

基于步态能量图像和2维主成分分析的步态识别方法

王科俊 刘丽丽 贲晓烨 陈薇

(哈尔滨工程大学自动化学院, 哈尔滨 150001)

摘要 为了快速有效地进行步态识别, 针对步态能量图像能够表征步态信息和2维主成分分析能快速降维的特点, 提出了一种基于步态能量图像和2维主成分分析的步态识别方法。该方法首先应用背景减除法分割出人体轮廓, 然后通过人体宽高比的相关信号确定运动周期, 再对二值周期序列进行步态能量图像(GEI)合成; 最后运用行列相结合的2维主成分分析((2D)²PCA)方法与加权的2维主成分分析(W(2D)²PCA)方法提取特征主向量, 并采用最近邻分类器进行分类。实验结果表明, 该步态识别方法可以有效降低前期处理对分类识别的影响, 而且对于3种不同行走状态的CASIA数据库中多个视角下拍摄的步态图像可取得很好的识别效果。

关键词 步态识别 步态能量图像 2维主成分分析 行列相结合的2维主成分分析 加权的2维主成分分析
中图法分类号: TP391.41 文献标识码: A 文章编号: 1006-8961(2009)12-2503-07

Gait Recognition Based on Gait Energy Image and Two Dimensional Principal Component Analysis

WANG Ke-jun, LIU Li-li, BEN Xian-ye, CHEN Wei

(College of Automation, Harbin Engineering University, Harbin 150001)

Abstract In order to carry on the gait recognition fast and effectively, aiming at the characteristics that gait energy image can view the information of gait and two dimension principal component analysis can reduce the dimensions quickly, a novel gait recognition based on gait energy image and two dimension principal component analysis is proposed in this paper. Firstly, the body silhouette extraction is achieved by background subtraction. Secondly, a gait cycle is obtained with the correlated signal of the ratio of width and height of human body. Gait energy image is applied on the binary image sequence to construct the feature vector. Finally, (2D)²PCA and W(2D)²PCA is used to reduce into a low dimension space. The nearest-neighbor classifier is adopted to distinguish the difference. This gait recognition method can decrease the influence of the early preprocess effectively, and our experimental results demonstrate that the method is effective and has achieved a good recognition effect on CASIA gait database including three different multi-views.

Keywords gait recognition, gait energy image, two dimensional principal component analysis, (2D)²PCA, W(2D)²PCA

1 引言

步态是指人们行走的姿势, 是一种远距离情况下唯一可感知的生物行为特征。它是通过人步行的

姿态来达到识别人身份的目的。是近年来计算机视觉和生物特征识别领域的一个备受关注的研究方向。与其他生物特征识别技术(例如指纹, 人脸等)相比, 步态识别的优势在于其具有非接触性、非侵犯性、易于感知、难于隐藏、难于伪装等特点。

基金项目: 国家高技术研究发展计划(863)项目(2008AA01Z148); 黑龙江省杰出青年科学基金项目(JC200703)

收稿日期: 2008-07-09; 改回日期: 2008-11-06

第一作者简介: 王科俊(1962~), 男, 教授。1995年于哈尔滨工程大学获船舶与海洋特辅装置与系统专业博士学位。现主要的研究方向为模式识别、神经网络。E-mail: heukejun@sohu.com

它在虚拟现实、视觉监控、感知接口、门禁系统、安全监控、人机交互、医疗诊断^[1]等领域具有广泛的应用前景和经济价值,因此激发了国内外广大科研工作者的研究热情。

文献[1]从运动检测、周期检测、特征提取、识别算法 4 个方面对当前的研究成果进行了全面的综述。在步态特征提取方法的研究中,近年来涌现出大量可以借鉴的、有意义的工作,例如速度矩^[2]、隐马尔可夫模型^[3]、Procrustes 形状分析^[4]、主成分分析(principal component analysis, PCA)^[5-6]、正则分析(canonical analysis)^[6]、对称性分析^[7]以及各种基于运动学和动力学的模型^[8-10]等方法。

不同于上述方法,本文提出了一种基于步态能量图像(GEI)和行列方向结合的 2 维主成分分析((2D)²PCA), GEI 和加权 2 维主成分分析(W(2D)²PCA)相结合来进行特征提取的方法,即将 2 维主成分分析(2DPCA)方法用于步态识别的特征降维中,首先应用背景减除法分割出人体轮廓;然后通过人体宽高比的相关信号确定运动周期;接着对二值周期序列进行 GEI 合成,并运用(2D)²PCA 方法与 W(2D)²PCA 方法相结合来提取特征主向量;最后采用最近邻分类器进行分类。实验结果表明,在 3 种不同行走状态的 CASIA 数据库中,对多个视角下的步态图像进行识别,均取得很好的识别效果。

