

# 基于 Girvan-Newman 分裂的人群异常事件检测算法

李文韬, 付晗, 郝真, 滕燕, 杨林, 赵沛然, 张学武\*

河海大学物联网工程学院, 江苏 常州 213022

**摘要** 针对传统基于群体运动状态分析的异常事件检测方法对场景语义信息描述不足的问题, 引入了复杂网络中运用社区发现的 Girvan-Newman(GN)分裂算法。将具有相似运动特征且位置相近的行人划分为多个群组, 利用群组运动强度和群组数量的变化, 描述群组在正常和异常场景中的差异, 检测异常事件的发生。通过实验验证, 该算法能够在丰富场景语义信息的同时实现对异常事件的准确检测。

**关键词** 机器视觉; 运动特征; GN 分裂; 异常事件检测算法

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP57.061506

## Detection Algorithm of Crowd Abnormal Event Based on Girvan-Newman Splitting

Li Wentao, Fu han, Hao Zhen, Ten Yan, Yan Lin, Zhao Peiran, Zhang Xuewu\*

College of Internet of Things Engineering, Hohai University, Changzhou, Jiangsu 213022, China

**Abstract** In terms of the problem that the traditional detection method of crowd abnormal events based on group motion state analysis does not describe the semantic information of scene adequately, the Girvan-Newman (GN) splitting up algorithm found by the community in the complex network is introduced. The pedestrians with similar motion characteristics and similar positions are divided into multiple groups, and the differences among the groups in normal and abnormal scenes are described and the occurrence of abnormal events is detected with the changes in group motion intensity and group number. Through experimental verification, the proposed algorithm can accurately detect abnormal events while enriching the semantic information of the scene.

**Key words** machine vision; motion characteristics; GN splitting; abnormal event detection algorithm

**OCIS codes** 150.0155; 100.5010; 100.2000; 100.2960

## 1 引言

人群异常事件检测是机器视觉中的关键研究领域。通过分析监控视频采集到的数据, 实现对人群异常事件快速准确的检测, 有助于提高相关部门的响应速度与救援效率, 从而减少公众场所的人身和财产损失, 提升监控系统的智能化水平。

现有研究主要利用图像处理和机器学习等技术, 通过描述人群运动特征检测异常事件的发生。社会力模型是一种结合社会学理论的异常事件检测算法, 利用行人的运动速度、方向等运动特征, 描述“社会学”中驱动力、排斥力、吸引力和环境力等属

性, 进而通过分析群体之间以及群体与环境间的相互作用力检测异常事件的发生<sup>[1]</sup>。光流直方图(HOF)模型是一种基于光流算子的经典异常事件检测算法, 通过获取光流的直方图统计特性描述场景中人群运动特征, 并利用分类器对其进行学习与检测<sup>[2]</sup>。密集轨迹(DT)模型是一种基于多特征融合的异常检测算法, 将梯度直方图、光流直方图以及运动边界直方图三种描述人群运动的特征进行融合, 并利用词袋模型对特征进行编码, 最后使用支持向量机对其进行学习与判别。之后又有研究人员从特征编码和正则化两个角度对其进行优化, 提高了对异常事件的检测性能<sup>[3]</sup>。能量模型(EM)是一种

收稿日期: 2019-08-20; 修回日期: 2019-08-26; 录用日期: 2019-09-06

基金项目: 国家重点研发计划(2016YFC0401606)、国家自然科学基金(61671202, 61573128, 61701169)

\* E-mail: Lab\_112@126.com

结合人群数量统计和异常事件检测的检测模型,通过在已建立背景模型的场景上进行能量与边缘信息的计算,估计场景中行人的数量并计算人群熵,最后利用门限阈值判别检测场景中的人群分布指数<sup>[4]</sup>以及是否发生异常事件。也有大量研究利用深度学习强大的特征表示与学习能力,从群体运动状态分析的角度检测异常事件的发生<sup>[5-7]</sup>。

