

基于足压特征信号的步态识别研究

高莉俊^{1,2}, 许德章^{1,2}, 汪步云^{1,2}

(1. 安徽工程大学机械与汽车工程学院, 安徽 芜湖 241000; 2. 芜湖安普机器人产业技术研究院有限公司, 安徽 芜湖 241007)

摘要:在人体步态的解析研究中,足底压力信号常被检测用以分析步态的变化情况。其中,以传感器阵列采集的足压信息,因信号关联性弱、冗余度高以及噪声干扰等原因,而无法直观识别出步态的变化规律。针对这一问题,以盲信号建立足压信号的数学模型,在分析其构成与解析上的复杂性后,采用奇异值分解(SVD)的方法,从多源观测数据中提取出足压特征信号。提出以主特征向量张成信息子空间中各特征点的分布规律,结合先验的步态运动过程,对单足步态运动进行识别与划分,并利用多组步态实验数据,验证了该方法的有效性。

关键词:足压信号;奇异值分解;特征提取;步态解析

中图分类号:TP242

文献标志码:A

引言

人在行走的过程中,足压记录了关于步态的丰富信息,这些信息在病理分析^[1]、身份识别^[2]、人机交互^[3-4]等领域有着极高的研究与应用价值。尤其在下肢外骨骼助力机器人的人机信息交互、行走引导以及稳定性检测等方面有着重要意义。其中,薄膜式压敏传感器(FSR),作为一种外形纤薄、灵敏度高的传感器,已被广泛应用于该类信息的检测当中^[5-6]。在具体的应用过程中,常采用传感器多点阵列的形式检测足压信息。该方式下,各阵元采集的足压数据形成信息上的互补,但互补信息间关联性较弱,且不可避免地存在冗余,在混杂了噪声干扰之后,很难由其直接解析出步态的相关变化

规律。

为了从足压多源采集信号中有效识别出步态的相关运动特性,目前,多数研究以随机过程建模步态运动,并结合概率统计、预测估计、模糊分类等方法对步态进行解析,且取得了不同的步态识别结果。如文献^[7-9]均以隐马尔可夫模型(HMM)建立步态运动过程。其中,文献^[7]将足压信号与足部加速度信号相融合,判断识别出平地、上楼梯、下楼梯等多种行走模式;文献^[8]以足底64个压力采集点的数据估算出足压中心点(CoP)的变化,并以此对行走过程中的单支撑相、双支撑相进行实时判别;文献^[9]利用高斯朴素贝叶斯分类(GNB)及模糊准则,对单足运动过程中的5种步态相位进行实时判别。文献^[10]以半马尔可夫

收稿日期:2017-10-09

基金项目:安徽省自然科学基金项目(1608085QF154);安徽省科技攻关项目(1604a0902125);安徽工程大学引进人才科研启动基金(2015YQQ005)

作者简介:高莉俊(1989-),男,安徽芜湖人,硕士生,主要从事机器人信息感知方面的研究,(E-mail)gao_lijun@126.com

许德章(1964-),男,安徽芜湖人,教授,博士,主要从事机器人信息感知、信号获取与应用等方面的研究,(E-mail)dzx@ahpu.edu.cn

过程(SMP)建模步态运动,并以双足地面反作用力为解算对象,采用主成分分析(PCA)的方法,实现了对异常步态的有效评估。

上述研究中,对于步态运动过程的辨识属于在线分析,故当前状态的识别较依赖于之前每一次状态的准确预测,其鲁棒性不强,不适宜中长期步态信息的预测识别。本文以盲信号建模足压信息,对采集到的信号进行离线分析,并能从截取的足压信息中对单足运动过程进行识别。具体采用奇异值分解(SVD)的方法,从原始信息中提取出特征信号,并以相应特征点的空间聚类分布规律,对单足运动过程按阶段进行划分识别。

