

基于时-频分析的步态模式自动分类

王 斐^{1 2)} ✉ 闻时光¹⁾ 张育中¹⁾ 金基准¹⁾ 吴成东¹⁾

1) 东北大学流程工业综合自动化国家重点实验室, 沈阳 110819 2) 哈尔滨工业大学机器人技术与系统国家重点实验室, 哈尔滨 150001

✉ 通信作者, E-mail: wangfei@ise.neu.edu.cn

摘 要 针对不同路况和运动模式下的高维、非线性、强耦合和高时变下肢加速度信号的识别问题, 提出了一种基于时-频分析的步态模式自动分类方案. 利用三轴加速度传感器采集运动时小腿在矢状面、冠状面和横切面的加速度信号, 利用五阶 Daubechies 小波基对其进行特征提取, 并采用线性判别式分析进行降维, 最后利用决策树和支持向量机对得到的精简步态特征进行模式分类. 实验结果显示两种分类器的总体分类准确率均达到 90% 以上, 个别步态分类可达到 100%, 验证了特征提取和降维方法的合理性和有效性.

关键词 步态分析; 模式分类; 加速度测量; 小波分析; 决策树; 支持向量机

分类号 TP183

Automated classification of gait patterns based on time-frequency analysis

WANG Fei^{1 2)} ✉, WEN Shi-guang¹⁾, ZHANG Yu-zhong¹⁾, KIM Ki-jun¹⁾, WU Cheng-dong¹⁾

1) State Key Laboratory of Integrated Automation for Process Industries, Northeastern University, Shenyang 110819, China

2) State Key Laboratory of Robotics & System, Harbin Institute of Technology, Harbin 150001, China

✉ Corresponding author, E-mail: wangfei@ise.neu.edu.cn

ABSTRACT A general scheme for the automated classification of gait patterns based on time-frequency analysis was proposed to discriminate acceleration signals characterized by high dimension, non-linearity, strong coupling and high time-varying acquired under different terrains and motion patterns of lower limbs. A three-axis acceleration sensor was mounted on a crus to acquire acceleration signals in the sagittal, coronal and cross-sectional planes separately. By using a 5-order Daubechies wavelet base, the features were extracted from time-series acceleration signals and further dimensionally reduced by employing linear discrimination analysis (LDA). The reduced features were classified by the decision tree and the support vector machine (SVM). From experimental results, both classifiers can achieve the high classification accuracy ratio over 90% and for the specified gait the ratio can be up to 100%, indicating the rationality and effectiveness of the proposed methods for feature extraction and dimension reduction.

KEY WORDS gait analysis; pattern classification; acceleration measurement; wavelet analysis; decision trees; support vector machines (SVM)

步态是指人行走时的姿态, 正常的双腿行走是一种近似周期性的运动. 行走过程中双脚与地面交替接触和分离, 脚与地面的接触是一个滚动过程, 这一过程可以用一些步态特征参数来刻画, 如髌、膝和踝关节角度、角速度和角加速度, 步长、步频和步态周期以及地面反作用力等运动学和动力学信息. 这些步态特征是习惯使然的, 是一种后天行为, 然而其中却蕴含了众多的有价值信息^[1-2].

步态识别在身份验证、康复医学和计算机辅助诊断及仿人机器人等众多领域都有着非常重要的研

究和应用价值, 是目前生物特征识别领域一个重点的研究方向. 除了基于机器视觉的非接触式远程身份识别外, 应用前景更广泛的基于移动测量方式的 (如惯性传感器和力传感器) 的步态识别成为近年来该领域的一个研究热点, 但由于通过这种方式获取的步态数据具有强噪声、高维、非线性、强耦合及高时变性等特点, 使得定量的步态分析面临着巨大的挑战.

近十年来, 学者们从不同的应用领域出发, 采用不同的理论方法和技术手段对步态识别进行了深

入的探索和研究. Sekine 等^[3]利用绑缚在接近人体重心处的三轴加速度传感器对平路行走和上下楼梯这两种路况进行分类,并利用加速度信号评价了老年人和患有帕金森病人的步态. Wang 等^[4]利用加速度传感器感知运动时腰部的姿态信息,使用小波分解技术提取了 33 维特征向量,并利用神经网络对上下楼梯、上下坡和平路行走步态进行了分类. 文献[5]利用经验模态分解提取了 20 维的特征向量,并运用高斯混合模型成功地将上下楼梯、上下坡和平路行走这五种典型步态模式进行了分类. 类似研究在解决各自的问题上都取得了令人满意的结果^[6-9]. 可见人体运动时加速度信号是表征人体步态的一个重要参数,而获取加速度信息的感知系统设计简单、成本低廉、性能可靠且可在任意环境下使用.

