

基于因果网络分析的小规模人群行为识别

张旭光 刘春霞 左佳倩

燕山大学电气工程学院, 河北 秦皇岛 066004

摘要 人群行为识别是计算机视觉领域的重要研究课题, 针对小规模松散人群兼具微观层面与宏观层面行为特征这一特点, 提出了一种基于因果网络分析的小规模人群行为识别方法。先将各行人目标看成网络的节点, 利用协方差跟踪获得目标的运动轨迹, 并利用 Granger 因果关系检验来评估目标之间的相互作用, 并用此因果关系来构建成对因果网络和成组因果网络, 计算复杂网络的平均路径长度, 介数, 聚类系数等参数特性, 以表达和识别聚集、聊天、分离、徘徊、相遇及同行等6种人群行为, 实验结果表明, 提出的算法能够有效的表达和识别人群行为。

关键词 机器视觉; 人群行为识别; 协方差跟踪; Granger 因果; 复杂网络

中图分类号 O432

文献标识码 A

doi: 10.3788/AOS201535.0815001

Small Scale Crowd Behavior Recognition Based on Causality Network Analysis

Zhang Xuguang Liu Chunxia Zuo Jiaqian

Institute of Electrical Engineering, Yanshan University, Qinhuangdao, Hebei 066004, China

Abstract Crowd behavior recognition is an important research topic in computer vision field. Amid at the properties that the behavior of small scale crowd have the features both microcosmic and macroscopic, a small scale crowd recognition method based on causality network analysis is proposed. The trajectories of each pedestrians are calculated by covariance tracking to gain the nodes of crowd network. The Granger causality test is used to estimate the relationship between two pedestrians. Based on these causations, two types of complex network are generated which are pair-complex network and group-complex network. Some features of network such as the average path length, betweenness and clustering coefficient are extracted to recognize the six classifications crowd behavior (gather, chat, split, linger, meet and together). Experimental results show that the proposed method can express and recognize crowd behavior effectively.

Key words machine vision; crowd behavior recognition; covariance tracking, granger causality test, complex network

OCIS codes 150.0155; 150.0135; 150.1135

1 引言

人群行为分析是计算机视觉领域的研究热点和难点, 在公共场所监控、安全管理等领域有着迫切的需求。传统的人群行为分析方法主要可分为宏观和微观两类, 前者将人群看作一个整体, 从群体的全局外部表现入手分析其行为。如 Ernesto 等^[1]利用光流和非监督特征提取的方法识别大规模人群的紧急事件, Ge 等^[2]利用 Bernoulli 形状模型统计人群中人数, Kratz 等^[3]利用时空运动模型检测大规模人群的非正常行为, 胡波等^[4]利用小波和灰度共生矩阵评估人群密度, Xiong 等^[5]依据能量模型检测非常规人群行为, 此类方法适合处理规模较大或具有共同运动模式的人群, 但忽视了个体的位置、运动方向等特征, 不适合处理规模不大, 且运动模式松散的人群。而微观的方法从个体行为入手, 跟踪个体目标^[6-8], 利用目标的运动轨迹或姿态去识别人群行为。如 Tu 等^[9]通过

收稿日期: 2014-12-29; 收到修改稿日期: 2015-04-08

基金项目: 国家自然科学基金(61271409)、国家杰出青年科学基金(61025019)、中国博士后科学基金(2012M510768、2013T60264), 河北省自然科学基金(F2013203364)、中国留学基金(2011813018)

作者简介: 张晓光(1978—), 男, 博士, 教授, 主要从事视频图像分析方面的研究。E-mail: zhangxg@ysu.deu.cn

检测人的头、肩定位人体;Blunsden等^[10]利用AdaBoost分类器检测视频中的打斗场景,Guo等^[11]利用形状及运动模板检测人群个体运动,胡芝兰等^[12]根据目标的运动方向检测走廊内的异常事件,此类方法不利于揭示行人间的相互关系以及人群整体表现。由于小规模人群常常以三三两两的小团体形式出现,且团体间的运动具有某种关联性,因此,分析小规模人群行为的方法兼具微观与宏观特性。

