

基于 KOD 能量特征的群体异常行为识别*

段晶晶, 高琳, 范勇, 李郁峰, 夏菁菁, 任新宇

(西南科技大学 计算机科学与技术学院, 四川 绵阳 621010)

摘要: 在群体异常行为识别过程中, 针对传统特征易受目标遮挡影响导致其对群体行为的弱描述性问题, 提出一种基于 KOD(kinetic orientation distance) 能量特征的群体异常行为识别方法。该能量特征忽略群体中相互遮挡的个体的局部特征, 从群体行为整体上分别根据群体的运动剧烈程度、群体运动方向一致性和群体中个体的相对位置定义并提取群体动能、方向势能和距离势能构成群体行为高层 KOD 能量特征, 以此描述群体的运动状态变化, 最后通过构建隐马尔可夫模型实现群体异常行为检测及类型识别。在 PETS 和 UMN 公共数据集上进行实验并与传统光流特征进行对比, 实验结果表明, 使用 KOD 能量特征能够有效地检测出群体异常行为并识别出其类型, 且能够达到 92% 的准确率。

关键词: 群体异常; 角点; 光流; 能量特征; 动能方向距离; 隐马尔可夫模型

中图分类号: TP391.41 **文献标志码:** A **文章编号:** 1001-3695(2013)12-3836-04

doi:10.3969/j.issn.1001-3695.2013.12.084

Abnormal crowd behavior recognition based on KOD energy model

DUAN Jing-jing, GAO Lin, FAN Yong, LI Yu-feng, XIA Jing-jing, REN Xin-yu

(School of Computer Science & Technology, Southwest University of Science & Technology, Mianyang Sichuan 621010, China)

Abstract: In view of the weak descriptiveness problem on the crowd behavior which was caused by the fact that the shelter had a strong effect on traditional features in the abnormal crowd behavior recognition process, this paper proposed an abnormal crowd behavior recognition method based on the KOD energy characteristics. Neglecting the local characteristics of crowds in mutual occlusion, this paper defined and extracted crowd kinetic energy, orientation potential energy, distance potential energy on the basis of motion intensity, consistency of moving direction, relative location of the targets respectively. Then it constructed the KOD energy characteristics to describe the changes of crowd motion states. At last, the behavior type was distinguished from each other by constructing the hidden Markov models. Experimental results on the PETS and UMN datasets show that the method can detect and recognize different crowd abnormal behaviors with 92 percent accuracy, which is higher than traditional optical flow features.

Key words: crowd abnormality; corner; optical flow; energy characteristics; KOD; hidden Markov model

0 引言

随着社会经济的发展, 城市中的人口密度越来越大, 由此引起的诸如群体斗殴、非法聚集等群体异常行为时有发生, 对城市的治安造成很大的威胁。因此, 群体异常行为的检测识别成为视频监控中一个很有研究价值的课题^[1,2]。然而, 由监控场景的多样性、人群密度的不同以及群体间的相互遮挡引起的行为特征的提取难度大及描述性弱等问题, 导致群体异常行为的检测识别率普遍较低。

目前, 国内外学者已经在群体异常行为检测方面取得了一定成果。其中, Andrade 等人^[3,4]通过提取光流特征, 构建隐马尔可夫模型(hidden Markov model, HMM)实现群体异常检测, 但由于光流对群体行为的描述性弱, 使得检测率比较低。Wang 等人^[5]通过采用改进的自适应大小时空体特征对群体

行为进行描述, 却存在计算量巨大的缺点。另外, Xiong 等人^[6]通过定义群体行为能量模型实现群体异常检测。Mehran 等人^[7]提出在图像中建立粒子, 利用社会力模型描述粒子与周围空间的相互作用力, 采用力的强度来描述视频图像中行人行为, 然后构建局部时空立方体并建立 bag-of-words 模型, 检测群体运动剧烈的异常行为。Kratz 等人^[8]使用基于梯度的时空模型描述场景运动信息, 并用 HMM 来捕获时空模型之间的关系, 实现群体的局部异常行为检测。Xu 等人^[9]使用 LBP-TOP 算法提取群体行为特征, 然后使用隐含狄利克雷分配(latent Dirichlet allocation, LDA)算法对纹理特征进行训练, 构建得到 LDA 模型, 最后检测群体局部异常行为。

