

光流分量分解的步态识别

罗正平 刘延钧 杨天奇

(暨南大学信息科学技术学院 广州 510632)

摘 要 步态识别因其远距离和难于伪装等特点在生物识别技术中颇受关注。针对目前特征提取方法信息量不足的现状,提出一种基于光流分量分解的步态识别方法,对步态光流图中横向分量和纵向分量为正的部分按行、列进行分解,求出每行和每列的光流横、纵向分量,得到 4 个特征向量。根据训练得出的每个特征向量在识别过程中的权重进行特征融合。将主成分分析和线性判别分析相结合,用动态时间规整算法进行匹配,最后采用最近邻分类算法分类。在 CASIA Database B 和 C 上的实验表明,该方法在正常、背包和穿大衣的条件下分别得到了 97%,90% 和 64% 的识别率,在慢速和快速行走的条件下分别得到了 88% 和 87% 的识别率。

关键词 步态识别,光流,主成分分析,线性判别分析,动态时间规整,特征融合

中图分类号 TP391.41 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2016.9.059

Gait Recognition Based on Decomposition of Optical Flow Components

LUO Zheng-ping LIU Yan-jun YANG Tian-qi

(College of Information Science and Technology, Jinan University, Guangzhou 510632, China)

Abstract Gait recognition has gained tremendous attention for its characteristics of long distance and hard-to-disguise. Aiming at the problem of insufficient information of the existing feature extraction method, this paper proposed a novel gait recognition method based on the decomposition of optical flow components. The positive transverse or longitudinal components in gait optical flow image are decomposed by rows and columns, then the transverse and longitudinal components of optical flow for each row or column are calculated, and four feature vectors are obtained. The four vectors are fused according to their weight in recognition. Principle components analysis and linear discriminant analysis techniques are combined, and dynamic time warping algorithm is used to match. Finally, K-nearest neighbor algorithm is used for classification. Experiments on CASIA Database B and C show that, the proposed method achieves recognition accuracy of 97%, 90% and 64% respectively under the conditions of normal, backpack-wearing and coat-wearing, 88% and 87% under conditions of slow walking and fast walking.

Keywords Gait recognition, Optical flow, Principle components analysis, Linear discriminant analysis, Dynamic time warping, Feature fusion

1 引言

根据行走过程中的步态特征来进行身份识别,步态识别作为一种生物识别技术,与人脸识别、指纹识别、虹膜识别等识别方式相比,因具有不需要识别主体的刻意配合、难于伪装、远距离性等特点,而在门禁系统、视频监控等应用领域有独特的优势^[1]。但由于其很容易受到环境变化、个体的物理特征(比如服饰、携带物、行走方向、行走速度等)的影响,识别精度离实际应用还有一定距离。

目前对于步态识别的研究大致可分为基于模型和基于轮廓^[2]两类方法。基于模型的方法旨在依据人体运动规律构建一个结构化模型,用该模型拟合识别个体,得到具有判别性的步态特征。Bouchrika 等人^[3]通过提取运动人体区域的关节点(脚踝、膝盖、臀部)构建运动模型; Tafazzoli 等人^[4]在此基础上充分利用运动过程中手和脚摆动的特点,使得识别效果

得到了有效改善。然而这些模型都是基于人体形状和步态变化的先验知识构建的,虽然对距离、遮挡和视角变化具有一定鲁棒性,但是方法的计算量大、对视频图像质量敏感等缺陷使得它很难被应用到实际中。基于轮廓的方法通过对二值图像的轮廓序列进行处理,从人体轮廓图序列中提取具有判别性的步态特征。Chen 等人^[5]提取了图像轮廓序列之间的差别,构建出识别个体的帧差能量图(FDEI)。该方法减轻了图像噪声的干扰,使步态特征得到了较好地保留,但视角变化下的识别率仍然不够理想。近年来,在基于轮廓的基础上,针对视角变化提出了很多改进方法, Muramatsu 等人^[6]通过将训练过程中得到的 3 步态序列投影成与测试序列相近的 2D 轮廓序列,提出了一个任意视角转换模型(Arbitrary View Transformation Model)。Chen 等人^[7]对运动轮廓序列提取重心轨迹作为步态特征,引进一个场景转换因子来处理视角变换的问题。与基于模型的方法相比,基于轮廓的方法在大多数的

到稿日期:2015-08-07 返修日期:2015-11-09 本文受广州市科技计划项目(2014)(2014J4100107)资助。

罗正平(1991-),男,硕士生,主要研究方向为模式识别和人工智能,E-mail:1515040119@qq.com;刘延钧(1991-),男,硕士生,主要研究方向为模式识别和人工智能;杨天奇(1961-),男,博士,教授,主要研究方向为模式识别和人工智能。

数据库上都得到了更好的识别效果,此外计算的复杂度也得到了改善。然而以往基于模型和基于轮廓的方法在特征提取过程普遍过于简单,容易受噪声等偶然因素干扰,提取到的特征代表性不够强,因此能更加科学、准确地提取步态特征的新方法、新思路显得尤其重要。

