

基于惯导信息的人体动作和路况识别



王永雄^{1,2}, 陈晗¹, 尹钟¹, 喻洪流^{2,3}, 孟巧玲^{2,3}

1. 上海理工大学 光电信息与计算机工程学院 (上海 200093)
2. 上海康复器械工程技术研究中心 (上海 200093)
3. 上海理工大学 医疗器械与食品学院 (上海 200093)

【摘要】 人体动作和路况的快速准确识别是实现智能假肢自主控制的基础与前提。本文提出了一种基于假肢(下肢)惯导信号的高斯混合模型(GMM)和隐马尔可夫模型(HMM)融合的人体动作和路况识别方法。首先,使用惯性传感器采集膝关节处 x 、 y 和 z 轴方向上的加速度、角度和角速度信号,然后用时间窗截取信号段并用小波包变换消除信号的抖动噪声;接着对预处理后的信号进行快速傅里叶变换,提取其系数作为特征值;随后对特征进行主成分分析(PCA),去除冗余信息;最后采用高斯混合模型和隐马尔可夫模型进行假肢动作和路况识别。试验结果表明,本文方法对常规的动作(散步、跑步、骑行、上坡、下坡、上楼梯和下楼梯)的识别率分别达到96.25%、92.5%、96.25%、91.25%、93.75%、88.75%和90%。同等试验条件下,将本文方法与常规的支持向量机(SVM)识别方法进行比较,结果显示本文方法的识别率明显较高。本文研究结果或可为智能假肢的监测和控制提供新的思路和途径。

【关键词】 人体动作和路况识别; 高斯混合模型; 隐马尔可夫模型; 智能假肢; 惯导信息

Human action and road condition recognition based on the inertial information

WANG Yongxiong^{1,2}, CHEN Han¹, YIN Zhong¹, YU Hongliu^{2,3}, MENG Qiaolin^{2,3}

1. School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093. P.R.China
 2. Shanghai Engineering Research Center of Assistive Devices, Shanghai 200093. P.R.China
 3. School of Medical Instrument and Food Engineering, University of Shanghai for Science and Technology, Shanghai 200093. P.R.China
- Corresponding author: WANG Yongxiong, Email: wyxiong@usst.edu.cn

【Abstract】 Rapid and accurate recognition of human action and road condition is a foundation and precondition of implementing self-control of intelligent prosthesis. In this paper, a Gaussian mixture model and hidden Markov model are used to recognize the road condition and human motion modes based on the inertial sensor in artificial limb (lower limb). Firstly, the inertial sensor is used to collect the acceleration, angle and angular velocity signals in the direction of x , y and z axes of lower limbs. Then we intercept the signal segment with the time window and eliminate the noise by wavelet packet transform, and the fast Fourier transform is used to extract the features of motion. Then the principal component analysis (PCA) is carried out to remove redundant information of the features. Finally, Gaussian mixture model and hidden Markov model are used to identify the human motion modes and road condition. The experimental results show that the recognition rate of routine movement (walking, running, riding, uphill, downhill, up stairs and down stairs) is 96.25%, 92.5%, 96.25%, 91.25%, 93.75%, 88.75% and 90% respectively. Compared with the support vector machine (SVM) method, the results show that the recognition rate of our proposed method is obviously higher, and it can provide a new way for the monitoring and control of the intelligent prosthesis in the future.

【Key words】 human action and road condition recognition; Gaussian mixture model; hidden Markov model; intelligent prosthetic; inertial information

引言

应用于人体下肢的智能假肢的研发是最近几

年假肢制备技术的主要研究方向之一,其主要思路为利用多种传感器实时监测人体行走状态、推测环境信息,并根据不同的行走步态和环境特征,实现智能假肢膝关节自适应控制,让被动式智能假肢获得较佳的屈伸阻尼,使假肢使用者更加方便和舒适^[1-2]。在多变的路况和不同动作模式(例如:上下

DOI: 10.7507/1001-5515.201712081

基金项目: 国家自然科学基金(61673276, 61703277, 61473193)

通信作者: 王永雄, Email: wyxiong@usst.edu.cn

坡道、行走和跑步)下,假肢所需的控制量或者参数有较大变化^[3],体现在腿部各关节力矩不仅在数值上有很大变化,而且频率上也有较大差别,所以智能假肢自主学习人体运动模式和感知环境信息是实现自适应控制的先决条件^[4-5]。

人体行为识别的信息源主要有力学信息、惯导信息、生物电信息和视频图像信息。基于力学信息的识别是根据不同行为的地面反作用力信息,提取其时域特征,然后采用隐马尔可夫模型(hidden Markov model, HMM)等方法进行人体行为识别^[6]。基于生物电信息的识别则是把下肢表面肌电信号作为识别信息源,提取其时域特征和频域特征,再采用神经网络等模型进行识别^[7];或者提取小波包能量特征,然后采用核主元分析降维步态特征值后利用相关向量机方法进行分类识别^[8],这些方法均取得了不错的效果和进展。但已有的研究指出,肌电信号产生复杂,容易受人体自身状态等因素影响,稳定性较差,因此距实际应用还有较大距离^[9]。此外,还有基于视频图像信息的识别方法^[10-11],虽然这些方法分析人体行为图像取得了不错的效果,但是图像信息采集难以始终对假肢跟踪,并且容易发生遮挡、超出视野等问题,并不适合在真实假肢中使用。