为了即能代表人群个体运动的微观特性,同时又在宏观层面上体现多个个体的运动所蕴含的整体信息,有必要提出一种方法在人群运动的微观和宏观特性之间搭建一个桥梁。复杂网络是包含大量个体及个体间相互作用的系统,恰好可以被用来建立宏观与微观间的桥梁,网络可被表达成用来描述个体(顶点)及个体间相互作用(边)的图^[13]。复杂网络已被用于分析脑电信号^[14],揭示大气和海洋关键区相互作用关系,以及评估银行风险等领域。人群行人间相互关联,恰好可依此将人群构成一复杂网络,进而依据网络的特性识别其行为。根据人群运动的特点,可通过跟踪定位行人的位置,以每个行人作为网络的一个顶点,而其相互间的影响可被用来评估边的权值,由于人群行人在运动时,其个体间或多或少的存在相互作用,因此可挖掘行人间运动的因果关联度来刻画个体间的相互影响程度,Granger因果检验模型对于刻画时间序列中两个变量间的相互影响十分有效,而行人间的关联度往往由两两间的相互作用开始,因此十分适合用于评估行人间相互关联度,Granger因果检验主要基于时间序列因果性的定义,即如果时间序列 $y(t)$ 会引起 $x(t)$ 的发生,或对 $x(t)$ 有影响,则认为两序列间具有 Granger 因果关系,并通常用线性自回归模型来分析,目前 Granger 因果检验已被用于股票预测^[15]、神经信号分析^[16]和脑核磁图像分析^[17]等领域,近几年,开始吸引了计算机视觉领域学者的注意,如利用 Granger 因果判断两个目标间跟随、追逐、相遇等几种因果关系^[18-19];利用多变量点过程对视频中的事件进行编码,并根据 Granger 因果检验识别视频中的周期性动作^[20]。

2 网络的节点定位

本文试图构建人群网络以识别人群行为,将人群中每个目标作为节点,目标间的因果作用作为边,相互作用的大小作为网络权值,构造复杂网络,用有向加权图 $G(V,E,W)$ 表示人群的复杂网络,为了确定网络节点,需要在一段视频中获得目标运动的轨迹,本文采用融合多种特征的协方差匹配算法来跟踪各行人目标。

协方差匹配的基本原理:在第一帧中初始化一目标模板区域,并计算该区域的协方差矩阵特征,从而在随后的各帧图像的候选区域中匹配与模板最相似的区域,将该区域视为目标在当前帧的位置。假定一图像区域 R 大小为 $M \text{ pixel} \times N \text{ pixel}$, 对应于每一个像素点 (x,y) , 该像素的特征向量用 f_k 来表示,若提取该像素的颜色、亮度、梯度以及空间距离特征,则

$$f_k = [R(x,y) \quad G(x,y) \quad B(x,y) \quad d(x,y) \quad I(x,y) \quad I_x(x,y) \quad I_y(x,y)], \quad (1)$$

式中 $R(x,y)$ 、 $G(x,y)$ 、 $B(x,y)$ 代表颜色特征, $I(x,y)$ 表示图像的亮度特征, $I_x(x,y)$ 表示 x 方向的梯度特征, $I_y(x,y)$ 表示 y 方向的梯度特征, $d(x,y)$ 代表该像素与目标区域中心的距离, $d(x,y) = \sqrt{(x'^2 + y'^2)}$, $(x',y') = (x - x_0, y - y_0)$, 其中, (x',y') 是像素点相对于区域中心 (x_0, y_0) 的坐标。则其 d 维特征的协方差矩阵 C_R 可表示为

$$C_R = \frac{1}{MN} \sum_{k=1}^{MN} (f_k - \mu_R)(f_k - \mu_R)^T, \quad (2)$$

式中 μ_R 是区域 R 中各个像素点对应特征向量的均值。

为了在当前帧中确定与给定目标最相似的区域,需要计算目标区域与候选区域的协方差矩阵间的距离。文献[21]提出一种利用两个矩阵的广义特征值的对数平方和来计算协方差矩阵间距离的测量方法,本文依照此方法度量协方差矩阵间的距离为

$$\rho(C_i, C_j) = \sqrt{\sum_{k=1}^d \ln^2 \lambda_k(C_i, C_j)}, \quad (3)$$

式中 $\{\lambda_k(C_i, C_j)\}$ 是矩阵 C_i 与 C_j 的广义特征值,根据下式计算, $|\lambda C_i - C_j| = 0$ 。