光流分析的研究起源于对人和生物视觉系统的研究,光流场的概念和计算最初由美国学者 Horn 和 Schunck^[8]提出,光流场携带了相邻两帧图像之间丰富的运动信息和目标物体的结构信息^[9]。把光流分析理论应用于步态识别的研究在最近几年受到了很多关注,文献[10-12]以提取图像序列所形成的光流直方图为基础,与不同的方法结合都得到了较好的效果。杨阳等人^[13]提出计算步态序列中的密度光流场,用其描述光流的空间形状分布。Xu 等人^[14]提出一种基于区域分割的光流直方图识别方法。可以看出,目前提出的所有方法均是从形成的光流场整体考虑的解决方案,提取到的步态特征信息过于聚集和单一,不能对步态运动的方向性信息进行有效表达。

针对以上不足,本文提出了一种全新的基于轮廓运动变化所形成光流场分量分解的步态特征提取方法,通过对步态光流场的光流分量进行分解,得到不同分解下的步态特征向量,最后对特征向量进行融合,在 CASIA Database B 和 C 库上的实验均取得了比其他方法更好的实验结果;此外该方法还可以应用于与运动物体识别相关的多种图像识别领域。

2 光流分量分解方法

光流分量分解(Optical Flow Components Decomposition, OFCD)的方法通过从步态光流场提取光流横、纵向分量,对其按行、列分解后的 4 个特征向量进行融合从而得到能唯一代表识别个体的步态特征,在识别阶段分别用 PCA+LDA(Principle Components Analysis and Linear Discriminant Analysis)和 DTW(Dynamic Time Warping)两种方法进行匹配验证。具体的实现方案流程如图 1 所示。




图 1 OFCD 步态识别方法流程图

2.1 步态光流图

相邻两帧运动图像形成一个光流场,多个步态图像序列形成的光流场相叠加得到步态光流图。步态光流场的形成包括以数学理论为基础的光流等式推导和光流分量提取算法的实现两个步骤。

2.1.1 光流等式

光流的本质是图像表面亮度模式运动的反映,因此在计算步态光流时以亮度常数模型为基础。假设在时刻 t 步态图像中坐标为 (x, y) 的像元的灰度为 $f(x, y, t)$, 经过时间 Δt , 它在图像上的位置变为 $(x + \Delta x, y + \Delta y)$, 其灰度值记为 $f(x + \Delta x, y + \Delta y, t + \Delta t)$ 。根据图像一致性假设,即图像上一点沿着运动轨迹的亮度保持不变^[15], 有:

$$f(x, y, t) = f(x + \Delta x, y + \Delta y, t + \Delta t) \quad (1)$$

设 u 和 v 分别是该点的光流矢量沿 x 和 y 两个方向的分量,且:

$$u = \frac{dx}{dt}, v = \frac{dy}{dt} \quad (2)$$

将式(2)等号右边用泰勒公式展开,得到:

$$f(x + \Delta x, y + \Delta y, t + \Delta t) = f(x, y, t) + \frac{\partial f}{\partial x} \Delta x + \frac{\partial f}{\partial y} \Delta y + \frac{\partial f}{\partial t} \Delta t + \varepsilon \quad (3)$$

其中, ε 包含 dx, dy, dt 的二次和高次项,忽略此项,得到:

$$\frac{\partial f}{\partial x} \Delta x + \frac{\partial f}{\partial y} \Delta y + \frac{\partial f}{\partial t} \Delta t = 0 \quad (4)$$

由于 $\Delta t \rightarrow 0$, 有:

$$\frac{\partial f}{\partial x} \frac{dx}{dt} + \frac{\partial f}{\partial y} \frac{dy}{dt} + \frac{\partial f}{\partial t} = 0 \quad (5)$$

即:

$$f_x u + f_y v + f_t = 0 \quad (6)$$

得到的式(6)即为步态光流场的基本方程。设 f_x, f_y, f_t 分别为参考点像素的灰度值沿 x, y, t 这 3 个方向的偏导数,式(6)又可以写成如式(7)所示的矢量形式:

$$\nabla f \cdot U + f_t = 0 \quad (7)$$

其中, $\nabla f = (f_x, f_y)$ 表示梯度方向, $U = (u, v)^T$ 表示步态光流,由于步态光流 U 有两个变量,而步态光流的基本等式只有一个方程,因此根据基本等式求解步态光流场是一个病态问题,必须附加约束条件。

2.1.2 步态光流分量

OFCD 方法中的步态光流分量采用 Horn-Schunck 算法^[8]来计算, Horn-Schunck 算法是一种基于梯度的光流计算方法,该算法通过把光流整体平滑性作为附加约束条件来求解步态光流方程病态问题,即在给定的邻域内 $(\nabla^2 u + \nabla^2 v)$ 应尽量小,对 u, v 的附加条件如下:

$$\min \{ [\frac{\partial u}{\partial x}]^2 + [\frac{\partial u}{\partial y}]^2 + [\frac{\partial v}{\partial x}]^2 + [\frac{\partial v}{\partial y}]^2 \} \quad (8)$$