2 步态图像序列的预处理

实际采集的图像由于受到各种干扰因素的影响,往往存在噪声、对比度不足等缺陷,因此必须对图像进行预处理。图像预处理是特征提取与识别的先要条件,本文主要通过以下几个步骤来提取目标轮廓图像:

(1)背景重建 由于场景在整个视频序列中近似静止,且背景对应低频信息,因此可以用序列图像中像素的平均值来估计静止背景。

(2)运动目标检测 背景减除法用来检测图像序列中的运动目标,并采用最大熵阈值法对图像进行二值化处理。

(3)形态学后处理 对于二值化后的图像,再采用形态学膨胀与腐蚀算子去除噪声点和处理图像中的小空洞,最后用连通分析和贴标签的方法分隔出完整的目标。

(4)二值图像的规一化与中心化 为降低计算

复杂性、去除冗余信息,以及消除由摄像机焦距变化带来的人体侧影大小不统一的影响,本文对目标侧影图像进行了规一化处理,使图像缩放到统一大小。

3 周期检测

步态是周期性的时变数据,从人体侧影图像序列可以看出,它的宽度会经过一个周期性的变化过程。当人处于站立姿态时,宽度最小,而处于双腿分开、共同支撑姿态时,宽度最大,依此周而复始。同时由于在走路过程中,人体的高度也会随姿态的不同而有微小变化,因此本文采用侧影的宽高比^[11]对步态的周期进行分析来得到完整的步态周期图像序列。

4 特征提取

4.1 步态能量图

步态特征蕴含在人的行走过程中,其中包括人的行走频率相位、驱赶倾斜度、脚踝变化、胳膊摆动的不同等等,所以通常只有从一个周期序列图像中提取出来的步态特征,才可以表征一个人的步态特点。但是,在进行步态识别时,必须面临一个实质性的问题,即数据量过于庞大的问题。而数据量过大则将直接导致步态特征提取度复杂、运算时间过长等问题。因此,既要减小步态图像的数据量,同时又要尽量不抛弃步态特征,是选取步态特征需考虑的问题。

步态能量图像就能很好地解决这个问题,因为它能利用加权平均的简单步骤将一周步态图像合成为一幅图像,这幅图像既保留了轮廓、频率、相位等步态信息,又可将步态数据量减少到了原来的几十分之一。在此基础上,针对步态能量图像再采取统计分析方法(如 PCA 方法)即可进一步对步态数据进行降维,并提取步态能量特征。

对于给定的二值步态周期图像序列 $B_t(x, y)$, GEI^[12]的定义如下:

$$G(x, y) = \frac{1}{N} \sum_{t=1}^N B_t(x, y) \quad (1)$$

其中, N 是完整步态周期序列的长度, t 代表时间, x, y 代表 2 维图像像素点的平面坐标。

对周期序列图像执行式(1)运算,产生的 GEI 如图 1 所示。



图 1 GEI 图像
Fig. 1 GEI image

4.2 2 维主成分分析

传统的 PCA 和 LDA 方法在进行图像识别时,都是基于图像向量的,在这种识别技术中,2 维的图像矩阵必须先转变为 1 维图像向量,然后再进行 PCA 或 LDA 分析。其缺点很明显:首先,由于将图像矩阵转化为图像向量后,其形成的图像向量的维数一般较高,从而使得整个特征抽取过程所耗费的计算量相当可观。

2 维主成分分析,也叫广义主成分分析,是一种直接基于图像矩阵的包含在类平均图像中的判别信息的最优压缩技术。与 PCA 算法的不同之处在于,2DPCA 算法是以图像矩阵为分析对象;而 PCA 算法则是以图像的 1 维向量为分析对象。因此,2DPCA 算法在图像特征提取之前不必通过降维来构造图像的协方差矩阵,而是直接利用图像矩阵来计算图像协方差矩阵的特征向量。(2D)²PCA 方法在识别性能上与 2DPCA 算法相当,但能大大减少计算时间。

