

中图法分类号: TP301.2 文献标志码: A 文章编号: 1006-8961(2011)04-0625-09

论文索引信息: 胡荣, 王宏远. 对步态空时数据的连续特征子空间分析[J]. 中国图象图形学报, 2011, 16(4): 625-633

对步态空时数据的连续特征子空间分析

胡荣, 王宏远

(华中科技大学电信系数字视频与通信中心, 武汉 430074)

摘要: 提出一种基于空时特征提取的人体步态识别算法。连续的特征子空间学习依次提取出步态的时间与空间特征; 第一次特征子空间学习对步态的频域数据进行主成分分析, 步态数据被转化为周期特征矢量; 第二次特征子空间学习对步态数据的周期特征矢量形式进行主成分分析加线性判别分析的联合分析, 步态数据被进一步转化为步态特征矢量。步态特征矢量同时包含运动的周期特征以及人体的形态特征, 具有很强的识别能力。在 USF 步态数据库上的实验结果显示, 该算法识别率较其他同类算法有明显提升。

关键词: 步态识别; 子空间学习; 主成分分析; 线性判别分析

Recursive spatiotemporal subspace learning for gait recognition

Hu Rong, Wang Hongyuan

(Digital Video and Communication Center, College of Electronic and Information,
Huazhong University of Science and Technology, Wuhan 430074 China)

Abstract: A gait recognition method based on spatiotemporal feature extraction is proposed. Recursive subspace learning is used to extract both time and space feature of gait. In the first subspace learning, the periodic dynamic feature of gait is extracted by principal component analysis and sequence data is represented in the periodicity feature vector form. In the second subspace learning, principal component analysis plus linear discriminant analysis are applied to the periodicity feature vector representation of gait and sequence data is compressed into gait feature vector. Gait feature vector is an effective representation because it contains both human dynamic and shape feature. Experimental result on the USF gait database shows that the proposed method achieves highly competitive performance with respect to other published gait recognition approaches.

Keywords: gait recognition; subspace learning; principal component analysis; linear discriminant analysis

0 引言

步态识别^[1-3]是一项具有挑战性的信息处理技术。由于它在视觉监控以及生物鉴定领域有着广泛的应用前景, 现已受到越来越多的关注。与其他生物识别特征相比, 如脸^[4]、指纹^[5]、虹膜^[6]、签字^[7]等, 步态有着特殊的优势: 1) 步态是非接触式的生

物识别方法, 所以被观察者难以隐藏自己的行为特征; 2) 与指纹和虹膜不同, 步态识别不需要专业的数据采集设备, 人们可以利用现有视频监控仪器; 3) 步态识别适合于大范围远距离的视觉监控, 而其他生物特征可能会由于图像质量问题而无法工作。

步态特征与其他生物特征相比, 最大的不同在于步态数据是 3 维数据。除了空间的 x 与 y 轴之外还包括时间轴 t , 见图 1。步态的空间特征可以理解

收稿日期: 2009-09-17; 修回日期: 2009-11-28

基金项目: 高等学校科技创新工程重大项目培育资金资助项目(708065)。

第一作者简介: 胡荣(1982—), 男, 华中科技大学电信系数字视频中心博士研究生, 主要研究方向为图像处理、运动分割与模式识别。E-mail: hr@smail.hust.edu.cn。