针对以上不足,本文侧重研究基于惯导信息的人体行为识别方法,这是由于惯性传感器小巧、灵敏、传输速度快,满足易安装性和实时性等要求^[12-13]。然而,惯导信号的特征可以是时域特征的均值、方差、标准差、相关系数、时域积分等,也可以是频域特征的快速傅里叶变换(fast Fourier transform, FFT)系数、频域熵、能谱密度,还可以是时频特征的小波系数^[14]。特征的选择能很大程度上影响人体动作识别的最终结果,为此 Preece 等^[15]比较了时域、频域和时频域等 14 种特征,发现频域特征比时频域特征更适合用来描述非平稳信号,对主体的动态活动进行分类时更加稳定和精确,因此本文提取信号的 FFT 系数作为描述路况和动作的特征值。

早期的方法是根据惯导信号的平均加速度、极值、相邻两波峰时间等参数之间的差异作为依据进行人体动作识别^[16],或者采用峰值检测和零交叉检测的识别方法^[17],这些方法计算量小,实用性强,但总体识别率不高。随着人工智能研究的不断深入,机器学习算法已经在生物信息识别、语音识别等领域得到广泛应用。Shi 等^[18]提出用 FFT 生成特征,然后再用支持向量机(support vector machine, SVM)进行识别,该方法在识别种类和识别率两方

面均有所提升。Dehzangi 等^[19]也提出将惯性信号的频谱作为特征,利用卷积神经网络识别人体下肢行为。虽然该方法新颖,识别率也很高,但计算量大,需要的训练数据极大,目前还难以在实际中使用。此外, Panahandeh 等^[20]利用惯导信号和双层 HMM 的方法进行人体行为分类和步态分析,取得了良好的效果,说明了 HMM 在路况识别和动作识别方面具有较佳优势。最后,考虑到高斯混合模型(Gaussian mixture model, GMM)和 HMM 融合在语音识别中效果良好^[21],而且下肢运动的惯导信号与音频信号有很多相似之处,因此,融合 GMM 和 HMM 算法是惯导信号的人体动作和路况识别的较佳选择。

基于以上原因,本文提出了一种高斯混合隐马尔可夫模型(Gaussian mixture hidden Markov model, GMHMM)的人体动作和路况识别方法。首先采用时间窗法截取信号,并将每个窗口内的信号进行标准化处理,然后对标准化的信号进行降噪并提取 FFT 系数作为特征值,最后采用主成分分析(principal component analysis, PCA)将 FFT 系数矩阵降维并输入到 GMHMM 模型中进行训练和分类。本文将 GMM 和 HMM 融合算法应用到智能假肢上,不仅比传统的识别方法运算量少,而且提高了识别范围和准确率。同时本方法利用小巧、易安装的惯性传感器,可使智能假肢摆脱繁重的设备限制而变得更加轻便,适合更多的应用场景,对智能假肢的实用化和智能化有着重要的意义。

1 算法原理

GMHMM 模型主要由 GMM 和 HMM 两个部分组成。GMM 能够将一个向量表示成若干个高斯概率密度函数方程之和。HMM 则是一个双重随机过程,其中隐状态到隐状态之间的转移是随机的,而且每个状态的观测值也是随机的。虽然 HMM 可以根据观测到的数据,利用观测概率矩阵确定隐含状态,但由于 HMM 中隐含状态不能直接观测,只能通过观测向量感知它的存在,所以对于连续特征数据需要用 GMM 解决隐状态和数据之间的观测概率问题。

1.1 GMM 原理介绍

GMM 具有很强的拟合能力,几乎可以拟合任何一种复杂的概率分布函数。GMM 的表达式,如式(1)所示:

$$P(\mathbf{x}_t|\theta) = \sum_{k=1}^K \alpha_k \phi_k(\mathbf{x}_t) \quad (1)$$

其中 \mathbf{x} 是人体动作和路况样本的 D 维特征向量, t 为其样本序号; α_k 是混合权值; $\theta = \{\alpha_k, \mu_k, \delta_k\}$, $k = 1, 2, \dots, K$, 是 GMM; $\phi_k(\mathbf{x}_t)$ 是高斯密度函数; 每一个成员密度函数是一个关于 D 维变量的均值矢量 μ_k 和协方差 δ_k 的高斯函数, 形式如式 (2) 所示:

$$\phi_k(\mathbf{x}_t) = \frac{1}{(2\pi)^{D/2} |\delta_k|^{1/2}} \times \exp\left\{-\frac{1}{2}(\mathbf{x}_t - \mu_k)' \delta_k^{-1} (\mathbf{x}_t - \mu_k)\right\} \quad (2)$$