4.2.1 2 维主成分分析算法

考虑一个大小为 $m \times n$ 的图像 A ,其投影矩阵为 $X \in \mathbf{R}^{n \times d}$ ($n \geq d$),将图像矩阵 A 投影到 X ,将产生一个 $m \times d$ 大小的矩阵,即

$$Y = AX \quad (2)$$

X 为投影轴(即投影矩阵), Y 称为图像 A 的投影特征向量。最佳投影轴 X 可以根据特征向量 Y 的散布情况来决定。在 2DPCA 方法中,可用投影后向量的总离散度作为准则函数 $J(X)$ 来衡量投影矩阵 X 的优劣,采用的准则如下:

$$J(X) = \text{tr}\{S_x\} \quad (3)$$

其中, S_x 表示训练样本投影特征向量 Y 的协方差矩阵, $\text{tr}\{S_x\}$ 代表 S_x 的迹^[13],当准则(式(3))取得最大值时,它的物理意义是:找到一个将所有训练样本投影到投影轴 X ,使得投影后所得特征向量的总体散布矩阵(即样本类间散布矩阵)最大化。矩阵 S_x 的迹可以记为

$$\begin{aligned} \text{tr}\{S_x\} &= \text{tr}\{E[(Y - EY)(Y - EY)^T]\} \\ &= \text{tr}\{E[AX - E(AX))(AX - E(AX))^T]\} \end{aligned}$$

$$= \text{tr}\{X^T E[(A - EA)^T(A - EA)]X\} \quad (4)$$

定义图像的协方差矩阵为

$$G = E[(A - EA)^T(A - EA)] \quad (5)$$

G 是一个 $n \times n$ 大小的非负正定矩阵。通常可以直接利用训练样本来计算 G 。假设有 M 幅 $m \times n$ 大小的测试样本图像 A_k ,其平均图像矩阵为 $\bar{A} = \frac{1}{M} \sum_{k=1}^M A_k$,那么 G 就可以被估计为

$$G = \frac{1}{M} \sum_{k=1}^M (A_k - \bar{A})^T(A_k - \bar{A}) \quad (6)$$

所以式(4)可以写成

$$J(X) = \text{tr}(X^T G X) \quad (7)$$

X 是归一正交化列向量(只有一个列向量时的投影矩阵)。这个式(7)的准则就叫做广义总体散布准则。而 X 就是使准则(式(7))最大化的最佳投影轴。其物理意义是:矩阵在轴上投影后所得特征向量的总体分散程度最大。

实际上,该最佳投影轴即为与图像总体散布矩阵的最大特征值对应的单位特征向量。总体而言,只选择一个最佳投影轴是不够的,通常要选取一系列的标准正交化投影轴。可以证明,准则函数 $J(X)$ 最大的 X 中的每个列向量是由与协方差矩阵 G 的 r 个非零特征值对应的前面最大的 d 个特征向量组成,即

$$X = (x_1, \dots, x_d) = \arg \max [J(X)] \quad (8)$$

满足 $x_i^T x_j = 0, i \neq j; i, j = 1, \dots, d$

4.2.2 图像的主成分向量和特征矩阵

在获得投影矩阵 $X = (x_1, \dots, x_d)$ 后,就可以对步态能量图像进行特征提取和分类,如给定一幅步态能量图像 A ,令

$$Y_k = AX_k \quad k = 1, \dots, d \quad (9)$$

则可以得到一组投影后的特征向量 Y_1, \dots, Y_d ,称为图像 A 的主成分向量。2DPCA 选取 d 个主成分向量可以组成一个 $m \times d$ 大小的矩阵,称为图像 A 的特征矩阵或特征图。

4.3 行列相结合的 2 维主成分分析

(2D)²PCA^[14],即两个方向上的 2 维主成分分析,(2D)²PCA 分为行方向上的 2DPCA 和列方向上的 2DPCA,结合行列方向上的 2DPCA 即可实现图像特征表征。2DPCA 方法在图像特征提取方面,优于传统的 PCA 方法,但它也有其弊端。假设图像大小是 64×64 ,那么需要 $64 \times k$ 个数据来表示图像,而为了满足精度要求,通常 k 要大于 5,这样至少需

要 320 个数据来表示图像。因此特征向量维数仍较高,其识别模块将影响匹配速度。(2D)²PCA 方法即是基于这一问题提出的解决办法,其在识别性能上与 2DPCA 方法相当,甚至优于 2DPCA 方法,但却能大大减少运算时间。

4.3.1 行方向上的 2DPCA

记 $\mathbf{A}_k = [(\mathbf{a}_k^{(1)})^T, (\mathbf{a}_k^{(2)})^T, \dots, (\mathbf{a}_k^{(m)})^T]^T$ 及 $\bar{\mathbf{A}} = [(\bar{\mathbf{a}}^{(1)})^T, (\bar{\mathbf{a}}^{(2)})^T, \dots, (\bar{\mathbf{a}}^{(m)})^T]^T$, 其中, $\mathbf{a}_k^{(i)}$ 和 $\bar{\mathbf{a}}^{(i)}$ 分别表示 \mathbf{A} 和 $\bar{\mathbf{A}}$ 的第 i 个行向量,那么式(6)可表示为

$$\mathbf{G}_i = \frac{1}{M} \sum_{k=1}^M \sum_{i=1}^m (\mathbf{a}_k^{(i)} - \bar{\mathbf{a}}^{(i)})^T (\mathbf{a}_k^{(i)} - \bar{\mathbf{a}}^{(i)}) \quad (10)$$