1 足压信号分析

为全面检测足压信号,在一双自主设计的压力采集鞋垫上,布置薄膜式压敏传感器阵列。各传感器分别对应足底8个压力感应区域,具体阵列形式如图1所示。




图1 足底压力传感器阵列分布

利用足压信号对步态进行解析,需要以足压的特征变化为依据。而足压信号的特征提取,其过程类似与盲源信号分离(BSS)^[11],即在检测信号混合方式未知的情况下,求解原信号。故可将压力传感器阵列采集到的信号建模为

$$X(k) = AS(k) + N(k), k = 1, 2, \dots, m \quad (1)$$

式中: $X(k) = [x_1(k), x_2(k), \dots, x_n(k)]^T$ 为足压多源信号观测数据,具体对应传感器阵列的检测输出; A 为信

号混合矩阵,其主要是由局部足压信号混叠,且信号混叠方式不明确所造成的; $S(k) = [s_1(k), s_2(k), \dots, s_r(k)]^T$ 为 r 个足压特征信号,是对于步态变化的直观、准确描述; $N(k) = [n_1(k), n_2(k), \dots, n_r(k)]^T$ 为噪声干扰,其主要源于各传感器阵元的采样误差; m 为总采样次数。具体的信号解析需构造融合算法 $\varphi(\cdot)$, 使得有:

$$\hat{S}(k) = \varphi(X(k)) = \varphi(x_1(k), x_2(k), \dots, x_n(k)) \quad (2)$$

为对足压特征向量 $S(k)$ 的有效估计。假设信息融合算法 $\varphi(\cdot)$ 对应变换矩阵 W , 则有:

$$\begin{aligned} \hat{S}(k) &= WX(k) = \\ &W[AS(k) + N(k)] = \\ &WAS(k) + WN(k) \end{aligned} \quad (3)$$

为了从观测数据 $X(k)$ 中近似提取出足压特征向量 $S(k)$, 矩阵 W 应满足:

$$\begin{cases} WA \approx I \\ WN(k) \approx O \end{cases} \quad (4)$$

即 W 与 A 互逆,且与 $N(k)$ 相乘为零矩阵,但在混合矩阵 A 与噪声干扰 $N(k)$ 均未知的情况下,是无法直接对上式进行解算的。在盲信号分离中,通常采用独立分量分析(ICA)^[12] 或非线性主成分分析(NLPCA)^[13] 等方法,构造对比函数与迭代算法,以求解分离出目标信息。这些方法都基于各源信号 $S_i(k)$ 为零均值信号的假设,且当呈高斯分布的源信号多于一个时,算法便无法收敛。而足压信号本身呈非负性,具体包含的特征性状未知,故直接使用上述方法存在较大难度。此外,足压检测阵元在平面排布的不规则性,亦增加了算法解算的难度。

2 SVD 与特征提取

奇异值分解(SVD)^[14] 在信号的处理中,对数据矩阵 $X \in \mathbf{R}^{m \times n}$ ($m > n$) 的分解,总有如下形式

$$X_{m \times n} = U_{m \times m} \Sigma_{m \times n} V_{n \times n}^T \quad (5)$$

展开式(5)有:

$$\begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1j} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2j} & \cdots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x_{i1} & x_{i2} & \cdots & x_{ij} & \cdots & x_{in} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \cdots & x_{mj} & \cdots & x_{mn} \end{bmatrix} = \begin{bmatrix} u_{11} & u_{12} & \cdots & u_{1m} \\ u_{21} & u_{22} & \cdots & u_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ u_{m1} & u_{m2} & \cdots & u_{mm} \end{bmatrix} \cdot \begin{bmatrix} \sigma_1 & 0 & \cdots & 0 \\ 0 & \sigma_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \sigma_n \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 \end{bmatrix} \cdot \begin{bmatrix} v_{11} & v_{12} & \cdots & v_{1n} \\ v_{21} & v_{22} & \cdots & v_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ v_{n1} & v_{n2} & \cdots & v_{nn} \end{bmatrix} \quad (6)$$