对于 GMM 的参数估计, 可以采用最大期望 (expectation maximization, EM) 算法进行。其关键是根据当前模型 θ 去计算第 t 个观测向量来自第 k 个高斯分模型的概率 γ_{tk} , 称其为第 k 个分模型对观测数据 \mathbf{x}_t 的响应度, 然后用它去估计一个新的模型 $\bar{\theta}$, 使得 $P(\mathbf{x}_t|\bar{\theta}) \geq P(\mathbf{x}_t|\theta)$ 。

1.2 HMM 原理介绍

HMM 定义为 $\lambda = (\tau, \mathbf{B}, \mathbf{A})$, τ 为初始概率分布矩阵, 表示隐藏状态在初始时刻的概率。 \mathbf{B} 为观测概率矩阵, 在本文中观测概率由上一节的 GMM 决定, 其元素 $b_j(\mathbf{x})$ 表示在样本矩阵 \mathbf{X} 下矢量 \mathbf{x} 来自隐状态 s_j 的概率, 如式 (3) 所示:

$$b_j(\mathbf{x}) = \sum_{m=1}^M c_{jm} N(\mathbf{x}; \mu^{jm}, \delta^{jm}) \quad (3)$$

其中 N 表示高斯密度函数, c_{jm} 表示在隐状态 s_j 下第 m 个高斯分模型的权重。 \mathbf{A} 为隐藏状态概率分布矩阵, 它描述了 HMM 中各个状态之间的转移概率, 其元素 a_{ij} 代表当前隐状态为 s_i , 且下一状态为 s_j 的概率。隐状态的个数决定了矩阵的阶数, 且 \mathbf{A} 矩阵中每一行的概率和都为 1。根据训练样本重估状态转移率 \hat{a}_{ij} , 需先计算出前向概率和后向概率。前向概率 $\alpha_t(s_j)$ 和后向概率 $\beta_t(s_i)$ 如式 (4)、式 (5) 所示:

$$\alpha_t(s_j) = \left[\sum_{i=1}^N \alpha_{t-1}(s_i) a_{ij} \right] b_j(\mathbf{x}_t) \quad (4)$$

$$\beta_t(s_i) = \sum_{j=1}^N a_{ij} b_j(\mathbf{x}_{t+1}) \beta_{t+1}(s_j) \quad (5)$$

其中 $\alpha_{t-1}(s_j)$ 表示在 $t-1$ 时刻的前向概率, a_{ij} 表示重估前的状态转移率。 $\beta_{t+1}(s_i)$ 表示在 $t+1$ 时刻的后向概率。然后计算 HMM 下, 从 t 到 $t+1$ 时刻, 从隐状态 s_i 转移到 s_j 的概率, 如式 (6) 所示:

$$\xi_t(s_i, s_j) = P(S(t) = s_i, S(t+1) = s_j | \mathbf{X}, \lambda) = \frac{\alpha_t(s_i) a_{ij} b_j(\mathbf{x}_{t+1}) \beta_{t+1}(s_j)}{P(\mathbf{X} | \lambda)} \quad (6)$$

$$\hat{a}_{ij} = \frac{\sum_{t=1}^T \xi_t(s_i, s_j)}{\sum_{k=1}^N \sum_{t=1}^T \xi_t(s_i, s_k)} \quad (7)$$

为了重估 GMM 的第 m 个高斯分模型的均值 $\hat{\mu}^{jm}$ 、协方差 $\hat{\delta}^{jm}$ 和权值 \hat{c}_{jm} , 需将 HMM 下, 在 t 时刻隐状态为 s_j 和第 m 个分模型的概率作为响应度, 如式 (8) 所示:

$$\gamma_t(s_j, m) = P(S(t) = s_j, l = m | \mathbf{X}, \lambda) \quad (8)$$

则重估后的参数计算方式如式 (9)、式 (10)、式 (11) 所示:

$$\hat{\mu}^{jm} = \frac{\sum_{t=1}^T \gamma_t(s_j, m) \cdot \mathbf{x}_t}{\sum_{t=1}^T \gamma_t(s_j, m)} \quad (9)$$

$$\hat{\delta}^{jm} = \frac{\sum_{t=1}^T \gamma_t(s_j, m) (\mathbf{x}_t - \hat{\mu}^{jm})(\mathbf{x}_t - \hat{\mu}^{jm})^T}{\sum_{t=1}^T \gamma_t(s_j, m)} \quad (10)$$

$$\hat{c}_{jm} = \frac{\sum_{t=1}^T \gamma_t(s_j, m)}{\sum_{l=1}^M \sum_{t=1}^T \gamma_t(s_j, m)} \quad (11)$$