其中, $\nabla^2 u = [\frac{\partial^2 u}{\partial x^2}] + [\frac{\partial^2 u}{\partial y^2}]$ 是 u 的拉普拉斯算子, $\nabla^2 v = [\frac{\partial^2 v}{\partial x^2}] + [\frac{\partial^2 v}{\partial y^2}]$ 是 v 的拉普拉斯算子,结合式(6)和式(8),步态光流 u, v 的计算归结为如下问题:

$$\min \{ \iint (f_x u + f_y v + f_t)^2 + \alpha^2 ([\frac{\partial^2 u}{\partial x^2}] + [\frac{\partial^2 u}{\partial y^2}] + [\frac{\partial^2 v}{\partial x^2}] + [\frac{\partial^2 v}{\partial y^2}]) \} \quad (9)$$

因而可以得到其相应的 Euler-Lagrange 方程,并利用 Gauss-Seidel 方法进行求解,得到图像每个位置第 1 至第 $(n+1)$ 次迭代估计 (u^{n+1}, v^{n+1}) 为:

$$u^{n+1} = \overline{u^n} - \frac{\overline{f_x u^n} + \overline{f_y v^n} + \overline{f_t}}{\alpha^2 + \overline{f_x^2} + \overline{f_y^2}} \quad (10)$$

$$v^{n+1} = \overline{v^n} - \frac{\overline{f_x u^n} + \overline{f_y v^n} + \overline{f_t}}{\alpha^2 + \overline{f_x^2} + \overline{f_y^2}}$$

最终得到的 u, v 即为所求步态光流场的光流横向分量和纵向分量。求解过程需要进行多次迭代过程,实验过程中采取迭代 $n=20$ 次求得 u, v 的量。

2.2 步态光流分解

步态识别的关键在于能否有效提取唯一代表每个样本步态的识别特征,OFCD 的特征提取方法提取人体运动过程中所形成的步态光流图每行的光流横向分量和纵向分量及每列的光流横向分量和纵向分量,得到从两个角度反映人在行走过程中步态运动特征的 4 个特征向量,最后再把 4 个特征融

合,从而实现对该个体的识别。

2.2.1 周期检测

人在行走过程中步态会呈现周期性变化,这种周期性变化也表现为步态光流场中光流纵向分量的周期性变化。我们采用一种新的周期检测方法,通过整个运动过程中光流纵向分量的代数和 $T(t)$ 的周期性变化实现周期检测,用式(11)表示如下:

$$T(t) = \sum_{x=1}^G \sum_{y=1}^L f_v(x, y, t) \quad (11)$$

其中, $f_v(x, y, t)$ 表示第 t 帧光流图在 (x, y) 处的纵向分量。 $T(t)$ 的周期性的变化过程如图 2 所示。

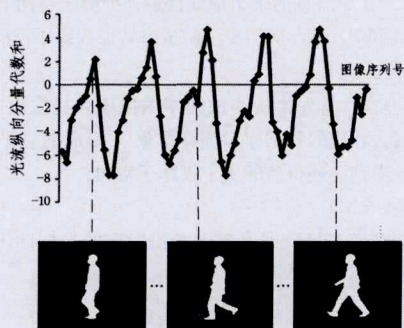


图 2 光流纵向分量周期变化图

从图 2 中曲线的波动可以看出明显的周期变化,两个相邻波峰或波谷之间的图像序列代表一个周期图像序列。

2.2.2 光流分量向量

光流分量向量为光流行、列分解下的横、纵向分量各自组成的向量,整个运动过程中的步态光流图在不同分解精度下的效果如图 3 所示。

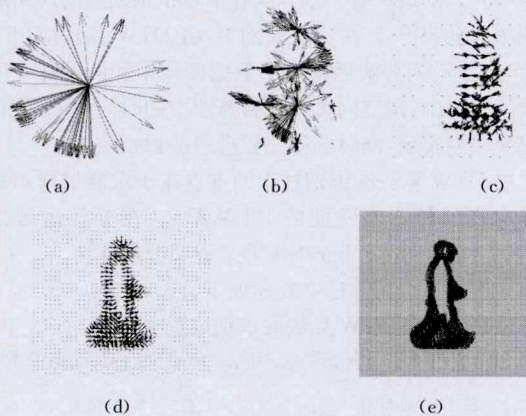


图 3 步态光流图

图 3 是在对每个样本图像序列进行重心归一化后的步态光流图,其中,(a)–(e)分别表示分解距离精度从小到大变化过程中所形成的逐步细化后的步态光流图,图中每一个网格点的光流矢量是所有相邻两帧图像形成的光流横向分量和纵向分量矢量和的矢量和。从图 3 中光流矢量的密度分布可以得出,图 3(a)相当于把样本所有的运动方向和大小信息映射到一个点上,随着分解精度越来越高,光流矢量形成的轮廓越来越能反映行走过程中的运动特点,步态光流图很好地表达了运动过程中尤其是四肢的运动信息,而上半身躯干等相对静止部分的信息得到了抑制。每个个体的步态光流图可以表示为:

$$F(x, y) = \sum_{t=1}^{L-1} f(x, y, t) \quad (12)$$

其中, $f(x, y, t)$ 表示第 t 帧与第 $t+1$ 帧形成的步态光流图, $F(x, y)$ 表示选定周期内从第 1 帧到第 L 帧所形成的总叠加步态光流图, L 表示选定总帧数。