3 网络的边的确立

为构建人群运动的网络模型,在确定节点的基础上,还需要确定网络的边的连接权重,可利用目标间的因

果关联度来评估目标间的联系程度,本文利用成对因果和成组因果两种因果关联计算方式,评估两目标间的因果关联度,并以此分别构建成组因果网络和成对因果网络,进而融合两个网络的特征参数,识别人群行为。

3.1 成对因果的定义

成对因果关系在描述人群中两两目标之间的关系时,只考虑两两目标之间是否存在因果作用及其它们的相互作用强度,不考虑其他目标对这两个目标的影响。Zhou 等^[18]提出在基于目标轨迹基础上,用 Granger 因果关系检验来定量评估两两目标之间的因果特性,用因果比率和反馈比率来表示,它们分别表示一个目标作用于另一个目标的强度以及另一个目标反作用的强度。

对于同时运动的两个人的运动轨迹分别为 $P_i(t)$ 和 $P_j(t)$,假设在一段时间内两目标的运动轨迹的相互作用是平稳过程,首先用 q 阶线性预测器对目标 i 的轨迹进行建模,即

$$P_i(t) = \sum_{m=1}^q \lambda_m P_i(t-m) + \sum_{m=1}^q \gamma_m P_j(t-m) + \varepsilon_{it}, \quad (4)$$

式中 λ_m 和 γ_m 为线性回归模型的系数, ε_{it} 为模型的误差项,其标准偏差可以表示为 $\delta[P_i(t)/P_i(1:t-m), P_j(1:t-m)]$, 当 γ_m 的值为 0 时,只有目标 i 的运动轨迹参与建模,可以得到 ε_{it}' , 其标准偏差为 $\delta[P_i(t)/P_i(1:t-m)]$, 根据 Granger 因果关系检验原理,可以得到目标 i, j 之间的因果比率为

$$gc_{j \rightarrow i} = \ln \frac{\delta[P_i(t)/P_i(1:t-m)]}{\delta[P_i(t)/P_i(1:t-m), P_j(1:t-m)]}, \quad (5)$$

与因果比率的计算过程相似,同样可以得到目标 i, j 之间反馈比率为

$$gc_{i \rightarrow j} = \ln \frac{\delta[P_j(t)/P_j(1:t-m)]}{\delta[P_j(t)/P_i(1:t-m), P_j(1:t-m)]}. \quad (6)$$

因果比率和反馈比率反映出的是误差项表示的信息,能较好地表示出两目标相互作用的强度。由因果比率和反馈比率可以得到一个 $n \times n$ (n 为目标的个数)的因果关联强度矩阵 gc_p , 并将其作为构建成对因果网络的依据。

3.2 成组因果定义

在一个人群中,通常包含三个或三个以上的行人,因此在衡量两目标间相互作用时,也应包含其他行人的影响。在不包含目标 j 的情况下,对目标 i 用线性回归方程预测得到的标准偏差为 $\delta[P_i(t)/U(1:t-m) - P_j(1:t-m)]$ (U 表示所有目标的轨迹信息),同样可以得到所有目标都包含的情况下,线性回归标准偏差为 $\delta[P_i(t)/U(1:t-m)]$, 此时可以得到目标 i, j 的因果比率为

$$gc_{j \rightarrow i} = \ln \frac{\delta[P_i(t)/U(1:t-m) - P_j(1:t-m)]}{\delta[P_i(t)/U(1:t-m)]}, \quad (7)$$

同样可以得到目标 i, j 的反馈比率为:

$$gc_{i \rightarrow j} = \ln \frac{\delta[P_j(t)/U(1:t-m) - P_i(1:t-m)]}{\delta[P_j(t)/U(1:t-m)]}. \quad (8)$$

在计算完所有目标之间的因果关系后,可以得到一个 $n \times n$ (n 为目标的个数)的因果关联强度矩阵 gc_g , 并将其作为构建成组因果网络的依据。

4 因果网络模型的特征提取

不同的行为具有不同的人群特征,同时构造的因果复杂网络模型也不同。而且在同一种人群行为中,人与人之间的相互作用不同,每个人在网络中的重要性也是不同的。在本文中采用复杂网络的统计特征参数来表达人群特征,并选取如下几个特征参数。