这些算法主要采用光流、局部时空或纹理特征描述群体行为, 用来检测群体行为局部异常, 缺乏对群体行为的全局特征描述, 无法从整体上表征群体行为的运动状态, 且少有针对群

收稿日期: 2013-04-03; **修回日期:** 2013-05-29 **基金项目:** 四川省教育厅科技资助项目(12zd1005); 四川省科技创新苗子工程资助项目(20132021); 西南科技大学研究生创新基金资助项目(13ycj39)

作者简介: 段晶晶(1988-), 女, 河南驻马店人, 硕士研究生, 主要研究方向为计算机视觉(dieche5740@163.com); 高琳(1976-), 男, 讲师, 博士, 主要研究方向为计算机视觉、数字图像处理; 范勇(1972-), 男, 教授, 博士, 主要研究方向为机器视觉、图像理解及应用等; 李郁峰(1972-), 男, 副教授, 博士研究生, 主要研究方向为计算机视觉、图像融合等; 夏菁菁(1987-), 女, 硕士研究生, 主要研究方向为计算机视觉; 任新宇(1988-), 男, 硕士研究生, 主要研究方向为计算机视觉。

体异常行为的行为类型识别研究。针对这些问题,本文在提取传统视觉特征基础上,提出了一种基于 KOD 能量特征的群体异常行为识别算法,结合统计规律分别定义并提取群体动能^[10]、方向势能和距离势能三种能量构成 KOD 能量特征,生成相应的行为模式,最后通过构建不同异常行为的隐马尔可夫模型进行分类识别,算法的流程如图 1 所示。该算法能够检测并识别多种群体异常行为,且具有较高的识别率。




图 1 基于 KOD 能量特征的群体异常行为识别方法流程

1 KOD 能量特征提取

1.1 基本特征

提取基本特征前,需要对视频序列进行运动目标检测,获得群体运动目标所在区域。群体运动目标区域的获取是为了通过优化图像中角点的提取,减少角点光流的计算量,从而更好地描述群体及群体行为。因此,无须精确提取目标区域而只提取粗略的运动区域,并将其作为掩模进行特征角点的提取。

本文采用基于灰度的 Harris 角点检测方法提取角点。通过计算图像像素点的梯度及曲率来检测目标边缘的角点,并用角点代表群体中的个体。然后采用基于金字塔模型的 Lucas-Kanade 光流算法通过特征匹配求得角点处的光流,得到群体行为的基本特征。

1.2 能量特征

由视觉的直观性得知,群体由多个个体组成,能够描述群体行为及动态的基本特征包括群体中个体的总数(即群体规模)、个体的运动速度大小及方向、个体在群体中所处位置(即群体中个体的分布)及群体的整体运动速度等。然而,基本光流特征只包含代表群体中个体的特征角点的运动速度即运动方向和运动速度大小信息,只能表征群体中个体的运动状态,却无法描述群体的运动趋势和运动状态以及群体的分布状态等,因此无法直接从全局上识别群体异常行为。

考虑到光流特征对群体行为的描述缺少重要特征信息,本文提出包含群体中个体运动信息、群体中个体位置分布及相对位置变化、群体主流运动方向等信息描述的 KOD 能量特征。基于物理学定义,物体由于运动而具有的能量叫动能;由于各物体间存在相互作用而具有的、由各物体间相对位置决定的能量叫势能。由此,本文分别定义群体动能、方向势能和距离势能三种群体行为能量,分别描述群体的运动激烈程度、群体的运动方向一致性、群体中个体的位置分布以及群体随时间的相