为人在某一时刻的形态特征,而步态的时间特征可以理解为人的运动特征,只有同时融合这两方面的特征才能完整地表达出步态。完整的步态特征提取

过程应该包含两次特征子空间学习,如图 1 所示。图中,上面的路径表示先空间后时间的特征提取顺序;下面的路径表示先时间后空间的特征提取顺序。

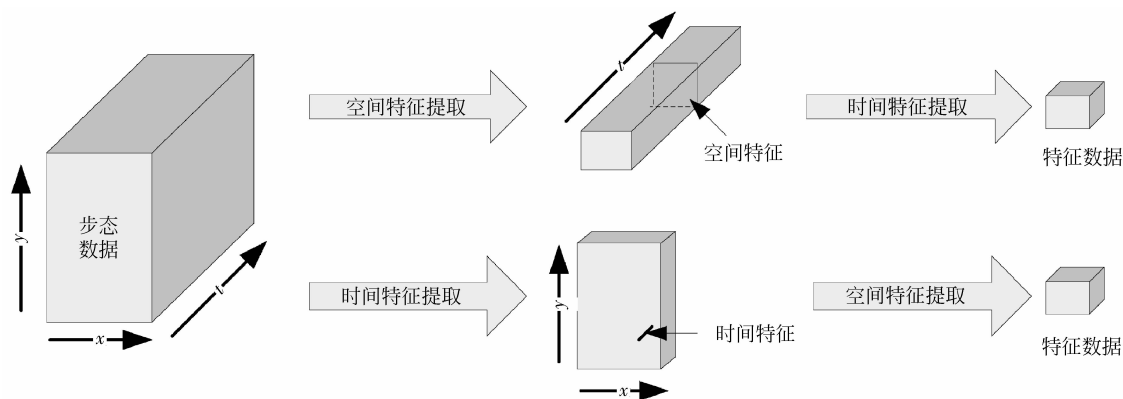


图 1 步态特征提取的一般性框架

Fig. 1 The framework of gait recognition to extract gait feature data

目前大多数的步态识别算法采用的均是先空间后时间的特征提取顺序。例如,在基于模型的一类方法中,有步幅、步频模型^[8]和躯干、臀、膝盖、脚踝的参数模型^[9]等;在非模型类的算法中,有侧影轮廓到人体重心的距离矢量^[10]和侧影轮廓点之间的关系分布^[11]等。这些方法都是首先提取每一帧图像的步态特征,然后再将特征序列进行匹配。其缺点有两个:1)通常情况下,步态序列的帧数较大,而以上方法需要对每一帧图像进行特征提取,因此整体运算效率不高;2)对于单帧图像内特征提取,其精确度会受到多方面影响,如噪声、遮挡等;3)特征序列的匹配要求有准确的步态周期以及相位评估,否则匹配率会受到严重影响。

基于以上考虑,本文提出一种全新的基于步态空时特征提取的人体识别方法。我们采用了先时间后空间的步态特征提取顺序,首先将步态图像中每一点的周期性时间信号转换到频域,然后再对其频域信号进行主成分分析(PCA),并提取出频域信号中的主分量。这些主分量叫做周期特征矢量(PFV),步态数据被转换为周期特征矢量的形式。然后,通过主成分分析(PCA)+线性判别分析(LDA)的联合分析对步态数据的空间特征进行提取,步态数据由此被压缩为步态特征矢量(GFV)。我们通过计算步态特征矢量之间的 Euclidean 距离来评估步态之间的相似性。

与目前主流的步态识别技术相比,本文提出的

方法有以下优点:

1) 与基于模型的方法^[8-9]不同,步态特征矢量既包含了人的周期性运动特征,又包含了人的体态特征。基于模型的方法忽略了人的体态特征,而大量研究却证明人的体态特征较人的运动特征具有更强的识别能力^[12]。同时,由于采用了全局的方法(PCA+LDA)对人体形态特征进行提取,所以对图像品质的要求较低。

2) 步态的 PFV 形式所提供的形态特征具有更高的鲁棒性。不管是基于模型的方法还是非模型的方法,其形态特征的提取都是针对单帧图像。由于总的形态特征误差是各帧图像的形态特征误差之和,所以微小的图像失真或噪声都会严重影响形态特征的最终精确度。本文方法的形态特征是基于整个步态序列的,因为对序列中的各帧图像误差做出了均衡与补偿,所以本文方法鲁棒性更高。

3) 由于不需要对每一帧图像都进行形态特征提取,所以运算效率较高,并且将步态数据以 PFV 形式表达可以节省大量的存储空间。

4) 本文方法无须进行步态周期和相位评估,避免了特征序列的对齐问题。目前,步态特征序列对齐方法都存在一定的缺陷,如自相关法^[10-11,13]需假定相比较的两步态序列拥有相同的周期和采样率;DTW 法^[14]和 HMM 法^[15]需要精确的步态周期和相位评估。

5) 虽然目前也存在一些采用先时间后空间的

特征提取方法,但是本文方法与之相比依然存在明显的优势;MEI/MHI 模型^[16]通过光流分析法来提取步态的运动能量图和运动历史图,但是光流分析法需要大量的计算,并且它没有利用到步态运动的周期特性;GEI^[17]方法采用了步态均值图像,由于对步态数据进行了大量的压缩,所以丢失了大量的步态运动信息。

1 周期特征矢量

步态是一项稳定的周期性运动。假如我们能够将步态序列中的人物对齐,那么步态图像中任意点的时间采样序列均为周期序列(见图 2(e))。对于周期序列而言,将其转换成频域信号是最佳的选择:1)序列在各频率点自动对齐;2)频域信号没有丢失任何步态周期运动特征;3)频域分析不需要对步态序列进行相位评估。