2 基于 GMHMM 方法的人体动作和路况识别

基于 GMHMM 方法的人体动作和路况识别主要包含 3 个步骤: ① 信号的预处理和特征提取; ② GMHMM 训练; ③ 行为和路况识别。在信号预处理过程中, 本文使用动态时间窗口法、数据标准化法和小波包去噪法来使运动信号更加的平滑, 以方便提取 FFT 系数。然后采用 PCA 降维 FFT 系数矩阵作为特征。在 GMHMM 训练阶段, 本文设计了散步、跑步、骑行、上坡、下坡、上楼梯和下楼梯这 7 个动作模式, 并根据这 7 个动作模式的样本特征分别训练出相应的 7 个 GMHMM 模型。在行为和路况识别阶段, 只须将待识别信号输入到这 7 个训练好的模型中进行识别, 依据待测信号与每个模型的匹配率, 即可确定待识别信号所属的人体行为或路况。

2.1 数据预处理和特征提取方法

针对连续变化的人体运动信号, 通常使用动态

时间窗法提取阶段性信息。常规的时间窗法主要有邻近窗口法和重叠窗口法。其中，邻近窗口法处理完一段数据之后，必须等待下一个时间窗的数据全部到达才能接着处理，因此处理器有个空闲的等待时间；而重叠窗口法可以利用上个窗口的部分数据，产生更密集、半冗余的信息，更能够充分使用信息和更高效使用 CPU^[22]。本文试验中采用重叠率为 50% 的重叠窗口提取窗内的 FFT 系数作为特征，每个窗口约有 750 个样本点，窗口时间跨度通常在 0.5 ~ 2 s 内，以散步动作模式下的膝关节 y 轴方向加速度信号提取为例，如图 1 所示。

其次，由于加速度、角度和角速度数据存在量纲差别，所以需先对每个窗口内信号进行归一化处理。这里采用标准差标准化方法，如式 (12) 所示：

$$X^* = \frac{X - \mu}{\sigma} \tag{12}$$

其中 X 表示原数据， μ 表示信号均值， σ 表示信号方差。

采集到的原始信号存在许多噪音，在试验中这些噪音会对特征提取带来很强的干扰，因此本文采用分解层数为 4 层，基波为席勒 (Symlets) 函波的小波包去噪来减少噪声影响。选择小波包去噪的原因在于小波包变换是建立在小波变换的基础上，但比小波分析更加精细，通过对信号多层次分解和重构，提取信号的时频特性，可更有效地实现去噪^[23]。

接下来是信号的特征提取，人体下肢运动呈周期性，而且不同动作模式的加速度之间有显著差

异，以 z 轴方向的加速度为例，随机选取本文某位受试者的 7 种不同动作信号，如图 2 所示。

针对这种周期性信号，频域特征能够很好地体现信号的本质。此外 Preece 等^[15]也表明，频域特征对下肢行为分类具有更高的准确率。基于此，本文提取窗内的 FFT 系数作为特征。每个窗口提取出 14×9 的系数矩阵，其中每一列分别是某状态下的 x 轴加速度、 y 轴加速度、 z 轴加速度、 x 轴角度、 y 轴角度、 z 轴角度、 x 轴角速度、 y 轴角速度和 z 轴角速度的 FFT 系数，但提取的系数矩阵维数较大，包含大量冗余特征。为了提高处理速度，本文采用 PCA 方法对提取的 FFT 系数矩阵进行降维，把原始的 14×9 矩阵降维到 6×6 。这样既减少了计算量，同时保留原始数据中有鉴别力的特征。

2.2 GMHMM 训练过程

针对散步、跑步、骑行、上坡、下坡、上楼梯和下楼梯这 7 种动作模式，对应地训练出 7 个 GMHMM。每个 GMHMM 包含 4 个隐状态，每个隐状态对应一个 GMM，其中每个 GMM 包含 3 个高斯分模型。单个行为的 GMHMM 的训练过程如图 3 所示。

图中 α 为前向概率缩写； β 为后向概率缩写； γ 表示第 t 个列向量属于隐状态 s_j 的概率； ξ 表示当 t 到 $t+1$ 时，状态从 s_i 转移到 s_j 的概率。具体训练过程是先对高斯分模型进行参数初始化，其中隐状态概率分布矩阵 A 初始化为 6×6 的单位阵，高斯分模型的初始化为均值是 $[0, 0, 0, 0, 0, 0]$ ，协方差是 $[1, 1, 1, 1, 1, 1]$ ，权重是 $1/3$ 。然后根据式




图 1 重叠窗口法截取信号

Fig.1 Overlapping window method for intercepting signals




图 2 7 种不同动作的 z 轴加速度信号对比

Fig.2 Comparison of z-axis acceleration signals of 7 different movements

(4)、式(5)分别计算特征矩阵 $X_n = \{x_1, x_2, \dots, x_6\}$ 的前向概率 $\alpha_t(s_j)$ 和后向概率 $\beta_t(s_i)$ ；其次根据式(6)、式(8)，计算出 $\xi_t(s_i, s_j)$ ，接着计算特征矩阵下第 t 个列向量属于隐状态 s_j 的概率 $\gamma_t(s_j)$ ，如式(13)所示：

$$\gamma_t(s_j) = \frac{1}{P(\mathbf{X}|\lambda)} \alpha_t(s_j)\beta_t(s_j) \quad j=1, 2, 3, 4 \quad (13)$$