式中: U 、 V^T 为正交阵,且分别为 X 的左、右奇异矩阵; Σ 为对角阵,其中 σ_i 为 X 的奇异值,并按 $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n$ 降序排列;可设数据矩阵 X 中元素 $x_{ij}(i = 1, 2, \dots, n; j = 1, 2, \dots, m)$ 为第 i 个传感器阵元的第 j 次数据采样值。其求解如下:

$$\begin{aligned}
 XX^T &= U\Sigma V^T V \Sigma^T U^T = U\Sigma\Sigma^T U^T = \\
 &\begin{bmatrix} \sigma_1^2 & & & & & \\ & \ddots & & & & \\ & & \sigma_r^2 & & & \\ & & & 0 & & \\ & & & & \ddots & \\ & & & & & 0 \end{bmatrix} U^T \quad (7) \\
 X^T X &= V \Sigma^T U^T U \Sigma V^T = V \Sigma^T \Sigma V^T = \\
 &\begin{bmatrix} \sigma_1^2 & & & & & \\ & \ddots & & & & \\ & & \sigma_r^2 & & & \\ & & & 0 & & \\ & & & & \ddots & \\ & & & & & 0 \end{bmatrix} V^T \quad (8)
 \end{aligned}$$

即对方阵 XX^T 与 $X^T X$ 的特征分解。其中,方阵 XX^T 与 X 的协方差矩阵 C 存在如下关系:

$$\begin{aligned}
 C &= \begin{bmatrix} (x_1, x_1) & (x_1, x_2) & \cdots & (x_1, x_m) \\ (x_2, x_1) & (x_2, x_2) & \cdots & (x_2, x_m) \\ \cdots & \cdots & \cdots & \cdots \\ (x_m, x_1) & (x_m, x_2) & \cdots & (x_m, x_m) \end{bmatrix} = \\
 &\frac{1}{n} \cdot \begin{bmatrix} \sum_{j=1}^n x_{1j}x_{1j} & \sum_{j=1}^n x_{1j}x_{2j} & \cdots & \sum_{j=1}^n x_{1j}x_{mj} \\ \sum_{j=1}^n x_{2j}x_{1j} & \sum_{j=1}^n x_{2j}x_{2j} & \cdots & \sum_{j=1}^n x_{2j}x_{mj} \\ \cdots & \cdots & \cdots & \cdots \\ \sum_{j=1}^n x_{mj}x_{1j} & \sum_{j=1}^n x_{mj}x_{2j} & \cdots & \sum_{j=1}^n x_{mj}x_{mj} \end{bmatrix} = \\
 &\frac{1}{n} \cdot \sum_{j=1}^n x_j x_j^T = \frac{1}{n} \cdot XX^T \quad (9)
 \end{aligned}$$

通过式(9)的推导过程,可看出 XX^T 是根据数据矩阵 X 列向量之间的相关性,对其进行的一种简单、有效融合。显然,其增强了各阵元间数据样本的关联性。同理,基于矩阵行向量融合的协方差矩阵为:

$$C' = \frac{1}{m} \cdot X^T X \quad (10)$$

至此可推断:由式(7)特征分解得到的左奇异矩阵 U ,其中包含的特征向量 u_1, u_2, \dots, u_r ,即为提取出的足压特征信号及干扰信号,且各信号间保持相互独立。为了将足压特征信号与干扰信号完全分离开,对式(5)做如下变形:

$$X = U\Sigma V^T = \sigma_1 u_1 v_1^T + \sigma_2 u_2 v_2^T + \cdots + \sigma_n u_n v_n^T \quad (11)$$

根据奇异值的特性可知,奇异值越大,则对应的提取信息越重要;奇异值越小,则对应的提取信息即为噪声干扰,且已知奇异值 $\sigma_i(i = 1, 2, \dots, n)$ 按降序排列。故可设式(11)中,前 $r(r < n)$ 项为足压特征信号,后 $n - r$ 项为信号采集过程中混入的噪声干扰,具体的信号分离形式可表示为

$$X = U\Sigma V^T = U' \Sigma' V'^T + U'' \Sigma'' V''^T \quad (12)$$

其中:

$$\begin{cases} U' \Sigma' V'^T = \sigma_1 u_1 v_1^T + \sigma_2 u_2 v_2^T + \cdots + \sigma_r u_r v_r^T \\ U'' \Sigma'' V''^T = \sigma_{r+1} u_{r+1} v_{r+1}^T + \sigma_{r+2} u_{r+2} v_{r+2}^T + \cdots + \sigma_n u_n v_n^T \end{cases} \quad (13)$$