对位置变化情况,包含丰富的特征信息对群体全局运动状态进行表征。

1) 群体动能

群体动能代表群体整体的运动激烈程度,将群体视为个体的集合,由提取的特征角点代表其中个体,因此,计算群体动能即所有个体的运动能量之和等同于计算全部角点的运动能量之和。遵循物理学中对运动物体的动能定义,使用式(1)计算所有代表个体的特征角点的运动能量之和,即群体动能:

$$E_k(n) = \frac{\sum_{i=1}^I m_i |v_i|^2}{I} \quad (1)$$

其中: m_i 表示第 i 个角点的质量权重值,群体行为发生时,假设群体中的个体在群体行为中所占的权重相同,因此,质量权重值 m_i 取相同常量值; I 表示第 n 帧中角点的个数; v_i 代表了第 i 个角点的光流矢量(v_{ix}, v_{iy}); $|v_i|$ 表示光流矢量的幅值,计算方法为

$$|v_i| = \sqrt{v_{ix}^2 + v_{iy}^2} \quad (2)$$

2) 方向势能

描述群体中个体相互作用的能量叫做势能。为描述群体相互作用引起的运动方向一致性,定义为方向势能,表示运动的统一性。个体与个体间方向势能表现为:若个体相互之间的运动方向差异较小,则说明运动方向一致或接近,反之,说明两者方向比较分散。因此,定义方向势能为群体中个体的运动方向差异性的总和,用于描述群体的运动方向及群体行为一致性。另外,在方向势能的计算中加入运动速度大小差异性能更充分地描述群体运动状态一致性。群体行为分析中假设每一个角点代表群体中的一个个体,因此,定义 c_i 和 c_j 角点运动之间的差异性 S_{ij} 为运动方向差异性及运动速度大小差异性的加权和,如式(3)所示。群体的方向势能即为所有个体与个体之间的方向势能总和,计算各个角点间差异性的总和,归一化后得到第 n 帧中群体的方向能量 $E_o(n)$,如式(4)所示。

$$S_{ij} = \alpha \left[\arccos \left(\frac{v_i \cdot v_j}{|v_i| |v_j|} \right) \right] + \beta | |v_i| - |v_j| | \quad (3)$$

$$E_o(n) = \gamma \frac{\sum_{i=1}^I \sum_{j=i+1}^I S_{ij}}{\sum_{i=1}^I (i-1)} \quad (4)$$

其中: v_i 和 v_j 分别表示第 i 和 j 个角点的光流矢量; α 与 β 分别代表群体运动方向及运动速度大小所占的权重,一般取经验值且满足 $\alpha > \beta$,另外 α 和 β 的取值需要使得方向及大小两种差异性接近相同数量级; γ 为归一化常量。

3) 距离势能

群体行为特征中有一个重要描述指标是群体中个体的位置分布。由于难以直接用点的分布描述位置分布,采用点与点之间的相对位置描述群体中个体的相对位置关系。因此,定义距离势能为个体之间的欧式距离,用以描述个体之间的远近。群体整体的距离势能则能描述整个群体中个体的分布状态。若群体距离势能较小,说明群体中个体比较集中,群体较密集,反之说明群体比较分散。

计算群体中两两个体间的欧式距离计算量较大,且有不必要的重复计算。因此考虑通过计算各个角点的坐标平均值近似为群体所在区域的中心,通过计算角点与中心的欧氏距离代替个体之间的距离,并由式(5)计算得到归一化后的群体的总

距离势能为

$$E_d(n) = \varphi \frac{\sum_{i=1}^I |c_i - (\sum_{i=1}^I c_i)/I|}{I} \quad (5)$$

其中: φ 是修正因子,取常量。

1.3 行为模式

本文通过计算角点光流特征,计算群体动能、方向势能和距离势能三种行为能量并生成高层 KOD 能量特征后,提取群体异常行为模式。通过提取正常和异常行为中能量特征,针对不同场景不同视角下的视频序列统计得到群体正常行为的动能阈值 θ_{E_k} 、方向势能阈值 θ_{E_o} ,分别表示正常行走与奔跑的动能分界线和群体正常与异常行为的方向散度分界线。