式中 $P(\mathbf{X}|\lambda)$ 表示特征矩阵在 HMM 下的概率。最后根据公式(9)、(11)和(13)，重新估算新

GMHMM 模型 $\hat{\lambda} = (\hat{\mu}^{jm}, \hat{c}_{jm}, \hat{a}_{ij}, \hat{\delta}^{jm}, \hat{\tau}_i)$ ，其中初始概率计算如式(14)所示：

$$\hat{\tau}_i = \frac{1}{M} \sum_1^M \gamma_1(s_i) \quad (14)$$

迭代过程多次循环，直到 $P(\mathbf{X}|\lambda)$ 值趋于稳定。得到的模型训练结果为状态转移概率矩阵 \mathbf{A} ，GMM 权值参数 c_{jm} ，GMM 均值向量 μ^{jm} ，GMM 协方差矩阵 δ^{jm} 和初始概率分布矩阵 τ_i 。

2.3 人体行为和路况的识别

根据训练好的模型去识别路况和人体动作的过程如图 4 所示。待识别信号经过上述同样的预处理和特征提取后,生成一个 6×6 的待识别特征矩阵 $\mathbf{O} = \{\mathbf{o}_1, \mathbf{o}_2, \dots, \mathbf{o}_6\}$ 。然后将待识别特征矩阵分别输入到已经训练好的散步、跑步、骑行、上坡、下坡、上楼梯和下楼梯这 7 个 GMHMM 模型中。

图中的 $P(\mathbf{O}|\lambda)$ 表示待识别矩阵属于模型 λ 的概率。首先取出一个 GMHMM 模型,根据模型的 μ^{jm} 、 c_{jm} 、 δ^{jm} 和观测概率计算公式,如式 (3) 所示,计算出该特征矩阵的观测概率 $b_j(\mathbf{o}_i)$,接着根据前向概率计算公式,如式 (4) 所示,计算待识别特征矩阵属于隐状态 s_i 的概率 $\alpha_6(s_i)$ 。最后计算特征矩阵在每个模型下的概率 $P(\mathbf{O}|\lambda)$,如式 (15) 所示:

$$P(\mathbf{O}|\lambda) = \sum_{i=1}^4 \alpha_6(s_i) \quad (15)$$

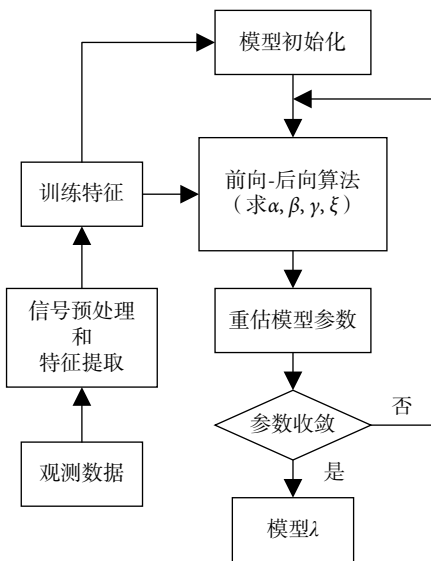


图 3 GMHMM 训练流程图
Fig.3 GMHMM training flowchart

这样待识别特征对于每个 GMHMM 模型中均有一个对应的 $P(\mathbf{O}|\lambda)$,最后选择 $P(\mathbf{O}|\lambda)$ 最大者为该数据所属的人体行为。

3 试验和结果分析

影响人体动作和路况识别率的因素有很多,例如去噪方式对降噪效果的影响、模型参数对识别结果的影响等。因此,为了验证各种因素对识别结果的影响程度,本文首先采用多种降噪策略进行对比,然后将不同组合的隐状态数和高斯分模型数进行了试验对比,最后为了验证算法的优越性,与经典的 SVM 算法做了对比试验,并给出试验分析。

3.1 试验硬件平台

惯导信息采集系统包含一个高性能惯导传感器 (MPU6050, 深圳维特智能)、三轴数字罗盘 (HMC5883, 深圳维特智能)、一个蓝牙接收器 (HC-06, 深圳维特智能) 和一台计算机 (Precision 5520, 美国戴尔)。其中,高性能惯导传感器 MPU6050 内部集成了三轴陀螺仪和三轴加速度计,陀螺仪用来检测转动角速度,加速度计用来测量线运动加速度。MPU6050 的采样率为 50 Hz,其中三轴陀螺仪量程为 ± 2000 ($^\circ$)/s,分辨率高达 16 位;三轴加速度计的测量范围为 ± 160 m/s²,有 16 位分辨率,可以满足本系统的需求。