且该分离形式需满足主特征信息比重要求:

$$\alpha = \frac{\|U'\Sigma'V'^T\|_F^2}{\|U\Sigma V^T\|_F^2} = \frac{\sum_{i=1}^r \sigma_i^2}{\sum_{i=1}^n \sigma_i^2} \geq \alpha_{\text{Threshold}} \quad (14)$$

即所提取的前 r 项奇异值的累计信息量占总信息量的比重 α , 大于所设定的阈值 $\alpha_{\text{Threshold}}$ 。式(14)中以矩阵的 F 范数量化表示信息量的大小: $\|U'\Sigma'V'^T\|_F^2$ 为前 r 项的累计信息量, $\|U\Sigma V^T\|_F^2$ 为总的信息量, 二者比值即为前 r 项奇异值的累计信息比重。

经上述的数据融合与提取、分离处理, 所获得的左奇异向量 u_1, u_2, \dots, u_r , 即为对足压特征信息的估计 $S(k)$ 。

3 实验分析

实验采集一个正常成年男子在匀速行走过程中的足压信息, 并选取一个完整步态周期内的单足压力数据为解算对象, 具体数据如图 2 所示。图 2 中 8 条独立变化的传感器压力采集曲线, 分别对应足底 8 个不同区域

的压力信息。显然, 各压力曲线所描述的足部触地过程均不完整, 且相互间无关联特征, 并在互补交叠的过程中, 存在信息上的冗余。故从未经处理的足压数据中, 无法直接解析出步态的相关信息。




图 2 传感器压力曲线

根据式(6), 将图 2 中 8 个传感器在一个步态周期内采样 40 次的数, 构成足压观测矩阵 $X_{40 \times 8}$ 。将其按行、列融合, 并利用式(7)与式(8)对融合矩阵进行特征分解, 可得 $U_{40 \times 40}$ 、 $\Sigma_{40 \times 8}$ 、 $V_{8 \times 8}^T$, 相应的奇异值分解形式如下:

$$X_{40 \times 8} = U_{40 \times 40} \Sigma_{40 \times 8} V_{8 \times 8}^T \quad (15)$$

其中:

$$\Sigma_{40 \times 8} = \begin{bmatrix} 10.4917 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 9.2399 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 2.7246 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1.7621 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0.4799 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0.2396 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0.1612 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0.0907 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (16)$$

根据式(14), 计算 $\Sigma_{40 \times 8}$ 中各奇异值 $\sigma_i (i = 1, 2, \dots,$

8) 对应的信息量:

$$\|\sigma_i u_i v_i^T\|_F^2 = \text{tr}[(\sigma_i u_i v_i)(\sigma_i u_i v_i)^T] = \sigma_i^2 \quad (17)$$

与前 r 项累计信息量:

$$\|U'\Sigma'V'^T\|_F^2 = \text{tr}[(U'\Sigma'V'^T)(U'\Sigma'V'^T)^T] = \sum_{i=1}^r \sigma_i^2 \quad (18)$$

结果见表 1。

由表 1 可知, 当 $r = 3$ 时, 累计信息比重为 0.98339, 而通常所设定的信息比重阈值 $\alpha_{\text{Threshold}}$ 为 0.95, 显然满足主特征信息比重要求。故矩阵 $U_{40 \times 40}$ 中, 与 $\sigma_1, \sigma_2, \sigma_3$ 对应的左奇异向量 u_1, u_2, u_3 , 即为提取的足压特征信号, u_4 至 u_8 则为信息采集中混入的噪声干扰。

表1 信息量比重与累计信息比重

奇异值	信息量	信息比重	累计信息比重
σ_1	110.0758	0.53356	0.53356
σ_2	85.3758	0.41384	0.94741
σ_3	7.4234	0.03598	0.98339
σ_4	3.1050	0.01505	0.99844
σ_5	0.2303	0.00112	0.99956
σ_6	0.0574	0.00028	0.99983
σ_7	0.0260	0.00013	0.99996
σ_8	0.0082	0.00004	1