最优投影矩阵 \mathbf{X} 可以通过计算与式(10)的前 d 个较大特征值对应的特征向量得到。

4.3.2 列方向上的 2DPCA

按照式(10),若对图像行方向上的 2DPCA 进行扩展,则可使用图像列向量间的外积来重构 \mathbf{G}_i 。若记 $\mathbf{A}_k = [\mathbf{a}_k^{(1)}, \mathbf{a}_k^{(2)}, \dots, \mathbf{a}_k^{(m)}]$ 及 $\bar{\mathbf{A}} = [\bar{\mathbf{a}}^{(1)}, \bar{\mathbf{a}}^{(2)}, \dots, \bar{\mathbf{a}}^{(m)}]$, 这里 $\mathbf{a}_k^{(j)}$ 和 $\bar{\mathbf{a}}^{(j)}$ 分别表示 \mathbf{A}_k 和 $\bar{\mathbf{A}}$ 的第 j 个列向量,那么图像协方差矩阵 \mathbf{G}_i 的另一种定义为

$$\mathbf{G}'_i = \frac{1}{M} \sum_{k=1}^M \sum_{j=1}^n (\mathbf{a}_k^{(j)} - \bar{\mathbf{a}}^{(j)}) (\mathbf{a}_k^{(j)} - \bar{\mathbf{a}}^{(j)})^T \quad (11)$$

设 $\mathbf{Z} \in \mathbf{R}^{m \times q}$ 是列之间相互正交的矩阵,把随机图像矩阵 \mathbf{A} 投影到 \mathbf{Z} ,则可产生一个 $q \times n$ 大小的矩阵 $\mathbf{B} = \mathbf{Z}^T \mathbf{A}$,与式(4)相似,可以定义如下的散布矩阵:

$$\begin{aligned} J(\mathbf{Z}) &= \text{tr}\{E[(\mathbf{B} - \mathbf{E}\mathbf{B})(\mathbf{B} - \mathbf{E}\mathbf{B})^T]\} \\ &= \text{tr}\{E[(\mathbf{Z}^T \mathbf{A} - E(\mathbf{Z}^T \mathbf{A}))(\mathbf{Z}^T \mathbf{A} - E(\mathbf{Z}^T \mathbf{A}))^T]\} \\ &= \text{tr}\{\mathbf{Z}^T E[(\mathbf{A} - \mathbf{E}\mathbf{A})(\mathbf{A} - \mathbf{E}\mathbf{A})^T] \mathbf{Z}\} \quad (12) \end{aligned}$$

由式(12)可看出,协方差矩阵 \mathbf{G}_i 的另一种定义为

$$\begin{aligned} \tilde{\mathbf{G}}_i &= E[(\mathbf{A} - \mathbf{E}\mathbf{A})(\mathbf{A} - \mathbf{E}\mathbf{A})^T] \\ &= \frac{1}{M} \sum_{k=1}^M (\mathbf{A}_k - \bar{\mathbf{A}})(\mathbf{A}_k - \bar{\mathbf{A}})^T \\ &= \frac{1}{M} \sum_{k=1}^M \sum_{j=1}^n (\mathbf{a}_k^{(j)} - \bar{\mathbf{a}}^{(j)}) (\mathbf{a}_k^{(j)} - \bar{\mathbf{a}}^{(j)})^T \quad (13) \end{aligned}$$

相似地,最优投影矩阵 \mathbf{Z} 可以通过计算与式(13)的前 q 个较大特征值对应的特征向量而获得。

4.3.3 行列方向结合的 2DPCA

行方向上的 2DPCA 和列方向上的 2DPCA 分别只在图像的行方向和列方向上发挥作用,行 2DPCA

首先从一组训练图像中生成一个能反应图像行之间信息的最优投影矩阵 \mathbf{X} ,然后再将一个大小为 $m \times n$ 的图像 \mathbf{A} 投影到 \mathbf{X} 上,产生一个大小为 $m \times d$ 的矩阵 $\mathbf{Y} = \mathbf{A}\mathbf{X}$;相似地,列 2DPCA 也能先生成一个反应图像列之间信息的最优矩阵 \mathbf{Z} ,然后再将 \mathbf{A} 投影到 \mathbf{Z} 上产生一个大小为 $q \times n$ 的矩阵 $\mathbf{B} = \mathbf{Z}^T \mathbf{A}$ 。下面介绍一种能同时利用 \mathbf{X} 和 \mathbf{Z} 这两个投影矩阵的方法。