3.2 数据采集和预处理

在数据采集阶段,为了保证数据的完整性和合理性,试验共招募 20 名年龄在 18 ~ 30 岁之间,身高范围在 152 ~ 185 cm,身体健康、下肢无任何疾病的受试者进行试验数据采集。考虑到假肢需要模拟正常腿的动作方式,试验中惯性传感器固定在正常腿的下肢膝盖处,其中 z 轴朝着人体正前方, x 轴与地面垂直向上, x 轴到 y 轴旋转方向符合右手定则(拇指方向为 z 轴正方向)。在相似的数据采

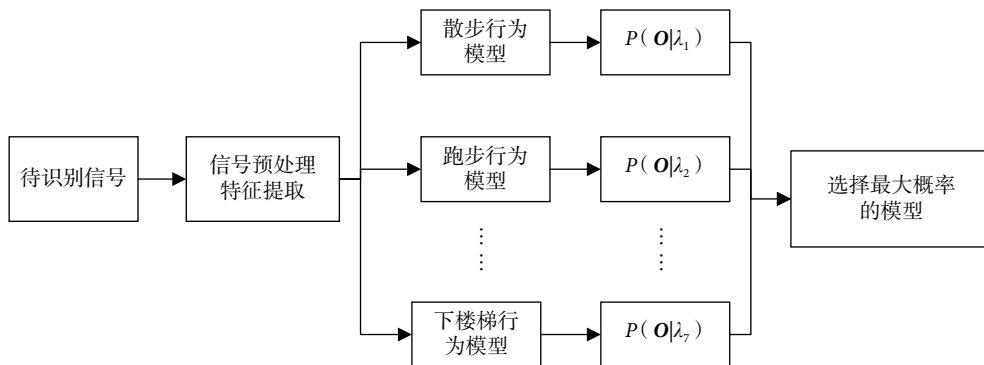


图 4 人体行为识别过程
Fig.4 The process of human action recognition

集场景中, 每个人在 30 ~ 40 min 内完成散步、跑步、骑行、上坡、下坡、上楼梯和下楼梯这 7 个动作模式。散步时的平均速度约 3 km/h, 上下楼梯、上下坡的平均速度约为 3 km/h, 跑步的平均速度为 6 km/h, 骑车平均速度约为 15 km/h。实际录制数据总时长超过 300 min, 共包含了约 185 万组数据。

在信号预处理过程中, 最重要的是信号去噪。常用的信号去噪方法主要包括: 有限长单位冲激响应低通滤波、移动均值滤波、加权移动均值滤波及小波去噪等, 但策略的不同, 降噪效果也不尽相同。为了验证各种降噪策略的去噪效果, 本试验中将小波降噪中的伯奇-马萨特 (Birge-Massart) 策略、惩罚 (penalty) 策略、小波包去噪与原始信号进行了对比, 具体试验结果如图 5 所示。

从图 5 中可以发现基于 penalty 策略的降噪方法去除高频噪音的效果较差, 而基于 Birge-Massart 策略的效果略好, 但依然包含较多的高频信号, 只有小波包降噪后曲线平滑, 有效地减少了高频噪音

信号, 并保留了数据的主要特征。

本文还将无效特征比重作为参考对象, 进一步验证各种策略的降噪效果。因为当 FFT 系数的某个值过大时, 会严重影响后续的模式训练, 所以这些特征可归类为无效特征。无效特征越少, 模型训练效果越好, 同时识别率也就越高。基于不同策略的降噪方法在特征提取之后, 包含无效特征的结果对比如图 6 所示, 纵坐标表示无效特征占有所有特征中的比重。通过本文试验发现, 采用 Birge-Massart 策略的去噪效果不明显, 而使用小波包降噪后的无效特征远低于其他几种降噪策略。以上试验结果证明, 小波包降噪对于特征提取来说更有效, 对比结果如图 6 所示。

3.3 隐状态和分模型个数对识别结果的影响

为了避免模型过拟合或欠拟合问题, 需要设置合适的 GMHMM 参数组合 (隐状态数目、高斯分模型数目等) 提高模型泛化能力。本文在试验中设置多个不同的参数组合进行对比, 隐含状态数分别取




图 5 不同降噪方法效果对比

Fig.5 Comparison of different denoising methods

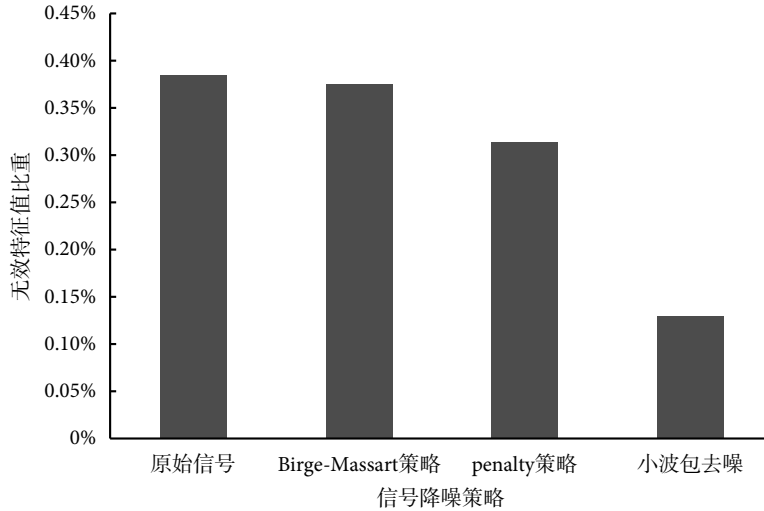


图6 不同去噪方法对应的无效特征比例

Fig.6 The ratio of invalid features for different denoising methods




图7 基于不同高斯分模型数和HMM隐含状态数组合的识别结果对比

Fig.7 Comparison of recognition results based on the different combination number of HMM hide states and Gaussian mixture components

