮, 屈盛官, 等. 基于 SVMBP 的下肢外骨骼步态检测及识别研究[J]. 机械工程学报, 2022, 58(12):29-37.
[9] 胡冬, 刘作军, 陈玲玲, 等. 基于支持向量机-隐马尔科夫模型的外骨骼穿戴者步速意图识别[J]. 生物医学工程学杂志, 2022, 39(1):1-8.
[10] KIM K T, PARK K H, LEE S W. An adaptive convolutional neural network framework for multi-user myoelectric interfaces[C]// Proceedings of the 4th IAPR Asian Conference on Pattern Recognition. Washington, USA: IEEE, 2017:788-792.
[11] 苏本跃, 倪钰, 盛敏, 等. 基于改进卷积神经网络的动力下肢假肢运动意图识别[J]. 控制与决策, 2021, 36(12):3031-3038.
[12] 黎毅达, 高发荣, 姚婷, 等. 极限学习机基于 Fisher 判别和 GKF-RELM 算法的多特征步态模式识别[J]. 电子学报, 2021, 49(10):1993-2001.
[13] 肖辉辉, 万常选. 基于多策略的改进花授粉算法[J]. 软件学报, 2021, 32(10):3151-3175.
[14] JOEL M, ROSEMARIE M, LUKAS G, et al. A mode ultrasound-based prediction of transfemoral amputee prosthesis walking kinematics via an artificial neural network[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023, 31:1511-1520.
[15] BAHAREH A, KIRSTIN A, ALEXANDER T. Electromyography-based control of lower limb prostheses: a systematic review[J]. IEEE Transactions on Medical Robotics and Bionics, 2023, 5(3):547-562.
[16] 刘磊, 杨鹏, 刘作军, 等. 基于多核学习极限学习机的助行机器人运动相容性识别[J]. 高技术通讯, 2021, 31(9):978-985.
[17] 刘磊, 杨鹏, 刘作军, 等. 采用蝙蝠算法进化相关向量机的假肢步态识别[J]. 振动、测试与诊断, 2022, 42(4):771-776.
[18] 张霞, 赵东, 陶思翰. 一种基于卷积神经网络的下肢动作模式识别方法[J]. 河北科技大学学报, 2022, 43(4):347-354.
[19] 赵翔, 涂娟, 黄紫娟. 基于优化模糊加权核极限学习机的下肢运动识别方法[J]. 传感技术学报, 2022, 35(5):621-626.
[20] 高新智, 刘作军, 张燕, 等. 基于 GWO-SVM 的下肢假肢穿戴者骑行相位识别[J]. 浙江大学学报(工学版), 2021, 55(4):648-657.

A locomotion-mode recognition method for intelligent prosthesis based on step by step machine learning

LIU Lei*, YANG Peng**, LIU Zuojun**
(*School of Building Environment Engineering, Zhengzhou University of Light Industry, Zhengzhou 450002)
(**School of Artificial Intelligence and Data Science, Hebei University of Technology, Tianjin 300130)

Abstract

In order to remedy the shortcomings of feature value selection and single classification model in gait recognition of intelligent prosthesis, and improve the accuracy of gait recognition of intelligent prosthesis wearers, surface lectromyography(sEMG) signal is selected as the gait recognition signal source, a feature extraction method based on gray scale model is proposed, and a road condition recognition model based on step by step machine learning is established. The gray-scale model coefficient is selected as the input characteristic value. The deep fine wave neural network is used to identify the road condition and distinguish the easily confused gait. An extreme learning machine optimized based on pollination algorithm is used to further distinguish the confusing road conditions, and the final recognition accuracy is 98.25% and the recognition time is 70.48 ms. Compared with a single machine learning model, the accuracy of this method is higher than that of a single machine learning model for seven gaits: level ground walking, upstairs, downstairs, uphill, downhill, standing up and sitting down.

Key words: intelligent prosthesis, locomotion-mode recognition, surface electromyography(sEMG), gray scale model, extreme learning machine(ELM)