但是仅频域信号不能提供足够的分辨能力,还需要对信号功率谱进行特征子空间分析。这里,我们采用 PCA^[18]来增加信号功率谱之间的辨识度。

1.1 预处理

在数据进行傅里叶变换之前,需要经历系列的预处理:1)侧影提取;2)侧影归一化;3)时域序列的处理,如图 2 所示。其中,子图(a)~(c)分别显示了 3 个不同时刻的人体侧影;子图(d)是侧影归一化的效果,垂线表示人体中轴线;子图(e)是侧影对齐示意图。

侧影提取采用的是简单背景去除法^[13]。由于人体的场景深度关系,提取的侧影大小并不一致,所以在侧影提取完毕之后需要对其进行归一化处理。方法描述如下:首先将所有侧影缩放为统一高度;然后计算人体重心并得到人体纵向中轴线;最后将侧影中轴线对齐,如图 2(e)所示。

假设符号 $P(x, y, t)$ 表示坐标位置 (x, y) 的采样序列。为了降低各帧噪声对识别率的影响,首先对 $P(x, y, t)$ 进行高斯滤波

$$P_c(x, y, t) = P(x, y, t) * G_\sigma(t) \quad (1)$$

式中 $G_\sigma(t)$ 代表高斯核。然后,将 $P_c(x, y, t)$ 零均值化以求去除信号功率谱中的直流分量

$$P_z(x, y, t) = P_c(x, y, t) - \frac{1}{T} \sum_{t=0}^T P_c(x, y, t) \quad (2)$$

式中, T 表示步态序列的长度。




图 2 侧影对齐示意图

Fig. 2 Illustration for silhouette alignment

我们通过 DFT (discrete Fourier transform) 得到信号功率谱。由于步态序列的长度 T 各不相同,需要对它们的功率谱进行线性插值运算以求在不同频点的数据一一对应。在某些特殊情况下,步态序列的采样率也会不同,因此还需要在功率谱的末端增加一系列的零来保证不同步态序列拥有相同的样点个数。在经过线性插值和尾部加零的处理之后,功率谱信号才能够统一地分布在频段 $(0, f_{\max})$ 之内,这里 f_{\max} 等于序列最大采样率的 $1/2$ 。注意,对于采样率小于 $2f_{\max}$ 的序列,必须在 PCA 之前进行尾部加零处理,将其频率范围扩展为 $(0, f_{\max})$ 。

1.2 PCA 训练

PCA 训练集合是训练步态库中所有步态的所有坐标位置上的功率谱集合。假设训练步态库中的步态个数为 N_{PCA} ,步态图像包含 L 个像素点,那么 PCA 的训练集合可以表示为 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ 。这里 \mathbf{x}_i 是 1.1 节所介绍的经过处理的信号功率谱, $n = L \times N_{\text{PCA}}$ 。矢量 \mathbf{x}_i 的维数是 d ,等于功率谱中的采样点个数。

首先计算训练集合 \mathbf{X} 的散射矩阵 \mathbf{S} :

$$\mathbf{S} = \sum_{i=1}^n (\mathbf{x}_i - \mathbf{m})(\mathbf{x}_i - \mathbf{m})^T \quad (3)$$

式中, $m = \frac{1}{n} \sum_{i=1}^n x_i$ 。然后通过以下公式得到各功率谱的周期特征矢量

$$y_k = [e_1, e_2, \dots, e_{d_1}]^T x_k \quad (4)$$

式中, d_1 是矢量 y_k 的维数, $d_1 \ll d$ 。而 $[e_1, e_2, \dots, e_{d_1}]$ 是由散射矩阵 S 的前 d_1 个最大特征值所对应的特征向量所构成的。 d_1 的大小取决于散射矩阵 S 的特征值分布情况。假设 $\{l_1, l_2, \dots, l_d\}$ 是散射矩阵 S 的所有特征值, 并且按照由高到低的顺序排列, 那么参数 d_1 根据以下准则来决定:

$$W_{d_1} = \sum_{i=1}^{d_1} l_i / \sum_{i=1}^d l_i > T_s \quad (5)$$

这里 T_s 是阈值。在变换矩阵 $[e_1, e_2, \dots, e_{d_1}]^T$ 确定之后, 根据式(4)将所有的功率谱转换为周期特征矢量。

1.3 步态序列的 PFV 形式

经历了 DFT 与 PCA 之后, 步态序列中的任意点均可以用周期特征矢量 y_k 表示。因为 y_k 的维数远远小于原步态序列的长度, 所以步态的 PFV 形式可以节省大量的数据存储空间。步态的 PFV 形式是一种矢量图, 它可以分解为 d_1 个子图, 它的第 i 维子图就是该步态的所有周期特征矢量的第 i 维数据的集合。为了提供更为直观的认识, 这里将步态 PFV 形式的各维子图以灰度形式表示出来, 如图 3 所示。作为比较, 同时还给出了步态的均值图 (GEI)。从