平均路径长度反映了网络中各目标节点间的分离程度,平均路径长度是通过网络中两两节点间的最短距离来计算的,对一个网络中所有两两节点间的最短距离求均值就是整个网络的平均路径长度,网络的平均路径长度越大说明网络中节点间的分离程度越大,反之,则分离程度越小。不同行为构成的网络中目标

与目标间的关系不同,所计算出的平均路径长度也不同,因此,可以用平均路径长度来表达人群行为,计算公式为

$$L = \frac{2}{N(N+1)} \sum_{i=1}^N \sum_{j=1}^N g^{C_{i \rightarrow j}}. \quad (9)$$

介数反映了相应的目标在整个人群中的作用和影响力,可以评估目标在网络中的重要性,节点 k 的介数计算公式为

$$g_k = \sum_{i \neq j} \frac{d_k(i,j)}{d(i,j)}, \quad (10)$$

式中 $d(i,j)$ 为节点 i 和 j 之间最短路径的条数, $d_k(i,j)$ 为经过节点 k 的节点 i 和 j 之间最短路径的条数. 一种人群行为中影响力最强的目标与另一种行为中影响力最强的目标不同,反应其影响力的介数也不同,同样,影响力最弱的目标也是如此. 因此,不同人群行为构成的网络,可以根据介数在一定程度上反映出相应行为中影响力最强及最弱的节点. 所以,用介数的最大值 g_{\max} 、最小值 g_{\min} 、平均值 g_{ave} 作为行为特征.

聚合系数被用来描述网络中各目标的聚集程度,即各目标之间的关系有多紧密,不同人群行为间目标联系的紧密程度不同,比如徘徊行为中各目标的运动是无序的,目标联系松散,聚合系数较小,而聚集行为中各目标的运动遵循一定的规则,目标联系相对紧密,聚合系数就较大,因此采用聚合系数作为人群行为特征,计算公式为

$$C = \frac{1}{N} \sum_{i=1}^N \frac{2E_i}{k_i(k_i - 1)}, \quad (11)$$

式中 E_i 为与节点 i 相连的边数, k_i 为与节点 i 相连的节点数.

因此,实验过程中采用了三种特征向量,它们分别为根据成对因果网络和成组因果网络提取的特征向量,以及它们的组合向量. 其中,成对因果网络特征向量表示为

$$\mathbf{V}^p = [L^p, g_{\max}^p, g_{\min}^p, g_{\text{ave}}^p, C^p], \quad (12)$$

成组因果特征向量表示为

$$\mathbf{V}^g = [L^g, g_{\max}^g, g_{\min}^g, g_{\text{ave}}^g, C^g], \quad (13)$$

组合向量表示为

$$\mathbf{V}^c = [\mathbf{V}^p, \mathbf{V}^g]. \quad (14)$$

5 实验分析

本文实验所使用的视频数据均是在室外露天场地采集的,相机为 MV Capture v2.2 工业相机,帧率为 30 frame/ps, 图片大小为 480 pixel \times 640 pixel. 共设计并采集了 6 种特定的行为,这 6 种行为分别为:聚集、聊天、分离、徘徊、相遇、同行,图 1 通过目标的运动轨迹展示了 6 种行为的含义,图中各目标都位于第一帧的起始位置,曲线表示的是各个目标的运动轨迹,目标的运动轨迹是根据基于协方差匹配的目标跟踪算法得到的,线的终点位置为各目标运动停止的位置,各别帧有严重遮挡而造成目标丢失时,进行了人工修正. 实验中将每段视频剪切成若干小片段用于建立数据库,下面分别以 4 人组和 7 人组的人群行为分类结果验证本文算法的有效性.

1) 4 人组人群行为分析

实验的视频样本数如表 1 所示,实验采用支持向量机分类算法对 4 人组人群行为进行分类,分类效果如图 2 所示,图中 G 表示聚集行为, C 表示聊天行为, S 表示分离行为, L 表示徘徊行为, M 表示相遇行为, T 表示同行行为,成对网络特征是用成对因果复杂网络所提取的特征,成组网络特征是用成组因果复杂网络所提取的特征,综合特征表示将成对网络特征和成组网络特征组合在一起对各行为进行分类的特征,以下实验中都用上述方式表示.