3~8个,高斯分模型个数取1~5个,试验结果对比如图7所示。

从图7中可以看出,这些参数组合的平均识别率约在83%~89%之间,彼此之间差别不是很大。但大部分组合的识别率随着隐藏状态数量增加,识别率均有下降。由于隐藏状态数增多会增加模型训练和识别的计算量,并且当组合策略为4个隐状态、3个高斯分模型时平均识别率最高,因此本文在每个行为的HMM模型下均设置4个隐状态,每个GMM有3个高斯分模型。

3.4 识别结果及与SVM的对比试验分析

针对散步、跑步、骑行、上坡、下坡、上楼梯和下楼梯这7种动作模式,经过小波包去噪后,每个

人每种状态取300个窗口,共2100个窗口。每个状态的前200个窗口用于训练模型,训练出7个GMHMM模型,后100个窗口用于验证模型的识别率,识别结果如表1所示。

从表1中可以看出,散步、跑步、骑行、上坡、下坡和下楼梯的识别率均高于90%,散步和骑行的识别率甚至高达96.25%,说明了本方法对人体动作和路况识别具有良好的识别效果,并且对差异比较明显的行为识别效果更好。虽然上楼梯的识别率偏低只有88.75%,但从总体上来看,本文方法可以满足智能假肢对于人体动作和路况的识别要求。

此外,本文和应用较为广泛的SVM算法进行了试验对比。在特征提取方法、模型的训练样本、

表 1 基于 GMHMM 的人体下肢行为识别混淆矩阵

Tab.1 The confusion matrix of lower limb recognition based on GMHMM

动作模式	识别率						
	散步	跑步	骑行	上坡	下坡	上楼梯	下楼梯
散步	96.25%	—	—	1.25%	2.50%	—	—
跑步	—	92.5%	2.50%	2.50%	—	—	2.50%
骑行	—	3.75%	96.25%	—	—	—	—
上坡	—	—	—	91.25%	0	1.25%	7.50%
下坡	—	3.75%	1.25%	1.25%	93.75%	—	—
上楼梯	—	—	5.00%	2.50%	—	88.75%	3.75%
下楼梯	—	—	2.50%	7.50%	—	—	90.00%

表 2 基于 SVM 方法的人体下肢识别混淆矩阵

Tab.2 The confusion matrix of lower limb recognition based on SVM method

动作模式	识别率						
	散步	跑步	骑行	上坡	下坡	上楼梯	下楼梯
散步	97.78%	2.22%	—	—	—	—	—
跑步	—	88.47%	8.65%	—	1.92%	—	0.96%
骑行	—	18.56%	75.26%	—	3.09%	—	3.09%
上坡	—	—	0.95%	90.48%	5.71%	2.86%	—
下坡	—	9.00%	1.00%	5.00%	72.00%	1.00%	12.00%
上楼梯	3.92%	5.88%	—	15.69%	5.88%	68.63%	—
下楼梯	0.95%	2.86%	3.81%	—	0.95%	—	91.43%

测试样本均与 GMHMM 方法相同。SVM 的核函数采用径向基函数 (radial basis function, RBF), 识别结果如表 2 所示。

从表 2 得出, SVM 方法下的散步状态识别率最高达到 97.78%, 上楼梯状态识别率最低仅仅为 68.63%, 并且把上楼梯误判为上坡的比例达到 15.69%, 说明对于比较相似的路况或人体动作, SVM 区分能力不是很强。此外, 在 SVM 算法下的骑行状态识别率有 75.26%, 下坡状态识别率只有 72%, 本文方法在同模式的识别率分别达到 96.25% 和 93.75%, 并且本文方法 92.69% 平均识别率远高于 83.36% 的 SVM 平均识别率, 充分证明本文方法的优越性。

4 讨论

本文提出了一种基于惯导信号的人体动作和路况识别方法, 可用于正常人和智能假肢(下肢)的动作和路况识别。惯导传感器的廉价、小巧、易安装, 使得惯导信号在假肢上的应用比图像信号和肌电信号处理更可靠、更合适。最终试验结果显示, 本文所提出的识别模型识别率较高, 今后或可在智能假肢、运动康复等多个研究领域方向上具有一定的应用前景。本文提出的方法是针对时间窗内信号进行信号分析, 所以识别存在一定的滞后