$$(u_1, u_2, u_3) = \begin{bmatrix} -0.0013 & -0.0001 & 0.0005 \\ -0.0014 & 0.0002 & 0.0005 \\ -0.0019 & -0.0009 & 0.0012 \\ -0.0526 & -0.0466 & -0.0515 \\ -0.2555 & -0.2437 & -0.2441 \\ -0.2839 & -0.2681 & -0.2431 \\ -0.3329 & -0.2511 & -0.0075 \\ -0.3357 & -0.2439 & 0.0538 \\ -0.3042 & -0.2195 & 0.0509 \\ -0.2582 & -0.1890 & 0.0407 \\ -0.2004 & -0.1372 & 0.0739 \\ \vdots & \vdots & \vdots \end{bmatrix}_{40 \times 3} \quad (19)$$

式(19)中,矩阵每行即为与采样时刻相对应的特征点,将其映射到由 u_1 、 u_2 、 u_3 所张成的信息子空间 Ω^3 中

$$span\{u_1, u_2, u_3\} \in \Omega^3 \quad (20)$$

结果如图3(a)所示。

特征点的空间分布,记录了足部在整个步态周期内的运动变化过程。如图3(b)所示,为了便于观察其规律,将各特征点投影至 yoz 面,并结合先验的步态识别规律,对其按象限进行分类:原点附近的特征点,对应步态的离地摆动期;第I象限内的特征点,对应步态的足跟触地期;第II象限内的特征点,对应步态的全脚掌着地前期;第III象限内的特征点,对应步态的全脚掌着地后期;第IV象限内的特征点,对应步态的足跟离地期。最终,将上述分类后的特征点还原到原压力信息曲线图中,便形成对步态的直观图解,具体如图3(c)所示。






图3 基于足压特征的单步态识别

为进一步验证上述方法的有效性,实验采集2名成年男子正常行走时的步态信息,被测对象的相关信息见表2。并将上述方法分别应用于实验对象A、B的连续步态分析中,分析的结果如图4所示。

表2 实验对象信息

实验对象	性别	年龄	身高	体重
A	男	24	178cm	61.6kg
B	男	31	181cm	74.7kg

由图4(a)~4(b)两组实验对象的对比分析可知,受被测试者各自体态、行走习惯以及可能存在的足部畸变等因素的影响,从二者足压信息中提取出的特征信号,在张成信息子空间后,对应特征点于 yoz 面的投影分布规律存在显著差异。依照实验总结的方法,对其按象限进行分类,并重映射至原信息的采样时刻后,所形成的连续步态相位划分结果表明:基于足压特征信号的步

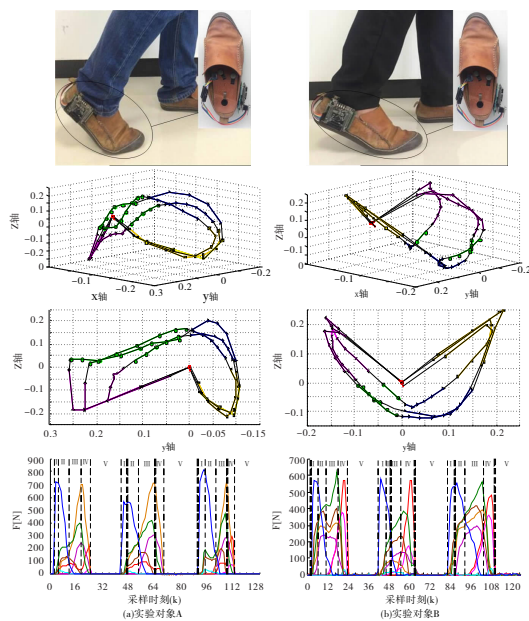


图 4 基于足压特征的连续步态识别

态识别方法,对于两个不同实验对象的步态划分均是有效的,且具有一定的鲁棒性。其中, I 为脚跟触地期、II 为全脚掌着地前期、III 为全脚掌着地后期、IV 为脚跟离地期、V 为摆动期。

4 结束语

本文在足底各区域压力变化关联性未知的情况下,采用奇异值分解的方法,从足底多点压力混杂信号中,提取出足压的主要变化特征。基于该特征,结合先验的步态运动过程,将单足步态过程划分为离地摆动期、脚跟触地期、全脚掌着地前期、前脚掌着地后期以及脚跟离地期,实现了对步态变化的直观解析,并通过两组不同实验对象的连续步态数据验证了该方法的有效性。

参考文献:

[1] 王萍萍,王俊.去趋势互相关分析:一种新的步态分析方法[J].生物医学工程学杂志,2012(6):1193-1196.
 [2] LIANG C, JIA L Y, SHI D C. Identity recognition algorithm using improved Gabor feature selection of gait energy image[J]. Journal of Physics Conference Series, 2017, 778(1): 120151-120156.