上述方法都是通过高度抽象的场景特征检测异常事件是否发生,缺乏对场景语义信息的细节刻画,只有 EM 能够提供较低层次的语义信息。加入更丰富的场景语义信息,不仅符合人类的认知方式,也增强了检测方法的可解释性,且进一步提高了对异常事件的检测精度<sup>[8]</sup>。因此,本文提出了一种基于 GN(Girvan-Newman)分裂算法的人群异常事件检测算法。将复杂网络中用于社区发现的 GN 分裂算法引入人群异常事件检测中,把具有相似运动特征且位置相近的行人划分为多个群组,利用群组运动强度和群组数量的变化,描述群组在正常和异常场

景中的差异,检测异常事件的发生。实验结果显示,基于 GN 分裂的人群异常事件检测算法相较于同类型算法,能够在丰富场景语义信息的同时,提高对人群异常事件检测的召回率。

## 2 算法实现

### 2.1 算法概述

基于 GN 分裂的人群异常事件检测算法基本流程:1)利用光流法提取场景中目标的运动特征。提取时利用图像金字塔优化大尺度运动检测精度不足的问题,然后对特征进行网格化处理;2)利用复杂网络中用于社区发现的 GN 分裂算法。将图像映射为无向图,建立和删除无向图结点间的连接关系,改变无向图结构的方式,对具有相似运动特征、位置相邻的行人进行群组划分;3)利用群组运动强度和群组数量的变化描述群组在正常和异常场景中的属性差异,检测异常事件的发生,算法流程图如图 1 所示。




图 1 基于群组分析的异常事件检测算法流程图

Fig. 1 Flow chart of abnormal event detection algorithm based on group analysis

根据光流算子的特点对待测监控视频图像提出假设:1)待分析场景为简单的平面场景,即场景中的各个物体位置不存在明显的高度差异;2)监控相机处于相对静止状态,即监控相机不因任何外力而运动,若因外力撞击、人为操控等产生运动,行人自身的运动会与相机运动叠加导致真实的运动特征抵消或增强,因此不能准确得出目标的运动状态;3)场景中运动目标仅为行人;4)满足光流法中亮度恒定的条件。

### 2.2 运动特征提取

异常事件的发生通常伴随着场景内人群运动状态的剧烈变化,通过提取场景内人群运动特征来检测异常事件的方法灵活性高、鲁棒性强。而基于运动特征的检测方法能够过滤场景中的无关区域(如静止不动的背景),减少冗余分析。光流算子是一种能有效反映目标运动状态的特征描述算子,利用图像序列中像素在时间域上的变化以及相邻帧之间的相关性,寻找上一帧与当前帧之间存在的对应关系,

从而获得相邻帧之间物体的运动信息。基于此提出了一种基于图像金字塔的 Farneback 光流法<sup>[9]</sup>提取场景中运动特征, Farneback 光流法是一种基于梯度信息的稠密光流算子。根据光流算子的特点得出图像上一点 $(x, y)$ 在水平和垂直方向上的速度分量 $u, v$ 。考虑到异常事件发生时,仅利用光流算子检测人群剧烈的运动状态精度较低的问题,通过图像金字塔方法对该算法进行优化。通过图像金字塔将一个小尺度图像的大运动转换为一个大尺度图像的小运动,利用大尺度图像小运动估算小尺度图像中的大运动,优化可能发生的人群剧烈运动,提高了检测精度。最终获取图像中人群运动特征的运动强度 $X_{\text{mag}} = \sqrt{u^2 + v^2}$ 和运动方向特征 $X_{\text{ang}} = \arctan \frac{v}{u}$ 。

在提取运动特征后对特征进行网格化处理,以便于群组划分。在原始图像中以步长 $s$ 对图像进行区域划分,得到图像区域集合 $r = \{r_i\}, i = 1, 2, \dots,$

$M \times N$ , 其中  $M = \frac{X_{width}}{s}$ ,  $N = \frac{X_{height}}{s}$ ,  $X_{width}$ ,  $X_{height}$  分别为输入图像的宽、高。计算图像区域所含像素归一化后的运动强度均值  $i_{mag}$  和方向均值  $i_{ang}$ , 并将其作为图像区域  $r_i$  的属性, 即  $\{i_{mag}, i_{ang}\} \in r_i$ 。