从图中可以看出,对于聚集、聊天、分类、相遇 4 种行为,用三种特征均获得良好的效果,除分离行为采用成对因果略优于综合因果外,均是综合因果特征获得最好的识别率,而徘徊和同行两种行为的识别率相对较低,对于同行行为,用综合特征得到的识别率最高,为 79%,而成对特征和成组特征分别为 67% 和 70%,而

对于徘徊行为,最高识别率才为75%,也是用综合特征得到的,成对网络特征识别率为61%,成组特征识别率仅为45%,同时,本文比较了利用k-近邻分类方法对综合特征进行分类与支持向量机方法的结果,利用k-近邻分类方法的识别率仅聊天和徘徊超过了80%,其余都要在70%以下,弱与本文方法。

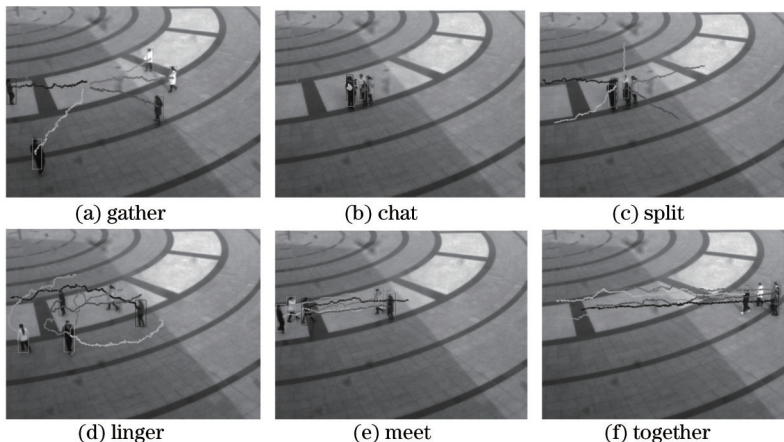


图1 6种人群行为示意图

Fig.1 Schematic of 6 crowd behavior

表1 4人组视频采集及实验样本数统计表

Table 1 Video sampling and experimental sample statistics of 4 people

Statistical items	Gather	Chat	Split	Liger	Meet	Together
Total number of small video clips	136	91	169	150	120	171
Training sampla number	91	60	110	100	80	110
Test sample number	45	31	59	50	40	61

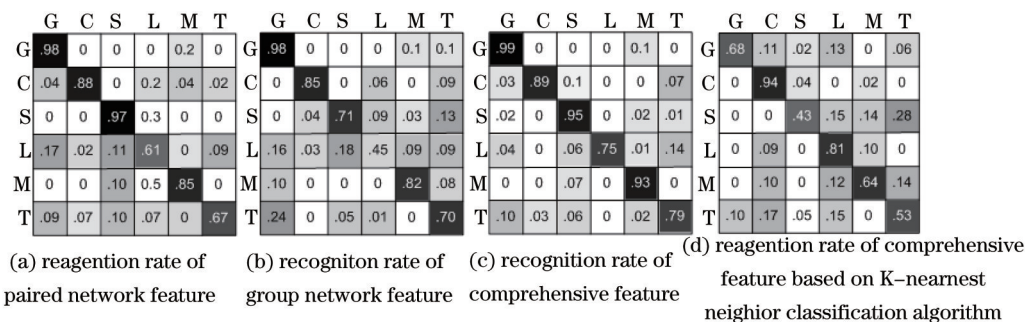


图2 4人组人群行为的识别率

Fig.2 Recognition rate of crowd behavior of 4 people

2) 7人组人群行为分析

7人组的视频采集情况及实验样本数统计结果如表2所示,用支持向量机算法对人群行为进行分类的结果如图3所示,可以看到,分类效果最好的是聚集行为、聊天行为和分离行为,利用成对因果特征和综合特征都达到了90%以上;其次是相遇行为,最高识别率达到了89%;分类效果最差的是徘徊和同行两种行为,虽然两种行为的最高识别率都在70%以上,其中徘徊行为的最高识别率为81%,但是相比于其他行为来说,它们的识别率是较低的,徘徊行为在用成组网络特征进行分类时,识别率只有52%,成对特征识别率也仅为67%,远低于综合特征。同时,在于k-近邻分类方法的比较中,本文算法在所有行为的识别率都占有明显优势。