本文要研究的对象是膝上截肢残疾人穿戴的智能仿生腿,它可通过步态识别间接估计出残疾人的运动意图,进而控制假肢关节对健康腿的步态进行智能跟随. 上述文献中提到的方法虽然解决了路况识别问题,但对于残疾人日常生活中经常遇到的变速行走、奔跑和跳跃等下肢运动模式的识别却鲜有文献提及. 且上述文献中提取的特征向量的维数往往过高,这不但影响分类的精度,也增加了控制系统的计算负荷,无法适应智能仿生腿实时步态控制的要求.

本文对智能假肢领域存在的步态识别问题进行了研究,以上、下楼梯,奔跑,跳跃,常速行走及快速行走这六种典型步态为例来进行识别,它们既包含了路况信息,也包含了步行速度和运动形式等信息. 首先利用绑缚在小腿末端的三轴加速度传感器获取下肢运动时在矢状面、冠状面和横切面上的加速度信号,然后利用五阶 Daubechies 小波基和线性判别式分析(linear discrimination analysis, LDA)对时序加速度信号进行特征提取和特征降维,并分别采用决策树和支持向量机(support vector machine, SVM)对提取的特征进行分类以验证所提出特征处理方法的正确性和有效性.

1 加速度信号的采集与处理

感知系统构成及实验配置如图 1 所示. 在测试者下肢(接近踝关节位置)放置一个三轴加速度传感器(Freescale MMA7260)用来感知行走时下肢在矢状面、冠状面和横切面上的加速度信息. 模拟信号通过 C8051F206 单片机进行采样处理后,经 RS-232 串口传送到 DSP 存储并进行在线步态信号处理.



图 1 下肢加速度信号采集实验配置

Fig. 1 Experimental configuration for acceleration signal acquisition of lower limbs

测试对象共有 14 人(均为成年男性,身高 168 ~ 180 cm,体重 60 ~ 76 kg). 每个测试对象须完成六组步态实验,分别是上、下楼梯,奔跑,跳跃,快速行走和常速行走. 每组实验要重复进行三次,每次持续时间从 7 ~ 20 s 不等,采集得到的原始加速度信号(快速平路行走和上楼梯)如图 2 所示. 采集得到的加速度信号中包含了大量由电子器件本身引入的噪声,其本质属高频噪声,因此采用巴特沃斯滤波器进行低通滤波,截止频率设定为 26 Hz. 此处对信号低通滤波的主要目的不是滤除噪声,而是为下一步小波分解做准备,因此采用的截止频率较高,噪声滤除主要在小波分解中体现.

2 特征选取与特征降维

目前对加速度信号进行处理的手段主要有离散小波变换、快速傅里叶变换、短时傅里叶变换和经验模态分解等方法^[10]. 本文利用五阶 Daubechies 小波分解对加速度信号进行时频域分析,将三个方向上的加速度信号分解为六层. 其中,近似信息用 A 表示,细节信息用 D 表示,层数用 i ($i = 1, 2, \dots, 6$) 表示,则 A_i 和 D_i 分别表示第 i 层上的近似信息和细节信息. 此外,对 D_i 再进行二层小波分解,用 DA 表示近似信息, DD 表示细节信息,层数用 i ($i = 1, 2$) 表示,则 DA_i 和 DD_i 分别表示对 D_i 进行分解得到的第 i 层的近似信息和细节信息. 由小波分解理论可知, A_i 代表低频信息, D_i 代表高频信息,且假设上一层近似信息的频率范围为 $0 \sim f$ Hz, 则 A_i 的频率范围为 $0 \sim (1/2)f$ Hz, D_i 的频率范围为 $(1/2)f \sim f$ Hz. 由于加速度信号的频率范围为 $0 \sim 26$ Hz, 按上




图 2 不同步态模式下的加速度信号. (a) 快速行走时水平面的加速度; (b) 快速行走时矢状面的加速度; (c) 快速行走时冠状面的加速度; (d) 上楼梯时水平面的加速度; (e) 上楼梯时矢状面的加速度; (f) 上楼梯时冠状面的加速度

Fig. 2 Acceleration signals under different gait patterns: (a) acceleration signal in the horizontal plane when walking; (b) acceleration signal in the sagittal plane when walking; (c) acceleration signal in the coronal plane when walking; (d) acceleration signal in the horizontal plane when going upstairs; (e) acceleration signal of sagittal plane when going upstairs; (f) acceleration signal of coronal plane when going upstairs

述原理可知, D_i ($i = 2, 3, \dots, 6$)、 DA_2 和 DD_2 是 0.4 ~ 19.5 Hz 频率段的信息, 其余信息均在这频率段外. 相关研究表明步态加速度有用信号主要集中在 17 Hz 以下, 而重力加速度信号主要集中在 0.25 Hz 以下的频率段. 因为 0.4 ~ 19.5 Hz 基本包含了 0.25 ~ 17 Hz 频率段, 所以只利用这个频率段的信息, 而其余信息均被忽略, 对每个方向的加速度均按表 1 中的表达式提取特征, 其中 std 表示标准方差, rms 则表示均方根.