行光流横、纵向分量向量和列光流横、纵向分量向量分别表示如下:

$$\begin{aligned} ru(h) &= \sum_{w=1}^k I(u, h, w), u > 0 \\ rv(h) &= \sum_{w=1}^k I(v, h, w), v > 0 \\ cu(w) &= \sum_{h=1}^l I(u, h, w), u > 0 \\ cv(w) &= \sum_{h=1}^l I(v, h, w), v > 0 \end{aligned} \quad (13)$$

其中, $h(h=1, 2, \dots, l)$ 表示步态光流图 $F(x, y)$ 的行号, $w(w=1, 2, \dots, k)$ 表示列号, $I(u, h, w)$ 表示在行、列号分别为 (h, w) 处的光流横向分量, $I(v, h, w)$ 表示相应的光流纵向分量,根据对称性的原理,均只取其大于 0 的分量。4 个不同样本的 4 个特征向量用曲线形式表示,如图 4 所示。

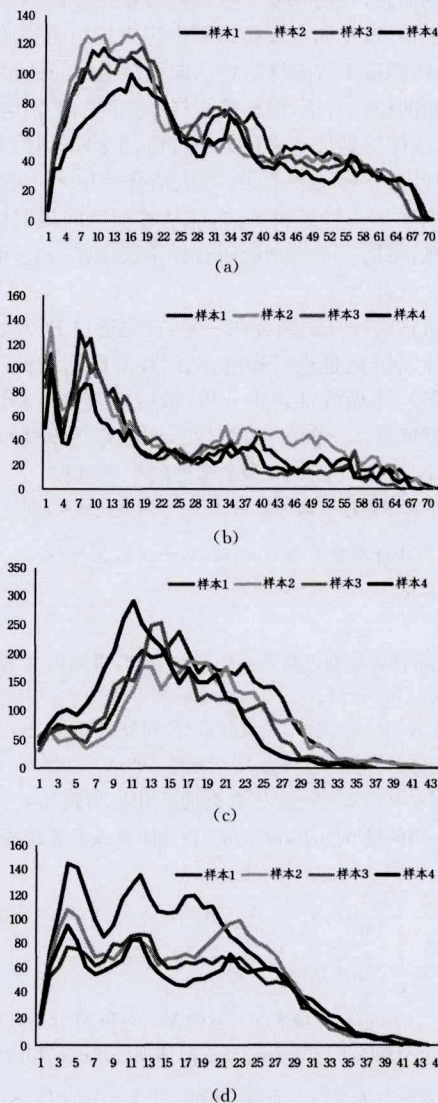


图 4 特征向量曲线图

图 4(a)–(d)分别表示 4 个样本在 ru, rv, cu, cv 4 种分解条件下光流分量之和的变化曲线图,横坐标表示相应的行号或列号,纵坐标表示运动量。为了便于比较,行号和列号均进行左对齐归一处理。每个样本曲线的变化反映了样本在运动过程中身体从下往上、从左往右各个部分横向、纵向运动量的大

小。从图 4 中曲线的变化可以得出, ru, rv 的曲线在四肢活动密集的区域呈现峰值, cu, cv 的曲线集中描述了躯干部分的上下运动量, 而这些正好是我们所要提取的步态信息。

3 匹配过程

按上述方法从轮廓图像序列提取光流分量所形成的 4 个特征向量, 对得到的特征向量采用两种识别方法进行验证: PCA+LDA 方法和 DTW 方法, 求得每个特征向量的识别率, 将得到的单个特征向量下的识别率作为权重赋给每个特征向量, 根据权重进行特征融合, 得到最终识别率。

3.1 PCA+LDA 方法

主成分分析又称为离散 K-L 变换 (Discrete Karhunen-Loeve Transform)、主轴变换 (Principle Axis Transform)、霍特林变换 (Hotelling Transform)、特征值变换 (Eigenvalue Transform)^[16], 是一种多变量分析工具, 用来处理由随机变量组成的向量, 对数据进行降维, 降维后仍然保存了特征的绝大多数判别信息, 从而降低了数据处理难度。PCA 广泛应用于物体识别领域, 比如在人脸识别中用来构建特征脸^[17]。但是 PCA 算法侧重于解除样本特征向量分量之间的相关性, 准确表达原始的模式特征, 而忽略了样本之间的类别信息, 所以用 PCA 算法能得到最有表现力的特征, 但得不到最有辨别力的特征, 因此常常将其和 LDA 算法结合使用^[18]。LDA 算法是模式识别中的一种经典算法, 能从特征空间提取样本之间的判别信息, 将同一个类别的所有样本聚集在一起, 而将不同类别尽量分散开^[19]。