[3] 贾山,韩亚丽,路新亮,等.基于人体特殊步态分析的下肢外骨骼机构设计[J].机器人,2014,36(4):392-401,410.
 [4] 高增桂,孙守迁,张克俊,等.面向外骨骼机器人人机交互的步态数据获取系统及识别模型[J].计算机科学,2014,41(10):42-44.
 [5] PINKAM N, NILKHAMHANG I. Wireless smart shoe for gait analysis with automated thresholding using PSO[C]//Proceeding of 2013 10th International Conference on Electrical Engineering/electronics, Computer, Telecommunications and Information Technology, Krabi, Thailand, May 15-17, 2013: 1-6.
 [6] 姜春华,张溪原,崔伟,等.基于PVDF与ARMCM3内核的足底动态压力测试系统[J].压电与声光,2013, 35(2):279-281.
 [7] 赵丽娜,刘作军,苟斌,等.基于隐马尔可夫模型的动力型下肢假肢步态预识别[J].机器人,2014,36(3): 337-341.
 [8] ROSSI S M M D, CREA S, DONATI M, et al. Gait segmentation using bipedal foot pressure patterns [C]// Proceeding of 2012 4th IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechanics, Rome, Italy, June 24-27, 2012: 361-366.
 [9] GONZÁLEZ I, FONTECHA J, HERVÁS R, et al. An ambulatory system for gait monitoring based on wireless sensorized insoles[J]. Sensors, 2015, 15(7): 16589-16613.
 [10] MA H, LIAO W H. Human gait modeling and analysis using a Semi-Markov process with ground reaction forces[J]. IEEE Transactions on Neural Systems & Rehabilitation Engineering A Publication of the IEEE Engineering in Medicine & Biology Society, 2017,

- 25(6):597-607.
- [11] 陈雷,张立毅,郭艳菊,等.基于时间可预测性的差分搜索盲信号分离算法[J].通信学报,2014,35(6):117-125.
- [12] 朱忠奎,陈祥芹,樊薇,等.基于降维的独立分量分析及信号特征成分检测[J].仪器仪表学报,2014,35(4):917-923.
- [13] KENETT R S, SALINI S. Modern Analysis of Customer Surveys: With Applications Using R[M]. New York: John Wiley & Sons, Ltd, 2012.
- [14] LIM J M, DEMARCO C L. SVD-Based voltage stability assessment from phasor measurement unit data [J]. IEEE Transactions on Power Systems, 2016, 31(4): 2557-2565.

Research on Gait Recognition Based on Foot Pressure Characteristic Signals

GAO Lijun^{1,2}, XU Dezhang^{1,2}, WANG Buyun^{1,2}

(1. School of Mechanical and Automotive Engineering, Anhui Polytechnic University, Wuhu 241000, China;

2. Wuhu Ahpu Robot Technology Research Institute Co. Ltd., Wuhu 241007, China)

Abstract: In the analysis of human gait, the plantar pressure signal is often detected to analyze changes in gait. Among them, the foot pressure information collected by the sensor array can not visually recognize the change pattern of gait because of weak signal correlation, high redundancy and noise interference. In order to solve this problem, the mathematical model of the foot pressure signal with the blind signal is established firstly. After analyzing the complexity of its composition and analysis, the singular value decomposition (SVD) method is used to extract the foot Pressure characteristic signal. The distribution law of each feature point in the subspace of the main feature vector Zhang Cheng information is proposed, and the step-by-step motion process is combined to identify and divide the single foot gait movement, and the multi-group gait experimental data is used to verify the effectiveness of the method.

Key words: foot pressure signal; SVD; feature extraction; gait analysis