表 1 每个方向加速度提取到的特征

Table 1 Extracted features of acceleration in every direction

编号	特征
1	$\sum_{i=2}^6 \ D_i\ ^2 + \ DA_2\ ^2 + \ DD_2\ ^2$
2	std(D_i) ($i=2, 3, \dots, 6$) std(DA_2) std(DD_2)
3	rms(D_i) ($i=2, 3, \dots, 6$) rms(DA_2) rms(DD_2)

从表 1 可知, 对三个方向加速度信号提取的特征共 45 维, 维数较高, 利用 LDA 进行进一步的特征选取, 以减少在设计分类器时的计算量. LDA 与主分量分析 (principle components analysis, PCA) 有所不同, PCA 主要是寻找在最小均方意义下最能够代表原始数据的映射, 而 LDA 是寻找在最小均方意义下最能够分开各类数据的映射. 设 $X = \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\}$, $x_i \in \mathbf{R}^n$, $y_i \in Y = \{1, 2, \dots, c\}$, c 是类别总数. 则样本集 X 的类内散布矩阵 S_W 和类间散布矩阵 S_B 见下式:

$$\begin{cases} S_W = \sum_{i=1}^c S_i; \\ S_B = \sum_{i=1}^c n_i (\mu_i - \mu) (\mu_i - \mu)^T; \\ S_i = \sum_{x \in D_i} (x - \mu_i) (x - \mu_i)^T; \\ \mu_i = \frac{1}{n_i} \sum_{x \in D_i} x = \frac{1}{l} \sum_{i=1}^l x_i. \end{cases} \quad (1)$$

式中, D_i 为属于第 i 类的所有 x 构成的集合, n_i 为属于第 i 类样本的总数. 现假设找到一个线性映射, 用 $n \times d$ 阶的矩阵 W 表示, 通过 $z = W^T x$ 将样本集 X 映射为 Z 样本集, $Z = \{(z_1, y_1), (z_2, y_2), \dots, (z_l, y_l)\}$, $z_i \in \mathbf{R}^d$, $y \in Y = \{1, 2, \dots, c\}$. 按照式 (1), 同样可以对样本集 Z 定义类内散布矩阵 S'_W 和类间散布矩阵 S'_B , 且容易证明:

$$\begin{cases} S'_W = W^T S_W W, \\ S'_B = W^T S_B W. \end{cases} \quad (2)$$

为了使得样本集 Z 中同类数据尽可能聚集而不同类数据尽可能分开, 可转换为求下式的最大值问题:

$$J(W) = \frac{|S'_B|}{|S'_W|} = \frac{|W^T S_B W|}{|W^T S_W W|}. \quad (3)$$

求解出上式的最优值, 即可得到所需映射 W , 则就可以将 n 维数据降为 d 维, 并且最大程度地保证同类样本聚集, 非同类样本分开. 本文主要根据训练和测试的准确率来选择最后降维的维数 d , 当

d 取不同值时,其训练和测试的准确率如图 3 所示. 当 d 取大于 5 的值时训练误差降为 0,但当 d 取 9 时其测试误差反而上升,所以综合考虑训练误差和测试误差以及计算复杂性等因素, d 取 5.




图 3 训练误差和测试误差与特征维数 d 的关系曲线

Fig. 3 Relations of training error and test error with feature dimension d

3 特征模式分类

为了验证特征提取和特征选取/降维方法的正确性和有效性,本文选取了两种分类器对步态特征进行分类,分别是决策树和 SVM.

决策树又称判定树,是用于分类和预测的一种树结构,对于解决多类或多峰分布问题尤为方便,它将一个复杂的多类别分类问题转化为若干个简单的分类问题来解决. 创建树的关键是在每个结点上如何选择特征以便创建简单的树. 目前针对这一问题,学者提出了许多决策树分类算法,主要有 CLS 算法和 CART 算法以及 ID3 算法.