表2 7人组视频采集及实验样本数统计表

Table 2 Video sampling and experimental sample statistics of 7 people

Statistical items	Gather	Chat	Split	Liger	Meet	Together
Total number of small video clips	175	98	136	136	162	153
Training sample number	112	66	83	83	102	103
Test sample number	63	32	53	53	60	50

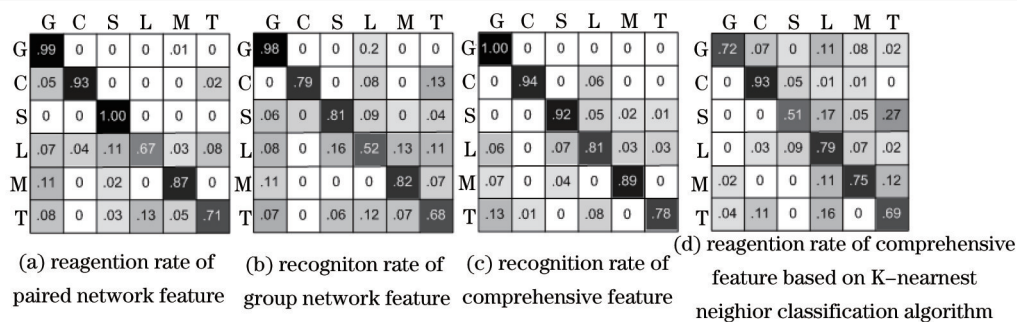


图 3 7 人组人群行为的识别率

Fig.3 Recognition rate of crowd behavior of 7 people

综上所述,本文提出的利用综合特征构建网络的识别效果要好于单纯应用成对和成组特征,并且利用支持向量机的分类效果要优秀于k-近邻分类,在6种行为的分类中,徘徊行为的分类效果相对较差,其原因是徘徊行为具有较强的随机性,在对视频进行小片段分解时,其各段行为的一致性更容易受到影响,因此识别率较低。

6 结 论

介绍了一种利用因果网络来分析人群行为的方法。从运动目标的轨迹着手,计算 Granger 因果检验值,定量评估各个体间相互作用和影响的程度,并以人群个体为顶点,以个体间相互影响程度为边权重构建因果网络,提取网络平均路径长度、介数、聚类系数等参数来分析人群行为,贡献如下:

- 1) 结合目标运动轨迹的微观特征,构建复杂网络,并从宏观层面分析网络的特性,以此在宏观与微观层面搭起一个桥梁,为小规模人群行为识别提供了新的解决思路;
- 2) 利用 Granger 因果关系检验算法度量各运动目标间的因果关联度,以此量化网络的边的权重和结构,为因果复杂网络的构建提供了前提条件;
- 3) 挖掘了网络属性中适用于表达人群行为的平均路径长度、介数、聚类系数等几种特征参数,以此识别人群行为。