图 3 步态均值图与步态 PFV 形式的比较示意图

Fig. 3 Gait energy image versus gait PFV representation

图中可以看出, 步态的 PFV 形式的每 1 维分别代表不同的步态周期性特征, 而 GEI 仅包含步态的各点能量。




图 4 对 PFV 各维数据的理解示意

Fig. 4 An explanation of dimensions of PFV representation

为了更好地理解步态 PFV 形式的各维特性, 我们给出一个更为形象的解释, 如图 4 所示。步态中拥有相同周期特性的点以集合的形式圈了起来, 例如, 背景区域、脚的摆动区域、手臂的摆动区域和身体的摆动区域等。根据 PCA 的性质, 拥有最大协方差的方向 (即图中标记为 D1 的直线方向) 成为步态 PFV 形式的第 1 维。同理, 直线 D2, D3 的方向对应着步态 PFV 形式的第 2 维和第 3 维。根据实验中 PCA 运算所求得特征值分布情况 (第 1 个特征值占据了总能量的近 70%; 第 2 个特征值所占据的总能量份额相对小很多, 只有 7.5% 左右; 而接下来的几个特征值缓慢减小, 直到接近于零), 步态 PFV 形式的第 1 维表示前景与背景之间的差异, 而余下各维分别表示人体各部位之间的运动差异, 如手臂、腿和躯干之间的摆动差异。

2 形态特征提取

2.1 矢量图的散射矩阵

设 $G = \{g_1, g_2, \dots, g_n\}$ 为训练步态集合, 其中 n 是训练步态的个数, g_k 是训练库中第 k 个步态的 PFV 形式 (矢量图), g_k 是以周期特征矢量 y_k 为行向量的 $L \times d_1$ 的矩阵, L 和 d_1 分别表示矢量图的大小与周期特征矢量的维数。 g_k 的第 i 维数据在这里指矢量图中第 i 个像素点所对应的周期特征矢量。

$\mathbf{g}_k (k=1,2,\dots,n)$ 的第 i 维数据与第 j 维数据之间的协方差值计算方法 (如图 5 所示)。图中 $y_{k,i}$ 和 $y_{k,j}$ 分别是 \mathbf{g}_k 的第 i 维与第 j 维数据; 而 $E[y_i]$ 和 $E[y_j]$ 表示所有训练步态第 i 维与第 j 维数据的期望值。协方差值计算如下:

$$\text{cov}(i,j) = \sum_{k=1}^n |y_{k,i} - E[y_i]| \cdot |y_{k,j} - E[y_j]| \cdot \cos \theta \quad (6)$$

式中, $|y_{k,i} - E[y_i]|$ 和 $|y_{k,j} - E[y_j]|$ 分别表示矢量 $(y_{k,i} - E[y_i])$ 和 $(y_{k,j} - E[y_j])$ 的长度; 而 θ 表示两矢量之间的夹角。式(6)可以改写成矩阵形式

$$\text{cov} = \sum_{k=1}^n (\mathbf{g}_k - \mathbf{m}) (\mathbf{g}_k - \mathbf{m})^T \quad (7)$$

式中, \mathbf{g}_k 和 \mathbf{m} 均是 $L \times d_1$ 的矩阵, 而 $\mathbf{m} = \frac{1}{n} \sum_{k=1}^n \mathbf{g}_k$ 表示所有矢量图的均值。在 2.2 节中, 所有散射矩阵的计算 (包括 PCA 和 LDA) 均基于式(7)所提供的矩阵进行运算。




图5 矢量图第 i 维与第 j 维之间的协方差计算方法

Fig.5 An illustration of calculating the covariance between dimension i and j of vector images