当群体动能大于一定的阈值时,定义其为动能异常,即表示群体运动较剧烈,因此群体异常行为序列中一帧的特征向量 O_i 中元素 o_i^1 由式(6)计算。

$$o_i^1 = \begin{cases} 1 & E_k > \theta_{E_k} \\ 0 & E_k < \theta_{E_k} \end{cases} \quad (6)$$

群体方向势能越大,代表群体中个体的运动方向越发散,群体运动方向越不统一,特征向量中元素 o_i^2 由式(7)计算。

$$o_i^2 = \begin{cases} 1 & E_o > \theta_{E_o} \\ 0 & E_o < \theta_{E_o} \end{cases} \quad (7)$$

当群体距离势能随着视频序列显示出递增趋势,表明群体正在扩散,反之,表明群体正在聚集。考虑当前帧与前一帧的距离势能变化趋势,计算特征向量中元素 o_i^3 ,如式(8)所示。

$$o_i^3 = \begin{cases} 1 & E_d(t-1) < E_d(t) \\ 0 & E_d(t-1) > E_d(t) \end{cases} \quad (8)$$

然后分别将每一帧的能量特征元素连接起来共同生成特征向量 $O_i = (o_i^1, o_i^2, o_i^3)$,将一类异常行为的多帧图像序列特征向量联合起来生成行为模式 $O = (O_1, O_2, \dots, O_T)$ 。

2 分类识别算法

提取能量特征构造特征向量并生成行为模式后,本文算法通过构建隐马尔可夫模型对未知行为进行分类识别。首先定义 HMM 中涉及到的参数,并加以解释说明,如表 1 所示。

表 1 HMM 参数列表

参数	描述
T	观察序列的长度
$Q = \{q_1, q_2, \dots, q_N\}$	状态集合
N	状态的个数
$V = \{v_1, v_2, \dots, v_M\}$	观测值集合
M	观测值的个数
$A = \{a_{ij} a_{ij} = P(s_{t+1} = q_j s_t = q_i)\}$	状态转移矩阵
$B = \{b_j(k) b_j(k) = P(v_k s_t = q_j)\}$	观测概率矩阵
$\Pi = \{\pi_i \pi_i = P(s_1 = q_i)\}$	初始状态矩阵
$\lambda = \{A, B, \Pi\}$	模型参数集合
$S = \{s_t\}, t = 1, 2, \dots, T$	状态序列
$O = O_1, O_2, \dots, O_T$	观察值序列

训练 HMM 即优化模型参数 $\lambda = \{A, B, \Pi\}$,使得观测序列产生的概率 $P(O | \lambda_i)$ 最大化。在为群体异常行为构建 HMM 时,首先定义模型的隐状态,根据群体异常行为典型行为模式 P 定义相应行为的隐状态集合,确定状态集合 Q 和观测值集合 V 后,根据经验初始化初始状态矩阵 Π 。然后,分别定义前向变量式(9)、后向变量式(10),中间变量式(11)(12)用于模型

参数估计:

$$\alpha_t(i) = P(O_1, O_2, \dots, O_t, s_t = q_i | \lambda) \quad (9)$$

$$\beta_t(i) = P(O_{t+1}, \dots, O_T | s_t = q_i, \lambda) \quad (10)$$

$$\gamma_t(i) = P(s_t = q_i | O_1, \dots, O_T, \lambda) \quad (11)$$

$$\xi_t(i, j) = P(s_t = q_i, s_{t+1} = q_j | O_1, \dots, O_T, \lambda) \quad (12)$$