SVM 是目前小样本学习能力极强的一种分类模型,较传统的神经网络等分类模型具有很强的泛化能力. SVM 有很多不同的模型,本文采用了 C-SVM. 设已知训练集 $T = \{(x_1, y_1), (x_2, y_2), \dots,$

$(x_l, y_l)\}$, $x_i \in X = \mathbf{R}^n$, $y_i \in Y = \{1, -1\}$, $i = 1, 2, \dots, l$. 选取适当的核函数 $K(x, x')$ 和适当的惩罚参数 C 构造并求解下列最优化问题:

$$\min_{\alpha} \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l y_i y_j \alpha_i \alpha_j K(x_i, x_j) - \sum_{j=1}^l \alpha_j \tag{4}$$

$$\text{s. t. } \sum_{i=1}^l \alpha_i y_i = 0; 0 \leq \alpha_i \leq C \quad i = 1, 2, \dots, l.$$

令最优解为 $\alpha^* = (\alpha_1^*, \alpha_2^*, \dots, \alpha_l^*)$, 选取 α^* 的一个正分量 $0 < \alpha_i^* < C$, 并据下式计算阈值 b^* :

$$b^* = y_j - \sum_{i=1}^l y_i \alpha_i^* K(x_i, x_j). \tag{5}$$

最后构造决策函数 $f(x)$ 如下式:

$$f(x) = \text{sgn} \left(\sum_{i=1}^l y_i \alpha_i^* K(x_i, x) + b^* \right). \tag{6}$$

在本文中主要涉及上、下楼梯,奔跑,跳跃,常速行走和快速行走等六种步态,要解决的是多分类问题,因此采用一类对余类多类算法,即将多类问题划分为多个二分类问题,再用上述的算法进行求解.

4 实验结果与讨论

本文主要研究智能仿生腿跟随健康肢体的步态识别问题. 为了实验方便,所有数据均采集于健康人的右(或左)侧下肢,这点符合假肢的实际使用情况,即为了进行步态识别,智能仿生腿所需的信息主要采集于健康肢体. 本文的数据样本采集于 14 名健康受试者(均为成年男性),其中 50% 的样本数据作为训练样本集,其余数据作为测试样本集. 下面分别给出决策树和 SVM 的分类结果.

4.1 决策树分类实验结果

图 4 给出了训练后得到的决策树结构,其中

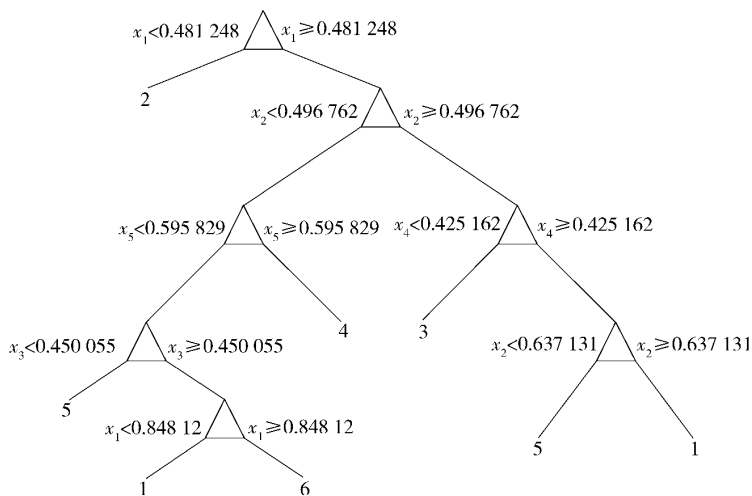


图 4 训练得到的决策树结构

Fig. 4 Decision tree structure after train training

x_1, x_2, x_3, x_4, x_5 和 x_6 是利用 LDA 映射后特征向量中的分量. 其中下标 1、2、3、4、5 和 6 分别代表快速步

行、奔跑、常速步行、上、下楼梯和跳跃这六种步态. 表 2 给出了决策树分类的测试结果.

表 2 决策树分类测试结果
Table 2 Classification results by using the decision tree

步态类别	快速步行 /%	跑 /%	常速步行 /%	上楼梯 /%	跳跃 /%	下楼梯 /%
快速步行	94.12	0	5.88	0	0	0
跑	0	100	0	0	0	0
常速步行	19.05	0	80.95	0	0	0
上楼梯	0	0	0	86.67	0	13.33
跳跃	0	0	0	25	75	0
下楼梯	5.56	0	0	0	0	100
总体准确率	90%					

4.2 支持向量机分类实验结果

在本文中,核函数选取常用的 RBF 核函数, RBF 核函数具体形式如下:

$$K(x, x') = \exp\left(\frac{-0.5 \times \|x - x'\|^2}{\gamma^2}\right) \quad (7)$$

图 5 给出了核函数参数 γ 、惩罚参数 C 与训练误差的关系. 从图中可以看出当 γ 取 0.2 左右, C 取 6 左右, 训练误差较小. 因此, 本文取 $\gamma = 0.2$, $C = 6$, 得到的实验结果见表 3.