假设已经获得了投影矩阵 \mathbf{X} 和 \mathbf{Z} ,把大小为 $m \times n$ 的矩阵 \mathbf{A} 同时投影到 \mathbf{X} 和 \mathbf{Z} 上,则产生一个大小为 $q \times d$ 的矩阵 \mathbf{C}

$$\mathbf{C} = \mathbf{Z}^T \mathbf{A}\mathbf{X} \quad (14)$$

在用于步态识别时,矩阵 \mathbf{C} 称为特征矩阵,在把每幅训练图像 $\mathbf{A}_k (k = 1, 2, \dots, M)$ 投影到 \mathbf{X} 和 \mathbf{Z} 后,就可以得到训练图像的特征矩阵 $\mathbf{C}_k (k = 1, 2, \dots, M)$ 。

4.4 加权的 2 维主成分分析

尽管(2D)²PCA 方法减少了图像特征矩阵的大小,但(2D)²PCA 方法仍然平等对待了步态的每一维特征,而大量生理学的研究表明,在步态识别的过程中,各个肢体部分对识别的贡献程度不同。由于与不同的特征值对应的特征向量对识别的贡献是不同的,大的特征值所对应的特征向量对识别的贡献较大,因此本文对特征向量进行加权,以突出不同特征值所对应的特征向量对识别的贡献,并提出了加权的(2D)²PCA 算法——W(2D)²PCA。

加权策略如下:

$$\begin{aligned} \tilde{\mathbf{Y}} &= \mathbf{Y}\boldsymbol{\lambda} = [\lambda_1^\omega \mathbf{y}_1, \lambda_2^\omega \mathbf{y}_2, \dots, \lambda_d^\omega \mathbf{y}_d] \\ &= [\lambda_1^\omega \mathbf{A}\mathbf{x}_1, \lambda_2^\omega \mathbf{A}\mathbf{x}_2, \dots, \lambda_d^\omega \mathbf{A}\mathbf{x}_d] \\ &= [\mathbf{A}(\lambda_1^\omega \mathbf{x}_1), \mathbf{A}(\lambda_2^\omega \mathbf{x}_2), \dots, \mathbf{A}(\lambda_d^\omega \mathbf{x}_d)] \\ &= \mathbf{A}\mathbf{X}\boldsymbol{\lambda}^\omega \quad (15) \end{aligned}$$

其中, $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d$ 是式(6)中 \mathbf{G}_i 的前 d 个较大的特征值,其对应 \mathbf{G}_i 的特征向量 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_d$, $\boldsymbol{\lambda} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_d)$ 为 $\lambda_1, \lambda_2, \dots, \lambda_d$ 组成的对角阵, $0 < \omega < 1$ 为控制权值 $\lambda_i (i = 1, 2, \dots, d)$ 大小的因子,当 ω 太大或太小时,由于会搅乱各特征向量对识别结果的贡献,因而识别效果会变差。本文中,取 $\omega = 0.25$;

将式(15)代入式(14),得

$$\tilde{\mathbf{C}} = \mathbf{Z}^T \mathbf{Y} = \mathbf{Z}^T \mathbf{A}\mathbf{X}\boldsymbol{\lambda}^\omega \quad (16)$$

$\tilde{\mathbf{C}}$ 即为加权后的 2 维主成分矩阵。

5 实验与结果分析

为验证本文算法的步态识别效果,采用 CASIA 步态数据库的步态图像进行了不同方法的识别效果对比实验。

5.1 实验步骤

在实验的训练过程中,首先采用上面介绍的方法对步态序列图像进行预处理,获得二值序列图像;然后计算每个样本序列的步态能量图像,分别将每类的各个样本序列作为训练样本,并通过 $(2D)^2PCA$ 或 $W(2D)^2PCA$ 计算最优的映射矩阵。

在测试识别过程中,经过如同训练过程一样的侧影检测、步态特征提取等步骤,将每个测试样本的步态能量图像,转换到低维空间;最后采用最近邻来进行分类识别输出。实验框架如图 2 所示。