本文将这两种算法结合在一起, 首先通过 PCA 过程对提取到的高维特征向量进行降维, 然后在降维后的低维空间对不同类别的样本做线性判别分析, 最后用欧氏距离计算测试样本和数据库样本之间的匹配效果, 详细算法步骤如下。

算法 1 基于 PCA+LDA 算法的识别过程

输入: 步态轮廓图像序列训练集 X, 训练个体类别数 C, 训练样本总数

$$N, X_i \text{ 类中样本总数 } N_i (i=1, 2, 3, \dots, C), \sum_{i=1}^C N_i = N$$

输出: 识别率 R

具体步骤:

Step 1: 对轮廓图像序列进行重心归一化处理, 得到训练集样本步态光流图 $F_{ij}(x, y)$ 。

Step 2: 计算 X_i 中 N_i 个样本光流分量行、列分解后 ru, rv, cu, cv 4 个向量分别形成的行数为 N_i 的矩阵 $V_i^r, V_i^v, V_i^c, V_i^s$ 。

Step 3: 分别求 $V_i^r, V_i^v, V_i^c, V_i^s$ 每列的平均值, 得到 X_i 4 个特征各自的平均向量 $m_i^r, m_i^v, m_i^c, m_i^s$ 和总体训练集 X 形成的平均向量:

$$\begin{aligned} M^r &= \frac{1}{C} \sum_{i=1}^C m_i^r, M^v = \frac{1}{C} \sum_{i=1}^C m_i^v \\ M^c &= \frac{1}{C} \sum_{i=1}^C m_i^c, M^s = \frac{1}{C} \sum_{i=1}^C m_i^s \end{aligned} \quad (14)$$

Step 4: 对 ru, rv, cu, cv 4 种情况对应的 V_i, m_i 和 M 分别做如下运算:

i. 把每个类别的平均向量 m_i 减去总体训练集的平均向量 M 所形成的差值向量作为行向量, 得到一个 C 行的矩阵 \bar{X} , 计算 $\bar{X}^T \bar{X}$ 的特征值 λ 和对应的特征向量 ϑ , 并将特征向量单位化。

ii. 根据 λ 的值按从大到小的顺序对相应的 ϑ 排序, 选取前 η 的维度组合成 PCA 的投影子空间 P_{pca} , η 满足如下关系:

$$\eta = \frac{\lambda_1 + \lambda_2 + \dots + \lambda_j}{\lambda_1 + \lambda_2 + \dots + \lambda_n} \times 100\% \quad (15)$$

其中, j 表示组成投影空间时选取的维度, n 表示特征向量的总维度。

iii. 分别求出在投影空间 P_{pca} 下 V_i, m_i 和 M 的投影值 PV_i, Pm_i, PM 。

iv. 计算 X_i 的类内散布矩阵 S_i 和总的散布矩阵 S_w :

$$S_i = \sum_{i=1}^d (PV_i - Pm_i)^T (PV_i - Pm_i) \quad (16)$$

$$S_w = \sum_{i=1}^C S_i$$

v. 计算 X 的类间散布矩阵 S_B :

$$S_B = \sum_{i=1}^C N_i (Pm_i - PM)^T (Pm_i - PM) \quad (17)$$

vi. 求解类内散布矩阵 S_w 和类间散布矩阵 S_B 的广义特征值和特征向量, 按特征值从大到小的顺序对相应的特征向量排序, 保留前 $C-1$ 个特征向量组成线性最佳分类子空间 P_{pca} 。

vii. 由 P_{pca} 和 P_{lda} 组合得到最终的步态特征投影子空间:

$$P = P_{lda}^T P_{pca}^T \quad (18)$$

Step 5: 在识别阶段, 首先将从测试样本图像序列提取出的 4 个特征向量减去相应的数据库训练样本集 X 形成的总平均向量 M, 然后投影到上述得到的 4 个投影子空间:

$$Y = P(V - M) \quad (19)$$

Step 6: 根据测试样本与数据库样本在投影空间坐标的 Euclidean 距离按最近邻分类算法进行分类。

Step 7: 得到识别率 $R = \frac{\text{分类正确样本}}{\text{总测试样本}} \times 100\%$ 。

3.2 DTW 方法

模板匹配法是计算和进行相似度匹配的一种最常用的方法, 动态时间规整因其硬件实现的简易性、训练过程的简单快速性而广泛应用于模板匹配中, 如孤立词语音识别、手势识别、数据挖掘、信息检索等^[20]。DTW 的基本思想是: 将输入模板和参考模板之间的时间对应关系用一个规整函数来描述, 通过求解满足两模板匹配时的累积距离最小的规整函数得到所求问题的最优解。该方法在语音识别领域的应用取得了很理想的效果^[21]。在步态识别中, 将 DTW 算法应用于运用光流分量行、列分解后提取的数据库样本和测试样本的特征向量的匹配中, 用空间关系代替算法中的时间关系, 使得匹配过程简单易实现, 同时获得比较理想的识别效果。