2.2 PCA + LDA 的联合形态分析

为了取得最佳的识别效果, 采用 PCA + LDA 的联合方式^[19]来提取人体形态特征。首先需要有一个训练步态库, 用 $\mathbf{G} = \{\mathbf{g}_1, \mathbf{g}_2, \dots, \mathbf{g}_n\}$ 来表示, 其中 n 是训练步态库中的步态个数, \mathbf{g}_k 是训练库中第 k 个步态的矢量图, \mathbf{g}_k 是 $L \times d_1$ 的矩阵, 而 L 和 d_1 分别表示矢量图的大小与 PFV 的维数。根据式(7), 首先构建 PCA 的散射矩阵

$$\mathbf{S} = \sum_{k=1}^n (\mathbf{g}_k - \mathbf{m}) (\mathbf{g}_k - \mathbf{m})^T \quad (8)$$

式中, $\mathbf{m} = \frac{1}{n} \sum_{k=1}^n \mathbf{g}_k$ 是 $\mathbf{g}_k (k=1,2,\dots,n)$ 的均值。

通过计算以上散射矩阵的特征值与特征向量, 得到 PCA 的变换矩阵 $\mathbf{M}_{\text{PCA}} = [\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_{d_2}]^T$, 这里 $d_2 \ll L$ 。将 $\mathbf{g}_k (k=1,2,\dots,n)$ 变换到对应特征子空间内, 通过下式

$$\mathbf{h}_k = \mathbf{M}_{\text{PCA}} \mathbf{g}_k \quad (9)$$

式中, $\mathbf{h}_k (k=1,2,\dots,n)$ 是 $d_2 \times d_1$ 维的矩阵。假设 $\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_n$ 属于 c 个不同类别 (个体), LDA 的目的就是找到一个变换矩阵 \mathbf{W} 使 $J(\mathbf{W})$ 最大化,

$$J(\mathbf{W}) = \frac{|\mathbf{W}^T \mathbf{S}_B \mathbf{W}|}{|\mathbf{W}^T \mathbf{S}_W \mathbf{W}|} \quad (10)$$

式中, \mathbf{S}_B 是各类之间的散射矩阵, 而 \mathbf{S}_W 是各类的内部散射矩阵。

各类的内部散射矩阵 \mathbf{S}_W 计算如下:

$$\mathbf{S}_W = \sum_{i=1}^c \mathbf{S}_i \quad (11)$$

式中, $\mathbf{S}_i = \sum_{h \in D_i} (\mathbf{h} - \mathbf{m}_i) (\mathbf{h} - \mathbf{m}_i)^T$, $\mathbf{m}_i = \frac{1}{n_i} \sum_{h \in D_i} \mathbf{h}$ 。 D_i 是第 i 类步态的集合, n_i 是该集合中步态序列的个数。

各类之间的散射矩阵 \mathbf{S}_B 计算如下:

$$\mathbf{S}_B = \sum_{i=1}^c n_i (\mathbf{m}_i - \mathbf{m}) (\mathbf{m}_i - \mathbf{m})^T \quad (12)$$

式中, $\mathbf{m} = \frac{1}{n} \sum_{h \in D} \mathbf{h}$ 。为了使得 $J(\mathbf{W})$ 最大化, 矩阵 \mathbf{W} 的列向量必须为根据下式所求得的广义特征向量:

$$\mathbf{S}_B \mathbf{w}_i = \lambda_i \mathbf{S}_W \mathbf{w}_i \quad (13)$$

式(13)最多存在 $(c-1)$ 个非零特征值, 它们对应的特征向量 $\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_{c-1}$ 构成了 LDA 的变换矩阵

$$\mathbf{z}_k = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_{c-1}]^T \mathbf{h}_k = \mathbf{M}_{\text{mda}} \mathbf{h}_k \quad (14)$$

对于任意的步态矢量图 \mathbf{g}_k , 可以使用 \mathbf{M}_{PCA} 和 \mathbf{M}_{mda} 将其转换为步态特征矢量

$$\mathbf{z}_k = \mathbf{M}_{\text{mda}} \mathbf{M}_{\text{PCA}} \mathbf{g}_k \quad (15)$$

在形态特征提取过程当中, 步态数据的空间维数首先经过 PCA 从 L 降低到 d_2 , 然后再经过 LDA 从 d_2 降低到 $(c-1)$, 而步态数据的时间维数一直保持为 d_1 。所以, 在经历了连续的空时特征提取之后, 步态特征矢量是 $(c-1) \times d_1$ 的矩阵。接下来, 利用步态特征矢量来对个体进行识别。