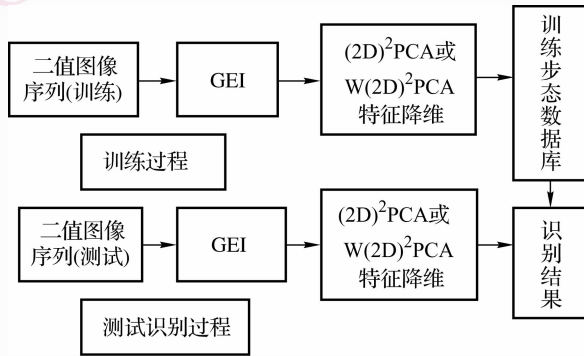


图 2 实验框架图

Fig. 2 Experiment frame chart

5.2 识别结果与对比实验

实验中,采用中国科学院自动化研究所提供的 CASIA 步态数据库,依次将数据库中每类不同的样本作为训练集,在 8 个不同视角的步态库中,分别进行训练识别。背包和外套变化步态库中,每人 2 个步态序列,分别对两个步态序列进行训练识别,其训练测试样本数均为 124。正常步态库中,每人 6 个步态序列,分别取其中一个步态序列作为训练集,其他的 5 个步态序列作为测试集,其训练样本数为 124,测试样本数为 620。采用最近邻分类器进行分类识别。在目标背包、外套变化和正常行走 3 种不同步态数据库中,当采用 $(2D)^2PCA$ 方法或加权的 $(2D)^2PCA$ 方法提取主向量时,各个视角下的步态识别率分别如表 1 ~ 表 3 所示。

表 1 各视角下背包数据库的识别率

Tab. 1 Under knapsack database various angles of view recognition rate

算法	序列号	不同视角下的识别率(%)							
		0°	36°	54°	72°	90°	108°	144°	180°
$(2D)^2PCA$	1	75.8	50.8	64.5	79.8	85.5	78.2	73.4	80.6
	2	70.9	53.2	66.1	77.4	83.8	77.4	73.4	83.1
	平均	73.4	52.0	65.7	78.6	84.6	77.8	73.4	81.8
$W(2D)^2PCA$	1	76.6	51.6	66.1	80.6	85.5	78.2	72.6	80.6
	2	74.1	52.4	65.3	79.0	83.0	77.4	72.6	81.4
	平均	75.4	52.0	65.7	79.8	84.2	78.1	72.6	81.5

表 2 各视角下外套变化数据库的识别率

Tab. 2 Under coat change database various angles of view recognition rate

算法	序列号	不同视角下的识别率(%)							
		0°	36°	54°	72°	90°	108°	144°	180°
$(2D)^2PCA$	1	80.6	58.8	72.6	87.1	89.5	85.5	82.2	91.1
	2	80.6	58.8	70.9	87.0	88.7	87.1	81.4	87.9
	平均	80.6	58.8	71.7	87.1	89.1	86.2	81.8	89.5
$W(2D)^2PCA$	1	82.2	58.0	71.7	89.5	91.1	84.6	79.8	91.1
	2	80.6	57.2	70.9	87.9	89.5	85.5	80.6	88.7
	平均	81.4	57.7	71.4	89.2	90.3	85.1	80.2	89.9

表 3 各视角下正常行走数据库的识别率

Tab. 3 Walks normally under the database various angles of view recognition rate

算法	序列号	不同视角下的识别率(%)							
		0°	36°	54°	72°	90°	108°	144°	180°
$(2D)^2PCA$	1	83.2	41.1	54.0	77.7	77.5	75.9	65.2	85.6
	2	86.4	41.6	57.9	83.2	81.4	81.4	70.2	87.7
	3	84.1	41.6	54.6	80.4	81.7	81.6	68.5	86.0
	4	85.8	44.1	55.0	83.2	82.7	79.0	67.9	87.1
	5	86.7	38.7	61.2	81.6	79.1	77.5	65.2	88.4
	6	85.3	44.1	56.7	81.6	81.1	75.0	69.2	86.6
平均	85.3	42.0	56.6	81.3	80.7	78.4	67.7	86.9	
$W(2D)^2PCA$	1	67.3	38.1	52.1	77.6	77.6	74.8	63.5	85.3
	2	74.5	39.4	55.8	84.2	81.1	79.5	70.0	88.4
	3	75.0	39.8	52.6	79.5	80.5	80.8	67.4	87.1
	4	76.9	42.6	53.1	83.4	83.2	77.9	68.1	86.3
	5	76.6	37.6	58.9	82.6	80.3	76.3	64.2	88.1
	6	76.5	39.8	54.2	81.8	80.9	74.0	68.1	86.0
平均	74.5	39.0	54.4	81.5	80.6	77.2	66.9	86.6	