运用 DTW 算法的识别过程的重点在于求测试样本和数据库样本之间相似度匹配的 DTW 距离, 在分类过程采用 KNN (K-Nearest Neighbor, KNN) 最近邻分类算法。

整个识别过程用算法 2 表述如下。

算法 2 基于 DTW 算法的识别过程

输入: 步态轮廓图像序列训练集 X, 训练个体类别数 C, 训练样本总数

$$N, X_i \text{ 类中样本总数 } N_i, i=1, 2, 3, \dots, C, \sum_{i=1}^C N_i = N$$

输出: 识别率 R

具体步骤:

Step 1: 对轮廓图像序列进行重心归一化处理, 得到训练集样本步态光流图 $F_{ij}(x, y)$ 。

Step 2: 计算 X_i 中 N_i 个样本光流分量行、列分解后 ru, rv, cu, cv 4 个向量所分别形成的行数为 N_i 的矩阵 $V_i^r, V_i^v, V_i^c, V_i^s$ 。

Step 3: 分别求 $V_i^r, V_i^v, V_i^c, V_i^s$ 每列的平均值, 得到 X_i 4 个特征各自的平均向量: $m_i^r, m_i^v, m_i^c, m_i^s$ 。

Step 4: 按上述同样的方法求得测试样本集 Y 中每个类别 4 个特征各自的平均向量: $n_j^r, n_j^v, n_j^c, n_j^s$, 其中 j 为样本的类别编号。

Step 5: 对 ru, rv, cu, cv 4 种情况对应的 m_i 和 n_j 分别做如下运算:

i. 求出 m_i 和 n_j 的维度分别为 $p = |m_i|$ 和 $q = |n_j|$ 。

ii. 定义 $p \times q$ 的匹配矩阵 D 和路径代价矩阵 d, 路径代价函数 $d(p, q)$ 为从起始点出发到当前点 (p, q) 的所有路径上最小的累积失真值, 且具有如下递推公式:

当 $p > 1, q > 1$ 时:

$$d(p, q) = D(p, q) + \min\{d(p-1, q-1), d(p, q-1), d(p-1, q)\}$$

当 $p = 1, q > 1$ 时:

$$d(p, q) = D(p, q) + d(p, q-1)$$

当 $p > 1, q = 1$ 时:

$$d(p, q) = D(p, q) + d(p-1, q)$$

当 $p = 1, q = 1$ 时:

$$d(p, q) = D(1, 1)$$

由上面的递推公式,即可求得从起点到终点的最佳匹配路径,从而可以计算出数据库样本和测试样本之间的匹配 DTW 距离。

Step 6: 根据测试样本与数据库样本之间的 DTW 距离按最近邻分类算法进行分类。

Step 7: 得到识别率 $R = \frac{\text{分类正确样本}}{\text{总测试样本}} \times 100\%$ 。

4 实验设计与分析

实验采用的数据库为中国科学院自动化研究所提供的 CASIA 步态数据库^[22],它一共包含 A, B, C 3 个库,其中 B 库是一个大规模多视角数据库,一共包含 124 个人,每个人有正常(nm)、穿大衣(cl)、背包(bg) 3 种行走条件,分别如图 5(a)~(c)所示;11 个视角($0^\circ, 18^\circ, 36^\circ, \dots, 180^\circ$),每个方向分别有 50~75 帧图像序列,原始图片尺寸为 352×240 像素。CASIA 步态数据库 C 是用红外摄像机于夜间拍摄的一个大规模数据库,一共包含 153 个人在 4 种条件(背包、正常、快速、慢速)下的数据,其他的参数和数据库 B 相同。实验均采用 90° 视角作为训练和测试样本的视角,验证方法采取留一法。所有实验过程均在 Windows 8.1 操作系统、Matlab 7.0 仿真软件环境下完成。




图 5 nm, cl, bg 3 种行走条件

从 B 库和 C 库各取 100 个个体在正常行走的情况下做实验,表 1 列出了分别用 PCA+LDA 方法和 DTW 方法在 B 库和 C 库上 ru, rv, cu, cv 4 个特征向量下各自识别率的实验结果。

表 1 单独识别率(%)

特征向量	OFCD+DTW		OFCD+PCA+LDA	
	B 库	C 库	B 库	C 库
ru	86.00	84.00	88.00	93.00
rv	89.00	90.00	91.00	94.00
cu	79.00	78.00	82.00	81.00
cv	78.00	80.00	80.00	84.00