性, 当人体行为模式切换较为频繁时行为识别率也会降低。今后的研究需增加基于惯导信息的人体动作和路况的预测, 使假肢更加智能化和实用化。

参考文献

- 1 Sup F, Bohara A, Goldfarb M. Design and control of a powered transfemoral prosthesis. *Int J Rob Res*, 2008, 27(2): 263-273.
- 2 Tucker M R, Olivier J, PAGEL Anna, *et al.* Control strategies for active lower extremity prosthetics and orthotics: a review. *J Neuroeng Rehabil*, 2015, 12(1): 1-29.
- 3 张腾宇, 兰陟, 樊瑜波. 智能膝关节假肢的技术发展与趋势分析. *中国康复医学杂志*, 2017, 32(4): 451-453.
- 4 杨鹏, 刘作军, 耿艳利, 等. 智能下肢假肢关键技术研究进展. *河北工业大学学报*, 2013, 42(1): 76-80.
- 5 Powers C M, Boyd L A, Torburn L, *et al.* Stair ambulation in persons with transtibial amputation: an analysis of the Seattle LightFoot. *J Rehabil Res Dev*, 1997, 34(1): 9-18.
- 6 Headon R, Curwen R. Recognizing movements from the ground reaction force, *CiteSeer*, 2001:1-8.
- 7 Jeong J, Cho W, Kim Y, *et al.* Recognition of lower limb muscle EMG patterns by using neural networks during the postural balance control//3rd Kuala Lumpur International Conference On Biomedical Engineering 2006. Berlin: Springer, 2007: 82-85.
- 8 刘磊, 杨鹏, 刘作军, 等. 采用核主成分分析和相关向量机的人体运动意图识别. *机器人*, 2017, 39(5): 661-669.
- 9 王振平, 喻洪流, 杜妍辰, 等. 假肢智能膝关节的研究现状和发展趋势. *生物医学工程学进展*, 2015, 36(3): 159-163.
- 10 Wang Y, Shi Y, Wei G. A novel local feature descriptor based on

- energy information for human activity recognition. Elsevier Science Publishers B. V, 2017: 19-28.
- 11 尹燕芳, 孙衣亮, 刘明, 等. 基于BSCPs-RF的人体关节行为识别与预测. 机器人, 2017, 39(6): 795-802.
 - 12 Jiménez-Fabián R, Verlinden O. Review of control algorithms for robotic ankle systems in lower-limb orthoses, prostheses, and exoskeletons. Med Eng Phys, 2012, 34(4): 397-408.
 - 13 Kim S K, Hong S, Kim D. A walking motion imitation framework of a humanoid robot by human walking recognition from IMU motion data//IEEE-Ras International Conference on Humanoid Robots, IEEE, 2009:343-348.
 - 14 张向刚, 唐海, 付常君, 等. 一种基于隐马尔科夫模型的步态识别算法. 计算机科学, 2016, 43(7): 285-289, 302.
 - 15 Preece S J, Goulermas J Y, Kenney L P, *et al.* A comparison of feature extraction methods for the classification of dynamic activities from accelerometer data. IEEE Trans Biomed Eng, 2009, 56(3): 871-879.
 - 16 Kwapisz J R, Weiss G M, Moore S A. Activity recognition using cell phone accelerometers. Acm Sigkdd Explorati, 2011, 12(2): 74-82.
 - 17 Abhayasinghe N, Murray I. Human activity recognition using thigh angle derived from single thigh mounted IMU data//2014 International Conference On Indoor Positioning And Indoor Navigation (IPIN), IEEE, 2014: 111-115.
 - 18 Shi G Y, Zou Y X, Li W J, *et al.* Towards multi-classification of human motions using micro IMU and SVM training process. Adv Mat Res, 2009, 60-61: 189-193.
 - 19 Dehzangi O, Taherisadr M, Changanvala R. IMU-based gait recognition using convolutional neural networks and multi-sensor fusion. Sensors (Basel), 2017, 17(12): 2735-2757.
 - 20 Panahandeh G, Mohammadiha N, Leijon A A. Continuous hidden markov model for pedestrian activity classification and gait analysis. IEEE Trans Instrum Meas, 2013, 62(5, SI): 1073-1083.
 - 21 You Y, Qian Y, He T, *et al.* An investigation on DNN-derived bottleneck features for GMM-HMM based robust speech recognition//IEEE China Summit and International Conference on Signal and Information Processing, IEEE, 2015: 30-34.
 - 22 Oskoei M A, Hu Huosheng. Myoelectric control systems-A survey. Biomed Signal Process Control, 2007, 2(4): 275-294.
 - 23 Zhou X, Zhou C, Stewart B G. Comparisons of discrete wavelet transform, wavelet packet transform and stationary wavelet transform in denoising PD measurement data//Conference Record of the 2006 IEEE International Symposium on Electrical Insulation, IEEE, 2006: 237-240.

收稿日期: 2017-12-21 修回日期: 2018-04-20

本文编辑: 陈咏竹