分别采用 $(2D)^2PCA$ 方法和加权 $(2D)^2PCA$ 方法提取主向量时,在各个视角下3种不同步态数据库的步态图像的平均识别率曲线对比如图3所示;图中,红色曲线表示采用 $(2D)^2PCA$ 方法提取主向量时的平均识别率,蓝色曲线表示采用加权 $(2D)^2PCA$ 方法提取主向量时的平均识别率。各曲线的标识意义如下:

- cloth: 目标所穿外套变化 + $(2D)^2PCA$;
- bag: 目标背包 + $(2D)^2PCA$;
- normal: 目标正常行走状态 + $(2D)^2PCA$;
- wcloth: 目标所穿外套变化 + $W(2D)^2PCA$;
- wbag: 目标背包 + $W(2D)^2PCA$;
- wnormal: 目标正常行走状态 + $W(2D)^2PCA$ 。




图3 各步态库中不同视角步态图像的平均识别率曲线图
Fig. 3 Various gaits storehouse different angle of view average recognition rate diagram of curves

对于同一数据库,在训练和测试方法不变的情况下,将 $(2D)^2PCA$ 方法换成常用的特征提取算法——PCA和LDA做了对比实验,实验所得的平均识别率如表4所示。

表4 各视角下不同步态数据库的平均识别率

Tab. 4 Under different gait database various angles of view average recognition rate (%)

状态	算法	不同视角下的识别率 (%)							
		0°	36°	54°	72°	90°	108°	144°	180°
正常	PCA	84.1	43.2	55.8	79.4	81.6	77.5	65.6	85.1
	LDA	85.1	41.8	56.2	81.0	80.4	78.1	67.2	86.5
背包	PCA	70.5	50.7	65.9	74.9	85.1	73.8	70.8	80.3
	LDA	73.1	51.9	65.2	78.1	84.1	77.1	73.0	81.1
外套	PCA	79.1	58.1	70.6	84.1	88.9	85.1	80.7	87.4
	LDA	80.1	58.9	71.5	86.9	89.0	86.1	81.8	89.1

5.3 实验结果分析

5.3.1 对比实验分析

通过对PCA方法的平均识别率与2DPCA方法的平均识别率进行比较可以发现,PCA方法的识别

率略低于2DPCA方法,对于124个人数据训练的时间,2DPCA方法要4min左右,而PCA方法则需要2到3h;产生花费时间差距的主要原因在于矩阵的运算上,2DPCA方法的图像运算矩阵的大小是 64×64 ,PCA方法运算图像矩阵的大小是 4096×4096 ;而LDA方法与2DPCA方法的比较结果是,LDA方法的识别率与2DPCA方法相当,或略低于2DPCA方法,但是LDA方法花费的时间比PCA方法还要多,大约是4~5h,LDA方法之所以耗时的主要原因是庞大的逆矩阵求取,从上述对比实验还可以看出,2DPCA方法的识别率高于PCA方法或与LDA方法相当,其最主要的优点是省时,步态识别是一个对实时性要求很高的技术,如果耗时过大也就失去了它的应用价值。

5.3.2 2DPCA实验结果分析

实验结果表明,本文方法能取得很好的识别效果。加权 $(2D)^2PCA$ 方法在侧面视角下,其平均识别率较 $(2D)^2PCA$ 方法略有提高。当前的步态特征提取方法多是在小数据库中试验,从以上实验结果可以看出,在本文采用的步态数据库中,目标类别相对较多。当使用单样本进行训练,其他所有样本作为测试样本时,仍然能获得很好的识别效果。同时,从实验数据可以看出:

(1) 视角的影响。当前已有的方法多是基于侧面视角的检测识别方法。本文采用的方法在多个视角下均能获得很好的识别效果。当目标与摄像机光轴的角度范围在 $72^\circ \sim 108^\circ$ 之间时,其识别率与侧面视角情况下相当,并且在正面视角和背面视角同样可以获得很高的识别率。

(2) 携带物的影响。同一个人在携带物品和不携带任何物品时,摄像机所拍摄的步态图像序列中相应帧的图像是不同的。对于不携带任何物品的步态识别有效的算法,对于携带了物品的步态序列进行识别就未必有效。而本文采用的方法,在人背包情况下仍能取得很好的识别效果。由此可以看出,本文方法对携带物品情况的识别有很好的鲁棒性。