从表 1 中可以看出,分别采用两种识别方法所得的 ru, rv 两个特征向量的识别率在不同数据库上均要高于 cu, cv 的识别率,这是因为在对步态光流图进行分解时, ru, rv 所代表的行分解将步态运动过程中的动作信息投影到了一个比 cu, cv 维度更大的向量上,使得步态信息比较分散,从而更加全面地代表了个体的步态特征。

为了验证 PCA+LDA 方法中不同 η 值对识别率的影响,

对不同 η 值在数据库 C 中 100 个个体正常行走的情况进行验证,求得其融合后的识别率变化如图 6 所示,特征融合过程中 4 个特征向量的权重分别等于各自单独条件下的识别率。




图 6 不同 η 值下的识别率

图 6 中曲线的变化反映了在主成分分析时选取投影空间维度的变化对识别率的影响,在 η 取值为 $0.8 \sim 0.99$ 之间时,识别效果最好,当 $\eta < 0.8$ 时,过多的判别信息被丢失,导致识别率下降;当 $\eta = 1$ 时,识别率反而大幅度下降,这是因为在形成投影子空间时需要每个样本进行长度规整,本实验采用全部规整到最大维度的方法,因此个别维度大的异常样本导致其他所有样本的维度都变大,从而增添了很多冗余信息,使得识别率反而下降。

表 2 给出了在 B 库中正常情况下行走时 100 个样本在步态光流分量分解的方法和其他方法上识别率的比较结果。

表 2 正常条件下的识别率(%)

方法	识别率
GEI+LBP+DCV ^[23]	93.98
文献[10]	97.00
OFCD+DTW	95.00
OFCD+PCA+LDA	97.00

实验结果表明,用 PCA+LDA 方法的识别效果因其不但考虑了样本之间的判别信息,而且在投影空间的选择上考虑了样本之间的差别,所以总体识别效果要好于用 DTW 的识别方法。基于 OFCD 的方法准确地对运动信息进行了行列分解,使得个体的步态特征得以较好保留,总体识别率要优于基于文献[23]中的 GEI+LBP+DCV 方法。

服饰和背包情况对步态识别的识别率构成了很大挑战,为了验证基于 OFCD 的方法对服饰和背包情况的鲁棒性,实验采用 CASIA B 库中 bg 和 cl 两种情况下 100 个样本的各一组数据作为测试样本, nm 情况下 3 组数据取平均值作为训练集样本进行训练,实验结果如表 3 所列。

表 3 背包、穿大衣条件下的识别率(%)

方法	cl(穿大衣)	bg(背包)
文献[10]	27.50	86.00
AEI+PCA+LDA ^[10]	57.62	75.00
OFCD+DTW	57.00	85.00
OFCD+PCA+LDA	64.00	90.00

在背包条件下因为背包相对躯干静止,得到的步态光流图和正常情况下差别不大;穿大衣的情况由于其遮掩了四肢的部分运动信息,因此导致穿大衣条件下的识别率要低于背包情况下的识别率。

行走速度的变化是影响步态识别精度的又一重要因素,不同行走速度下的人体姿势、四肢的摆动幅度都会有很大变化,表 4 给出了在 C 库 100 个人上的实验结果,实验采用正常步速下的两组数据作为训练集样本, fs(慢速)和 fq(快速)条件下的数据各一组作为测试样本。

表4 速度变化条件下的识别率(%)

方法	fn(正常)	fs(慢速)	fq(快速)
文献[24]	90.20	85.60	88.20
OFCD+DTW	95.00	84.00	83.00
OFCD+PCA+LDA	97.00	88.00	87.00

基于 OFCD+PCA+LDA 的实验结果总体上要略好于文献[24]中基于确定性学习的识别方法,这是因为文献[24]中的方法本质上是基于轮廓区域的,OFCD 方法本质上是基于运动步态的,前者关注的是运动过程所呈现的静态信息,而后者更多地关注运动过程中的动态变化信息。

以上几组实验结果充分表明:基于光流分量行列分解的步态识别方法从水平和垂直两个角度对步态进行特征分解,能够有效提取运动过程中的步态信息,降低了服饰和携带物对识别过程的影响,对速度变化也表现出了较强的鲁棒性。

结束语 基于光流分量的步态特征提取方法将行分解下和列分解下的光流横向分量向量与光流纵向分量向量 4 个特征融合,实现了对人体行走过程中四肢左右运动和躯干上下运动的分离,把步态信息投影到不同的投影面,使得步态特征得到了有效表达。运用不同的识别方法,在不同数据库、不同外在条件(服饰、背包、速度)下的结果充分表明,该方法能准确地对步态运动进行特征分解,有效地提取运动信息,从而实现对其个体的识别。此方法还可以应用于人脸识别、手势识别等与运动物体识别相关的领域。进一步的研究工作需要从如何降低步态光流图计算的复杂度以及如何提高该方法对视角变化的鲁棒性两个方面来考虑。