2.3 个体识别

对步态功率谱信号进行 PCA 训练, 得到变换矩阵 \mathbf{M} , 并将所有步态序列转换成步态矢量图; 对所有的步态库序列进行形态特征分析, 得到变换矩阵 \mathbf{M}_{PCA} 和 \mathbf{M}_{mda} 。对于任何测试步态:

1) 计算步态各点位置的功率谱, 见 2.1 节;

2) 使用矩阵 M 将步态每点的功率谱转换为周期特征矢量, 见式(4);

3) 利用 M_{PCA} 和 M_{mda} 计算步态特征矢量(GFV), 见式(15);

4) 计算测试步态的 GFV 与库中标准步态的 GFVs 之间的欧氏距离:

$$D(z_i, z_j) = \sqrt{\sum_{m=1}^{c-1} \sum_{n=1}^{d_1} (z_i^{m,n} - z_j^{m,n})^2} \quad (16)$$

式中, z_i 代表测试步态的 GFV, z_j 代表库中标准步态的 GFV, $z_i^{m,n}$ 和 $z_j^{m,n}$ 分别是矩阵 z_i 和 z_j 在位置 (m, n) 处的输入值。

步态数据库中存在 c 个类(个体)。将观测步态 z_i 分配给第 k 类, 如果它满足

$$i = \arg \min_{j \in D_k} (D(z_i, z_j)) \quad (17)$$

式中, D_k 是属于第 k 类的所有步态集合。

3 实验与分析

3.1 数据与参数

实验数据来源于 USF HumanID 步态数据库^[13]。该数据库包含 5 种影响因子: 视角(L/R)、两种鞋子类别(A/B)、地表类型(G/C)、负重(BF/NB)和拍摄时间(t1/t2)。我们可以采用以上 5 种因子的任何一种组合形式作为实验的标准步态, 然后采用这些因子的其他组合形式作为实验的测试步态。在本实验中, 标准的步态形式为(G, A, R, NB, t1)。我们设计了 12 种其他组合(以 A—L 表示)作为实验的测试步态来验证本文方法的性能。这 12 种组合的具体形式见表 1 第 2 列; 其对应的步态个体数见表 1 第 3 列; 其组合形式与标准步态的差异见表 1 第 4 列。

在 USF 步态数据库中共有 122 种步态类别(class), 每个类别均对应该数据库中的一个注册人物(individual), 而每个人物则至少包含一个或多个步态序列。其中, 每一个步态序列均对应一种不同的因子组合, 所以每个人物最多可能拥有 13 个步态序列(gallery + A—L)。在训练期间, 数据库中所有的步态序列均参与了训练, 所以变换矩阵 M_{PAC} 和 M_{mda} 包含了该数据库最完整的分类信息。在识别过程中, 将因子组合为(G, A, R, NB, t1)的个体序列作为识别的标准序列(gallery), 而将因子组合为 A—L 的序列作为识别所用的测试序列(probe)。

表 1 在 USF 步态数据库上设计的 12 种个体识别实验

Tab. 1 Twelve experiments designed for individual recognition in USF humanID gait database

编号	观测步态		人物个数	步态差异
	(地表, 鞋, 视角, 负重, 时间)			
(C/G, A/B, L/R, NB/BF, t1/t2)				
A	(G, A, L, NB, t1)		122	V
B	(G, B, R, NB, t1)		54	S
C	(G, B, L, NB, t1)		54	S + V
D	(G, A, R, NB, t1)		121	F
E	(C, B, R, NB, t1)		60	F + S
F	(C, A, L, NB, t1)		121	F + V
G	(C, B, L, NB, t1)		60	F + S + V
H	(G, A, R, BF, t1)		120	B
I	(G, B, R, BF, t1)		60	S + B
J	(G, A, L, BF, t1)		120	V + B
K	(G, A/B, R, NB, t2)		33	T + S
L	(C, A/B, R, NB, t2)		33	F + T + S

注: V—视角, S—靴子, F—地表, B—包, T—时间。

实验前需要确定以下 2 个参数: 周期特征矢量 PFV 的维数 d_1 (1.2 节) 以及 2.2 节中 PCA 的散射矩阵 S 的主分量个数 d_2 。 d_1 可以根据式(5)来决定, 实验中的阈值 T_s 为 0.9; d_2 的大小关系到式(13)的求解, 如果 $d_2 < c$ 或 $d_2 \gg c$ 都会导致式(13)中的 S_w 矩阵不可逆, 我们选择 $d_2 = 2c$, 这里 c 是步态库中个体的个数。