6 结论

本文通过详细分析人体的步态特征,提出了一种基于步态能量图与 $(2D)^2PCA$ 方法相结合以及步

态能量图与 $W(2D)^2PCA$ 方法相结合的步态识别方法。该方法先将每一个步态序列作为一幅步态能量图进行分析识别,并采用 $(2D)^2PCA$ 方法和 $W(2D)^2PCA$ 方法对特征进行进一步提取,同时采用最近邻方法进行分类识别;最后在不同视角、不同步态的数据库中进行了实验。通过常用的特征提取算法的实验结果和本文方法的实验结果的对比表明,本文方法能有效降低特征空间维数和提高识别匹配速度,取得了很好的识别效果。本文选取步态能量图来表征步态特征,虽然保留了轮廓、频率、相位等步态信息,使步态数据量减少到了原来的几分之一,但是这种加权平均的叠加损失了一些步态的动态信息,这是步态能量图的不足之处,下一步的工作重点将放在步态表征上,即把步态能量图与另一种步态表征方法相结合,以解决步态能量图在动态信息描述上的不足。

致谢 本文实验采用的 CASIA 步态数据库由中国科学院自动化研究所提供,在此表示感谢。

参考文献 (References)

- 1 Wang Ke-jun, Hou Ben-bo. A survey of gait recognition[J]. Journal of Image and Graphic, 2007, **12**(7): 1152-1160. [王科俊, 侯本博. 步态识别综述[J]. 中国图象图形学报, 2007, **12**(7): 1152-1160.]
- 2 Shutler J D, Nixon M S. Zernike velocity moments for description and recognition of moving shapes [A]. In: Proceedings of the British Machine Vision Conference [C], Manchester, UK, 2001, **II**: 705-714.
- 3 Kale A, Rajagopalan A, Cuntoor N, et al. Gait based recognition of humans using continuous HMMs [A]. In: Proceedings of the 5th IEEE International Conference on Automatic Face and Gesture Recognition [C], Washinton, DC, USA, 2002: 336-341.
- 4 Wang Liang, Ning Hua-zhong, Hu Wei-ming. Gait recognition based on procrustes shape analysis [A]. In: Proceedings of the IEEE International Conference on Image Processing [C], Rochester, NY, USA, 2002: 433-436.
- 5 Wang Liang, Hu Wei-ming, Tan Tie-niu. Gait-based human identification [J]. Chinese Journal of Computers, 2003, **26**(3): 353-360. [王亮, 胡卫明, 谭铁牛. 基于步态的身份识别[J]. 计算机学报, 2003, **26**(3): 353-360.]
- 6 Huang P S, Harris C J, Nixon M S. Recognising humans by gait via parametric canonical space [J]. Journal of Artificial Intelligence in Engineering, 1999, **13**(4): 359-366.
- 7 Hayfron-Acquah J B, Nixon M S, Carter J N. Automatic gait recognition by symmetry analysis [J]. Pattern Recognition Letters, 2003, **24**(13): 2175-2183.
- 8 Cunado D, Nixon M S, Carter J N. Using gait as a biometric, via phase-weighted magnitude spectra [A]. In: Proceedings of the International Conference on Audio and Video Based Biometric Person Authentication [C], Crans Montana, Switzerland, 1997: 95-102.
- 9 Ning Hua-zhong, Tan Tie-niu, Wang Liang, et al. Kinematics based tracking of human walking in monocular video sequences [J]. Image and Vision Computing, 2004, **22**(5): 429-441.
- 10 Liu Yu-dong, Su Kai-na, Ma Li. Gait recognition method based on body skeletal model [J]. Computer Engineering and Applications, 2005, **41**(9): 88-92. [刘玉栋, 苏开娜, 马丽. 一种基于模型的步态识别方法[J]. 计算机工程与应用, 2005, **41**(9): 88-92.]
- 11 Su Han, Huang Feng-gang, Hong Wen. Automatic human identification method based on gait analysis [J]. Journal of System Simulation, 2006, **18**(5): 1292-1296. [苏茜, 黄凤岗, 洪文. 一种基于步态分析的身份识别方法[J]. 系统仿真学报, 2006, **18**(5): 1292-1296.]
- 12 Han J, Hanu B. Statistical feature fusion for gait-based human recognition [A]. In: Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition [C], Washington, DC, USA, 2004: 842-847.
- 13 He Guo-hui, Gan Jun-ying. Application study for 2DPCA in face recognition [J]. Computer Engineering and Design, 2006, **27**(24): 4667-4673. [何国辉, 甘俊英. 二维主元分析在人脸识别中的应用研究[J]. 计算机工程与设计, 2006, **27**(24): 4667-4673.]
- 14 Zhang Dao-qiang, Zhou Zhi-hua. Two-directional two-dimensional PCA for efficient face representation and recognition [J]. Neuron Computing, 2005, **69**(1-3): 224-231.