未来的工作将着眼于通过网络分析的方法识别人群中的局部行为或异常行为,以更大的发挥网络分析的优势。

参 考 文 献

- 1 Andrade E L, Blunsden S, Fisher R B. Modelling crowd scenes for event detection[C]. The 18th International Conf Pattern Recognition, 2006, 1: 175-178.
- 2 Ge W, Collins R T. Marked point processes for crowd counting[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2009: 2913-2920.
- 3 Kratz L, Nishino K. Anomaly detection in extremely crowded scenes using spatio-temporal motion pattern models[C]. Computer Vision and Pattern Recognition, 2009: 1446-1453.
- 4 Hu Bo, Li Xiaohua, Shen Lansun. Estimation crowd density for surveillance[J]. Journal of Circuits and Systems, 2007, 12(6): 19-22.
胡 波, 李晓华, 沈兰荪. 场景监控中的人群密度估计[J]. 电路与系统学报, 2007, 12(6): 19-22.
- 5 Xiong G, Cheng J, Wu X, et al.. An energy model approach to people counting for abnormal crowd behavior detection[J]. Neurocomputing, 2012, 83: 121-135.
- 6 Jin Biao, Hu Wenlong, Wang Hongqi. Moving-objects interaction recognition based on spatial-temporal semantic information[J]. Acta Optica Sinica, 2012, 32(5): 0515002.
金 标, 胡文龙, 王宏琦. 基于时空语义信息的视频运动目标交互行为识别方法[J]. 光学学报, 2012, 32(5): 0515002.
- 7 Liang Min, Liu Guixi. Multi-object tracking algorithm based on adaptive mixed filtering[J]. Acta Optica Sinica, 2010, 30(9): 2554-2561.
梁 敏, 刘贵喜. 基于自适应混合滤波的多目标跟踪算法[J]. 光学学报, 2010, 30(9): 2554-2561.
- 8 Wang Zebing, Yang Wei, Qin Li. Target tracking based on particle swarm optimization using dynamic pyroelectric infrared sensor[J]. Acta Optica Sinica, 2014, 34(10): 1004001.
王泽兵, 杨 卫, 秦 丽. 基于粒子群算法的动态热释电目标跟踪[J]. 光学学报, 2014, 34(10): 1004001.

- 9 Peter T, Thomas S, Gianfranco D, *et al.*. Unified crowd segmentation[C]. 10th European Conference on Computer Vision, 2008: 691–704.
- 10 Scott B, Robert F. Pre-flight detection– classification of fighting situations using hierarchical AdaBoost[C]. Proceedings of the Fourth International Conference on Computer Vision Theory and Applications, 2009, 2: 303–308.
- 11 Guo P, Miao Z. Action detection in crowded videos using masks[C]. 20th International Conference on Pattern Recognition, 2010:1767–1770.
- 12 Hu Zhilan, Jiang Fan, Wang Guijin, *et al.*. Anomaly detection based on motion direction[J]. Acta Automatica Sinica, 2008, 34(11): 1348–1357.
胡芝兰, 江帆, 王贵锦, 等. 基于运动方向的异常行为检测[J]. 自动化学报, 2008, 34(11): 1348–1357.
- 13 Wu Jinshan, Di Zengru. Complex networks in statistical physics[J]. Progress in Physics, 2004, 24(1): 18–46.
吴金闪, 狄增如. 从统计物理学看复杂网络研究[J]. 物理学进展, 2004, 24(1): 18–46.
- 14 Hou Fengzhen, Dai Jiafei, Liu Xinfeng, *et al.*. Phase synchrony in the cerebral infarction electroencephalogram based on the degree of network–links[J]. Acta Phys Sin, 2014, 63(4): 040506.
侯凤贞, 戴加飞, 刘新峰, 等. 基于网络连接度指标的脑梗死患者脑电信号相同步分析[J]. 物理学报, 2014, 63(4): 040506.
- 15 Su Yanli, Zhuang Xintian. On the correlation between development of stock market and economic growth in China[J]. Journal of Northeastern University(Social Science), 2010, 12(2): 129–134.
苏艳丽, 庄新田. 中国股市发展与经济增长的相关性研究[J]. 东北大学学报(社会科学版), 2010:12(2): 129–134.
- 16 Aatira G N, Govindan R, Neeraj J, *et al.*. Analyzing multiple spike trains with nonparametric granger causality[J]. Journal of Computational Neuroscience, 2008, 27(1): 55–64.
- 17 Sato J R, Fujita A, Cardoso E F, *et al.*. Analyzing the connectivity between regions of interest: An approach based on cluster Granger Causality for fMRI data analysis[J]. Neuroimage, 2010, 52(4): 1444–1455.
- 18 Zhou Y, Ni B B, Yan S C, *et al.*. Recognizing pair–activities by causality analysis[J]. ACM Trans Intell Syst Technol, 2011, 2(1): 5.
- 19 Ni B B, Yan S C, Kassim A. Recognizing human group activities with localized causalities[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2009: 1470–1477.
- 20 Prabhakar K, Oh S, Wang P, *et al.*. Temporal causality for the analysis of visual events[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2010: 1967–1974.
- 21 Förstner W, Moonen B. A Metric for Covariance Matrices[R]. Dept of Geodesy and Geoinformatics, Stuttgart University, 1999.

栏目编辑: 张浩佳