3.2 性能评估

我们在图 6 中给出了 3 个不同个体在步态库中的注册步态以及它们所对应的观测步态(观测步态 A—L)的 PFV 形式。注: 这里只列举了前 3 维的数据, 而 PFV 的具体维数由公式(5)来决定。从图中可以看出, 每 1 维的数据都代表一种不同的运动周期分布情况, 而不同人之间的步态 PFV 形式存在较大的差异。

我们将本文算法与另外两种算法(Baseline 算法^[13]和 GEI 算法^[17])进行了比较, 其实验结果如表 2 所示。这里, 识别率是以 Rank1 和 Rank5 的形式表示的, Rank1 识别率指的是: 对于任何观测步态以及在步态库中与该观测步态匹配度最高的注册步态, 如果它们属于相同的个体, 则识别算作成功; 同理 Rank5 识别率指的是: 对于任何观测步态以及在步态库中与该观测步态匹配度最高的前 5 个注册步态, 如果这 5 个注册步态中有任何一个与观测步态属于相同的个体, 则识别算作成功。

表 2 Baseline 算法、GEI 算法和本文算法的 Rank1 和 Rank5 识别率

Tab.2 The Rank1 and Rank5 results of Baseline method, GEI real template and our method

		CCR/%											
		A	B	C	D	E	F	G	H	I	J	K	L
RANK1	Baseline 算法	73	78	48	32	22	17	17	61	57	36	3	3
	GEI 算法	89	87	78	36	38	20	28	62	59	59	3	6
	本文算法	92	90	83	58	51	28	34	67	64	63	6	18
RANK5	Baseline 算法	88	93	78	66	55	42	38	85	78	62	12	15
	GEI 算法	93	93	89	65	60	42	45	88	79	80	6	9
	本文算法	96	94	92	83	78	61	52	91	88	87	15	23

从实验结果可以看出,本文算法的识别率较 Baseline 算法和 GEI 算法均有明显提升。Baseline 算法因为采用了自相关算法来进行序列匹配,因此它假设所有步态的周期必须一致,而实际上不同个体之间的周期是难以保证一致的。另外,图像噪声很可能会导致步态图像帧与帧之间的形态特征匹配出现较大的误差。GEI 算法虽然也采用了压缩的方法将步态序列表示为步态均值图,但是步态均值图丢失了过多的人体动态特征,特别是周期性的变化特征。从图 6 可以看出,步态均值图中灰度相当的位置在步态的 PFV 形式中有着不同的周期特征值。




图 6 3 个不同个体的步态 PFV 形式的前 3 维,其中包括标准序列以及 A ~ L 的测试序列

Fig.6 The first three dimensions of PFV representation of three individuals in the gallery set and their corresponding sequence in probe set A ~ L

最后, PCA + LDA 的特征分类算法在减小了同类步态之间特征差异的同时又增加了异类步态之间的特征差异, 因此相较于 Baseline 算法所使用的 K-nearest 分类方法本文方法的正确识别率有了很大提升。

步态序列的 PFV 形式不仅能够节省大量的数据存储空间, 而且其计算量要求较其他类别的步态识别方法也要低很多。以一个长度为 120 帧的步态序列为例, 如果我们只保留 PFV 的前 5 维数据, 那么步态的 PFV 形式相对于原始序列则可以节省高达 96% 的数据存储空间。而通常情况下, PFV 的前 5 维数据就已经包含了足够的步态空时特征信息。在计算量方面, 由于本文方法在步态特征提取期间不需要对每一帧图像都进行特征提取, 因此本文方法的特征提取计算量较传统方法要小很多。同样以长度为 120 帧的步态序列为例, 序列中图像大小为 128×88 , 我们在 CPU 主频为 2.8 GHz 的计算机上提取该序列的 PFV 形式用时约为 700 ms。而如果对序列中的每一帧图像都进行特征提取, 即使使用最简单的细化骨架算法来进行步态特征提取, 平均每帧图像消耗的时间约为 200 ms, 整个序列所消耗的时间为 24 s。由此可见, 采用先时间后空间的数据压缩方式能够节省大量的特征提取计算量。在特征匹配期间, 本文方法计算的是测试步态特征矢量与标准步态特征矢量之间的欧氏距离, 其计算复杂度为 $O(c \cdot d_1)$, 其中 c 表示步态的空间特征维数, d_1 表示步态的时间特征维数 (见公式 (16))。Baseline 算法则需要进行特征序列的自相关匹配, 其计算复杂度为 $O(cLL)$, 其中 c 表示步态空间特征维数, L 表示序列长度。假设两种方法所使用的步态空间特征维数相同, 那么自相关算法进行特征匹配的计算复杂度是本文方法的 L^2/d_1 倍。