最后,使用 Baum-Welch 算法对模型参数进行估计,如式(13)~(15)所示。

$$\bar{a}_{ij} = \frac{\sum_{t=1}^{T-1} \xi_t(i, j)}{\sum_{t=1}^{T-1} \gamma_t(i)} \quad (13)$$

$$\bar{b}_i(k) = \frac{\sum_{t \in \{t | O_t = v_k\}} \gamma_t(i)}{\sum_{t=1}^T \gamma_t(i)} \quad (14)$$

$$\bar{\pi}_i = \gamma_1(i) \quad (15)$$

优化模型参数后,得到群体异常行为模型。

为识别未知类型观测序列所属行为类型,首先为每一类异常行为构建并训练一个 HMM $\lambda_i = \{A_i, B_i, \Pi_i\}$,在识别阶段,选择观察序列最匹配的模式即该行为所属分类,用式(16)实现。

$$c^* = \arg \max_i (P(O | \lambda_i)) \quad (16)$$

另外,当给定观测序列 O 和模型参数 λ_i 时,根据贝叶斯准则,即可由前向算法将该分类问题转换为计算 $P(O | \lambda_i)$,产生该观测序列的概率最大的模型(该观测序列行为所在模型),即所属异常行为类型。

3 实验结果与分析

本文实验是在普通 PC 机(CPU 为双核 1.8 GHz, 2 GB 内存)上进行,通过 VS2010 和 MATLAB2010 开发平台编写代码并加载 OpenCV 函数库来实现本文算法,并通过与传统的角点特征进行对比分析验证本文提出算法的准确性。算法分别在公共数据集 PETS 和 UMN 数据集上进行测试。

PETS 数据集是包含同一场景多种视角下的多种不同群体行为的数据集。实验主要采用 PETS 中的群体行为数据,包括群体突聚、突散、突然奔跑等异常行为。将本文 KOD 能量特征提取方法在 PETS 数据集中群体突散行为进行测试,KOD 能量特征曲线如图 2 所示。




图 2 PETS 数据集中突散行为的 KOD 能量曲线

突散行为发生前,如图 2(a) 所示,群体比较集中,有少量运动,因此初期的动能比较小,接近于零;但是当突散行为发生时,如图 2(b) 所示,群体运动变化剧烈,以较高的速度散开;由图 2(c) 动能曲线可直观看出,群体约在第 30 帧处开始加速运动,图中横线表示动能阈值,此处取值 60,代表群体运动剧烈与否的分界线;图 2(d) 中横线代表方向势能的阈值,取值 60,

由方向曲线看出,群体方向势能一直大于阈值,表明个体的运动方向从始至终均比较发散,且稳定发散;图 2(e) 中距离势能曲线在一段时间内呈现较稳定的上升趋势,表明群体中的个体相互距离越来越远。综合三种能量形成 KOD 能量特征,生成相应行为模式,有效且准确地描述了群体突散行为,为群体突散行为类型的检测识别提供了保障,如图 2(f) 所示。

UMN 数据集是一种标准的群体异常行为检测算法测试数据集,包含了草地、大厅、广场三种场景下的群体正常行为和异常行为。针对其中群体突然奔跑行为进行实验,绘制 KOD 能量特征曲线如图 3 所示。




图 3 UMN 数据集中突然奔跑行为的 KOD 能量曲线

群体正常行为如图 3(a) 所示,群体中个体运动比较杂乱无章,运动速度一般,且群体中个体分布不会过于密集,因此初期的动能均小于动能阈值;当群体突然奔跑时,如图 3(b) 所示,群体运动突然发生剧烈变化,以较高的速度向统一的方向突然奔跑;由图 3(c) 动能曲线可以看出,群体约在第 40 帧处开始加速运动,动能发生较大增长,且超过动能阈值,其中动能阈值取值 60;图 3(d) 中方向势能阈值取值 60,由方向曲线看出,群体方向势能一直低于其阈值,表明个体的运动方向从始至终均比较统一,且在 20 帧后处于稳定状态,表明群体运动方向稳定一致;图 3(e) 中距离势能曲线在整个视频序列中呈现平稳趋势,表明群体中的个体相互距离比较稳定,符合群体分布比较平稳的特性。综合三种能量形成 KOD 能量特征,生成突然奔跑的行为模式,描述群体突然奔跑行为,实现对其他突然奔跑行为的准确识别,如图 3(f) 所示。