参 考 文 献

- [1] Lee T K M, Belkhatir M, Sanei S. A comprehensive review of past and present vision-based techniques for gait recognition [J]. *Multimed Tools Appl*, 2014, 72(3): 2833-2869
- [2] Zhang Er-hu, Zhao Yong-wei, Xiong Wei. Active energy image plus 2DLPP for gait recognition [J]. *Signal Processing*, 2010, 90(7): 2295-2302
- [3] Bouchrika I, Nixon M S. Model-based feature extraction for gait analysis and recognition [J]. *Lect Notes Comput Sc*, 2007, 4418: 150-160
- [4] Tafazzoli F, Safabakhsh R. Model-based human gait recognition using leg and arm movements [J]. *Eng Appl Artif Intel*, 2010, 23(8): 1237-1246
- [5] Chen C H, Liang J M, Zhao H, et al. Frame difference energy image for gait recognition with incomplete silhouettes [J]. *Pattern Recognition Letters*, 2009, 30(11): 977-984
- [6] Muramatsu D, Shiraiishi A, Makihara Y, et al. Gait-Based Person Recognition Using Arbitrary View Transformation Model [J]. *IEEE Transactions on Image Processing*, 2015, 24(1): 140-154
- [7] Chen X, Yang T Q, Xu J M. Cross-view gait recognition based on human walking trajectory [J]. *J Vis Commun Image R*, 2014, 25(8): 1842-1855
- [8] Horn B, Schunck B. Determining Optical Flow [J]. *Artificial Intelligence*, 1981, 17(2): 185-203
- [9] Lam T H W, Cheung K H, Liu J N K. Gait flow image: A silhouette-based gait representation for human identification [J]. *Pattern Recognition*, 2011, 44(4): 973-987
- [10] Yu C C, Cheng C H, Fan K C. A Gait Classification System using Optical Flow Features [J]. *J Inf Sci Eng*, 2014, 30(1): 179-193
- [11] Yang Ya-zhou, Tu Dan, Li Guo-hui. Gait recognition using flow histogram energy image [C] // 22nd International Conference on Pattern Recognition. 2014: 444-449
- [12] Pers J, Sulic V, Kristan M, et al. Histograms of optical flow for efficient representation of body motion [J]. *Pattern Recognition Letters*, 2010, 31(11): 1369-1376
- [13] Yang Yang, Guo Ji-chang. Gait recognition method based on spatial distribution of optical flow [J]. *Application Research of Computers*, 2013, 30(7): 2206-2209 (in Chinese)
杨阳, 郭继昌. 基于光流空间分布的步态识别方法 [J]. *计算机应用研究*, 2013, 30(7): 2206-2209
- [14] Xu Yan-qun, Zhang Bin. Application of Segmentation Based on Optical Flow in Gait Recognition [J]. *Computer Science*, 2012, 39(4): 275-277, 292 (in Chinese)
徐艳群, 张斌. 一种基于光流的多区域分割在步态识别中的应用 [J]. *计算机科学*, 2012, 39(4): 275-277, 292
- [15] Lucas Bruce D, Takeo K. An Iterative Image Registration Technique with an Application to Stereo Vision [C] // *Proceedings of Imaging Understanding Workshop*. 1981: 121-130
- [16] Harold H. Analysis of a complex of statistical variables into principal components [M]. Baltimore: Warwick & York, 1933
- [17] Wang Cheng-liang, Lan Li-bin, Zhang Yu-wei, et al. Face recognition based on principle component analysis and support vector machine [C] // 2011 3rd International Workshop on Intelligent Systems and Applications. 2011
- [18] Zhou C J, Wang L, Zhang Q, et al. Face recognition based on PCA image reconstruction and LDA [J]. *Optik*, 2013, 124(22): 5599-5603
- [19] Balakrishnama S, Ganapathiraju A, Picone J. Linear Discriminant Analysis for signal processing problems [C] // *IEEE South-eastcon '99*. 1999: 78-81
- [20] Hernandez-Vela A, Bautista M A, Perez-Sala X, et al. Probability-based Dynamic Time Warping and Bag-of-Visual-and-Depth-Words for Human Gesture Recognition in RGB-D [J]. *Pattern Recognition Letters*, 2014, 50: 112-121
- [21] Sheikhan M, Gharavian D, Ashoftedel F. Using DTW neural-based MFCC warping to improve emotional speech recognition [J]. *Neural Comput Appl*, 2012, 21(7): 1765-1773
- [22] Chinese Academy of Sciences. Institute of Automation Gait Database [OL]. <http://www.sinobiometrics.com>
- [23] Liu Zhi-yong, Feng Guo-can, Chen Wei-fu. Gait Recognition Based on Local Binary Pattern and Discriminant Common Vector [J]. *Computer Science*, 2013, 40(9): 262-265 (in Chinese)
刘志勇, 冯国灿, 陈伟福. 基于局部二值模式和辨识共同向量的步态识别 [J]. *计算机科学*, 2013, 40(9): 262-265
- [24] Zeng W, Wang C. Gait recognition across different walking speeds via deterministic learning [J]. *Neurocomputing*, 2015, 152: 139-150