从表 2 和表 3 可以看出, 支持向量机的分类效果比决策树分类效果理想. 虽然两者的总分类准确率均达到 90% 以上, 但决策树对上、下楼、快走、正

常步速行走分类效果较差, 利用支持向量机进行分类, 这几种步态分类效果得到明显的改善. 两种模型分类器的总分类准确率都是可以接受的.




图 5 训练误差与核函数参数、惩罚参数的关系

Fig. 5 Relation of training error with kernel parameter and penalty parameter

表 3 支持向量机分类测试结果
Table 3 Classification results by using SVM

步态类别	快速步行 /%	跑 /%	常速步行 /%	上楼梯 /%	跳跃 /%	下楼梯 /%
快速步行	94.12	0	5.88	0	0	0
跑	0	100	0	0	0	0
常速步速	0	0	100	0	0	0
上楼梯	0	0	0	100	0	0
跳跃	8.33	0	0	0	91.67	0
下楼梯	0	0	0	5.56	0	94.44
总体准确率	97%					

5 结论

本文主要根据人体在不同运动模式下小腿处(接近踝关节处)矢状面、冠状面和水平面的加速度信号来对平路正常步速行走、快走、跑、跳以及上、下楼梯这六种运动模式进行分类. 在特征提取环节中利用小波多分辨率的特点将这三个方向的加速度信号分解到特定频带上, 并对每个方向的加速度信号

采集了 15 维的特征向量, 三个方向的加速度信号共采集了 45 维的特征向量, 由于维数较高, 采用了 LDA 对特征向量进行了降维处理, 最终每种运动模式提取到的特征向量仅 5 维, 大大简化了系统的复杂性. 在最后的分类器设计环节中, 采用了两种分类器模型对该特征提取方法的稳定性和可行性进行了验证, 结果表明该方法可以对上述几种运动模式进行高精度地分类. 由于向量维数低, 因此计算

速度快,可用于智能仿生腿实时步态跟随控制中.

参 考 文 献

- [1] Murray M P. Gait as a total pattern of movement. *Am J Phys Med*, 1967, 46(1): 290
- [2] Zhang R H, Jin D W, Zhang J C, et al. Normal gait patterns on different terrain. *J Tsinghua Univ Sci Technol*, 2000, 40(8): 77 (张瑞红, 金德闻, 张济川, 等. 不同路况下正常步态特征研究. 清华大学学报: 自然科学版, 2000, 40(8): 77)
- [3] Sekine M, Tamura T, Akay M, et al. Discrimination of walking patterns using wavelet-based fractal analysis. *IEEE Trans Neural Syst Rehabil Eng*, 2002, 10(3): 188
- [4] Wang N, Ambikairajah E, Celler B G, et al. Accelerometry based classification of gait patterns using empirical mode decomposition// *Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing*. Las Vegas, 2008: 617
- [5] Wang N, Ambikairajah E, Lovell N H, et al. Accelerometry based classification of walking patterns using time-frequency analysis// *Proceedings of the 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. Lyon, 2007: 4899
- [6] Bidargaddi N, Klingbeil L, Sarela A, et al. Wavelet based approach for posture transition estimation using a waist worn accelerometer// *Proceedings of the 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. Lyon, 2007: 1884
- [7] Turcot K, Aissaoui R, Boivin K, et al. New accelerometric method to discriminate between asymptomatic subjects and patients with medial knee osteoarthritis during 3-D gait. *IEEE Trans Biomed Eng*, 2008, 55(4): 1415
- [8] Bidargaddi N, Sarela A, Klingbeil L, et al. Detecting walking activity in cardiac rehabilitation by using accelerometer// *Proceedings of the 2007 International Conference on Intelligent Sensors, Sensor Networks and Information Processing, ISSNIP*. Melbourne, 2007: 555
- [9] Sekine M, Tamura T, Fujimoto T, et al. Classification of walking pattern using acceleration waveform in elderly people// *Proceedings of the 22nd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. Chicago, 2000: 1356
- [10] Chen M, Huang B F, Xu Y S. Intelligent shoes for abnormal gait detection// *Proceedings of the 2008 IEEE International Conference on Robotics and Automation*. Pasadena, 2008: 2019