### 2.3 行人群组划分

GN 分裂是一种在复杂网络中用于社区发现的无向图聚类算法<sup>[10]</sup>, 其基本思想: 在构建好的复杂网络中, 计算网络中连接相邻点所在边的边介数, 通过不断删除网络中具有最大边介数的边, 从整个网络中划分出独立的社团。GN 分裂算法为区分一个社区的内部连接和社区与社区之间的连接提供了一种有效的度量标准。边介数是将两个独立的社团从整体网络中分裂出来, 从而形成两个单独聚类的有效评价指标。只要找到最大边介数边连接的两个顶点, 就可以认为这两个顶点属于两个不同的类别。一旦将这条边从网络中删除, 则两个顶点不再有直接联系。重复执行该算法直到满足停止条件, 最终划分出所有独立的社团。基于图论的图像分割方法是一种常见且有效的方法<sup>[11-13]</sup>, 也有相关研究将 GN 分裂算法运用到图像处理领域中<sup>[14]</sup>。实验中利用 GN 分裂算法




图 2 群组划分示意图。(a) 建立连接; (b) 群组划分

Fig. 2 Group division diagram. (a) Connection establishment; (b) group division

边  $e_{ij} \in e$  所连接的一对结点代表的图像区域为  $(r_i, r_j)$ , 其运动特征相似性为  $S_{ij}$ , 边权重  $\{w_{ij}\} \in W$ 。群组运动相似性由方向相似性  $S_{ang}$  和强度相似性  $S_{mag}$  两个部分组成, 其中

$$S_{ang} = \begin{cases} \cos \theta, & 0 \leq \theta < \theta_{th} \\ 0, & \theta \geq \theta_{th} \end{cases}, \quad (1)$$

式中,  $\theta = |i_{ang} - j_{ang}|$  为区域  $(r_i, r_j)$  运动特征中方向属性的夹角,  $\theta_{th}$  为运动方向夹角阈值, 实验中设  $\theta_{th} = 60^\circ$ 。

$$S_{mag} = 1 - \lambda \times |i_{mag} - j_{mag}|, \quad (2)$$

式中,  $\lambda$  为对计算结果赋予的归一化权重。为保证  $S_{ij}$  具有相同的贡献度, 由  $S_{ang}$  和  $S_{mag}$  共同表征为

$$S_{ij} = \begin{cases} 0, & S_{ang} = 0 \\ S_{ang} + S_{mag}, & S_{ang} > 0 \end{cases} \quad (3)$$

将具有相似目标方向、运动状态且位置相邻的行人进行划分与组合, 得到多个行人群组, 进而通过刻画群组的运动特征和结构在不同场景中的变化实现对异常事件的检测。

#### 2.3.1 图像与无向图映射

首先初始化无向图中的结点以及结点间的连接。将特征划分为  $M \times N$  个互不重叠区域的集合, 按  $i_{mag} \leq \overline{i_{mag}}$  条件筛选出无明显运动特征的区域, 其中  $\overline{i_{mag}}$  为场景中所有区域运动强度属性的均值。

筛选后剩余区域集合记作  $r_j$ ,  $j$  表示区域集合的个数。将  $r_i$  映射为无向图  $G$  中的结点  $n_i$ , 获得结点集合  $n = \{n_i\}$ 。根据  $r_i$  在图像中的邻接关系, 构建结点对  $(n_i, n_j)$  的连接边  $e_{ij}$ , 得到  $G$  中边的集合  $e = \{e_{ij}\}$ , 即  $G = \{e, n\}$ 。实验中采用的算法以  $r_i$  的四邻域判断邻接关系, 初始化完成后的无向图结构如图 2(a) 所示。其中虚线框表示的区域为满足筛选条件的图像区域块, 即不具有明显运动特征的区域, 其余区域映射为图  $G$  中的结点并根据邻接关系建立图中边的连接。最终群组划分结果如图 2(b) 所示, 图中连通子图个数为 3, 表示原始图像中存在 3 个相互独立的群组。