4 结 论

介绍一种全新的基于步态空时数据特征提取的人体识别方法。该方法采用两次连续的特征子空间学习, 依次对步态数据的时间特征以及空间特征进行提取, 最终得到步态特征矢量。步态特征矢量既包含人体的周期运动特征又包含人的形态特征, 因此具有较高的识别能力, 同时以周期特征矢量的形式来表示步态还能节省大量的数据存储空间以及计算量。实验结果表明, 所提出的方法鲁棒性较高且

实现简单, 与其他同类方法相比具有很强的竞争力。我们相信, 该方法在未来的步态识别系统中将会有巨大的应用价值。

参考文献 (References)

- [1] Gavrilu D. The visual analysis of human movement: a survey [J]. Computer Vision and Image Understanding, 1999, 73(1): 82-98.
- [2] Nixon M S, Carter J N. Advances in automatic gait recognition [C]//Proc. Int. Conf. Automatic Face and Gesture Recognition. Washington: IEEE Press, 2004: 139-146.
- [3] Boulgouris N V, Hatzinakos D, Plataniotis K N, Gait recognition: a challenging signal processing technology for biometric identification [J]. IEEE Signal Processing Magazine, 2005, 22(6): 78-90.
- [4] Turk M, Pentland A. Face recognition using eigenfaces [C]//Proc. Int. Conf. Computer Vision and Pattern Recognition. Washington DC, USA: IEEE Press, 1991: 586-591.
- [5] Jain A K, Hong L, Pankanti S, et al. An identity verification system using fingerprints [C]//Proc. IEEE. Washington DU, USA: IEEE Press 1999, 85(9): 1365-1388.
- [6] Daugman J G. High confidence visual recognition of persons by a test of statistical independence [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1993, 15(11): 1148-1161.
- [7] Qi Y, Hunt B R. A multiresolution approach to computer verification of handwritten signatures [J]. IEEE Transactions Image Processing, 1995, 4(6): 870-874.
- [8] BenAbdelkader C, Cutler R, Davis L. Stride and cadence as a biometric in automatic person identification and verification [C]//Proc. Int. Conf. Automatic Face and Gesture Recognition. Washington, DC, USA: IEEE Press, 2002: 372-377.
- [9] Cunado D, Nixon M S, Carter J N, Automatic extraction and description of human gait models for recognition purposes [J]. Computer Vision and Image Understanding, 2003, 90(1): 1-41.
- [10] Wang L, Tan T N, Ning H, et al. Silhouette analysis-based gait recognition for human identification [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003, 25(12): 1505-1518.
- [11] Vega I R, Sarkar S. Statistical motion model based on the change of feature relationships; human gait-based recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003, 25(10): 1323-1328.
- [12] Veeraraghavan A, Roy-Chowdhury A, Chellappa R. Role of shape and kinematics in human movement analysis [C]//Proc. Int. Conf. Computer Vision and Pattern Recognition. Washington DC, USA: IEEE Press, 2004: 730-737.
- [13] Sarkar S, Phillips P J, Liu Z, et al. The human ID gait

- challenge problem: data sets, performance, and analysis [J]. IEEE Transactions Pattern Analysis and Machine Intelligence, 2005, 27(2): 162-177.
- [14] Veeraraghavan A, Chowdhury A R, Chellappa R. Matching shape sequences in video with applications in human movement analysis [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(12): 1896-1909.
- [15] Sundaresan A, Chowdhury A R, Chellappa R, A hidden Markov model based framework for recognition of humans from gait sequences[C]//Proc. Int. Conf. Image Processing. Washington DC, USA; IEEE Press, 2003: 143-150.
- [16] Bobick A F, Davis J W. The recognition of human movement using temporal templates [J]. IEEE Transaction on Pattern Analysis and Machine Intelligence, 2001, 23(3): 257-267.
- [17] Han J, Bhanu B. Individual recognition using gait energy image [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(2): 316-322.
- [18] Jolliffe I. Principal Component Analysis [M]. Berlin, German. Springer Verlag, 1986.
- [19] Huang P S, Harris C J, Nixon M S. Recognizing humans by gait via parameteric canonical space [J]. Artificial Intelligence in Eng. , 1999, 13: 359-366.