本文使用交叉验证中的留一法对 PETS 和 UMN 数据集中三种群体异常行为进行训练及识别,得到本文算法的群体异常行为识别率,如表 2 所示。

表 2 基于 KOD 能量特征的群体异常行为识别率

样本及识别率	群体异常行为类型		
	突聚	突散	突然奔跑
视频样本	4	11	11
识别样本	3	11	10
识别率	75%	100%	91%
总识别率	92%		

为验证本算法的准确性,将本文算法与采用传统光流特征的算法进行对比。传统光流只包含群体中个体的运动方向及速度幅值,采用全部角点的光流信息构成群体行为特征向量描述群体行为,并对不同的异常行为训练构建 HMM。由于光流信息主要描述局部状态,而缺乏对群体整体的运动状态描述,因此,在 HMM 中估计状态转移时不能准确地确定光流特征所

处行为状态,并通过不同状态间的转移过程预测异常行为的发生。因此准确率不如 KOD 能量特征高,对比结果如表 3 所示。

表 3 KOD 特征与传统光流特征的对比

算法	测试样本数	识别样本数	识别率/%
光流	26	19	73
KOD 能量	26	24	92

4 结束语

本文针对群体场景监控下的突发性群体异常行为检测识别问题,提出了基于 KOD 能量特征的群体异常行为识别算法。通过定义并提取群体动能、方向势能和距离势能三种能量构成 KOD 能量特征对群体行为进行表征,最后通过使用 HMM 对不同类型的群体异常行为视频序列进行训练及识别,能够有效地检测识别群体异常行为。实验结果表明,该能量特征对群体行为具有较强的描述性,能够有效地识别多种不同群体异常行为。在以后的工作中,笔者会进一步加入群体动能和方向势能的阈值自适应选择步骤,以适应更多的场景,提高群体异常行为识别准确率。

参考文献:

- [1] JACQUES JUNIOR J C S, MUSSERAUPP S R, JUNG C R. Crowd analysis using computer vision techniques[J]. *IEEE Signal Processing Magazine*, 2010, 27(5): 66-77.
- [2] ZHAN Bei-bei, MONEKOSSO D N, REMAGNINO P, et al. Crowd analysis: a survey[J]. *Machine Vision and Applications*, 2008, 19(5): 345-357.
- [3] ANDRADE E L, BLUNSDEN S R B. Hidden Markov models for optical flow analysis in crowds[C]//Proc of the 18th International Conference on Pattern Recognition. 2006: 460-463.
- [4] ANDRADE E L, BLUNSDEN S R B. Modelling crowd scenes for event detection[C]//Proc of the 18th International Conference on Pattern Recognition. 2006: 175-178.
- [5] WANG Bo, YE Mao, LI Xue, et al. Abnormal crowd behavior detection using size-adapted spatio-temporal features[J]. *International Journal of Control, Automation and Systems*, 2011, 9(5): 905-912.
- [6] XIONG Guo-gang, WU Xin-yu, CHEN Yen-lun, et al. Abnormal crowd behavior detection based on the energy model[C]//Proc of IEEE International Conference on Information and Automation. 2011: 495-500.
- [7] MEHRAN R, OYAMA A M. Abnormal crowd behavior detection using social force model[C]//Proc of IEEE Conference on Computer Vision and Pattern Recognition. 2009: 935-942.
- [8] KRATZ L K, NISHINO K. Anomaly detection in extremely crowded scenes using spatio-temporal motion pattern models[C]//Proc of IEEE Conference on Computer Vision and Pattern Recognition. 2009: 1446-1453.
- [9] XU Jing-xin, DENMAN S, FOOKES C B, et al. Unusual event detection in crowded scenes using bag of LBPs in spatio-temporal patches[C]//Proc of International Conference on Digital Image Computing Techniques and Applications. 2011: 549-554.
- [10] 新海熊,熊庆宇,石欣,等. 基于角点动能模型的电梯轿厢内异常行为检测[J]. *计算机应用研究*, 2012, 29(2): 775-778.