相关度越高表明其运动特征越相似, 所以可将  $w_{ij}$  等价表示为  $S_{ij}$ , 即  $w_{ij} = S_{ij}$ 。

#### 2.3.2 群组划分

通过对所有边权重进行筛选确定要删除的连接, 最终实现群组的划分。边权重  $w_{ij}$  表示其连接结点连接的紧密性。群组与群组之间连接的紧密性远远低于群组内部结点的连接紧密性, 一旦将  $G$  中边权值较低的边删除后, 其中连通子图的个数也会发生变化, 各个行人群组会自然显现。原始 GN 分裂算法中将边权重定义为边介数, 每当一条具有最大边介数的边被删除时, 需要重新计算每一条边的边介数。而在群组划分的情况下, 只有在原始图像中具有邻接关系的结点才能被连接, 因此在初始连



接状态确定的情况下,删除边不会影响剩余边的权重,可利用各类排序算法实现群组的快速划分。实验中设权重均值  $\bar{w}$  为阈值,删除所有  $w_{ij} < \bar{w}$  的边后,获得当前的无向图  $G_{\text{sub}}$ 。根据连接关系,利用深度优先搜索算法获得连通子图集合  $\{g_i\} \in G_{\text{sub}}$ ,根据最初的图像的映射关系,逆推出各连通子图  $g_i$  对



应的图像区域集合,得到群组集合  $\{c_i\} \in c$ 。根据  $c_i$  包含区域  $\{r_i\}$  的运动特征属性,计算出群组运动特征属性  $\{M_{c_i}, A_{c_i}\}$ ,即分别求出对应分量运动强度和运动方向的均值。

利用上述方法对数据集中的两帧图像进行的群组划分结果如图 3 所示。




图 3 群组划分结果。(a)场景 1;(b)场景 2

Fig. 3 Grouping result. (a) Scene 1; (b) scene 2

图 3 中被相同数字覆盖区域表示为一个行人群组,通过群组划分结果可以得出:1)具有相似运动状态的邻接行人图像区域被划分为相同群组;反之则会被划分为不同群组;2)不具有明显运动状态的图像区域,即背景或禁止不动的行人未被划分至任一群组;3)与传统基于群体运动状态的异常事件检测算法相比,基于群组分析的异常事件检测算法可以获得场景中大致群组个数,对群组规模、运动方向和强度等场景的语义描述,符合人类的认知方式,增强了检测方法的解释性。

## 2.4 异常事件检测

在自然场景中行人的运动状态呈现的特点:1)人群以群组为单位,按照预定目标方向运动;2)行人运动速度较为缓慢且均匀。但当异常事件发生时,人群出于恐慌情绪,群组的运动状态和结构发生剧烈改变,表现为:1)行人为快速逃离异常中心,运动速度增加;2)异常事件发生的初期行人各自逃散,群组的数量会突然增加。基于上述特点,可利用群组运动强度变化量  $D_1$  和群组数量变化量  $D_N$  描述群组在自然场景和异常场景的属性差异,检测异常事件的发生。设视频中第  $t$  帧群组运动强度变化量  $D_1(t)$  为

$$D_1(t) = \frac{\overline{c_{\text{mag}}(t)}}{\frac{1}{t-1} \sum_{i=1}^{t-1} \overline{c_{\text{mag}}(i)}}, \quad (4)$$

式中,  $\overline{c_{\text{mag}}(t)}$  为第  $t$  帧所有群组运动强度的均值。当异常时间发生时,行人为了逃离当前场景,运动速度迅速增加。通过计算第  $t$  帧所有群组运动强度的均值和前  $t-1$  帧所有群组运动强度均值的变化,准

确地检测异常事件。

异常事件爆发初期,行人出于恐慌心理各自逃散,导致群组的数量突然增加。因此引入了群组数量变化量  $D_N$  检测异常的发生。设第  $t$  帧群组数量变化量  $D_N(t)$  为

$$D_N(t) = \frac{N_c(t)}{\frac{1}{m} \sum_{i=t-m}^{t-1} N_c(i)}, \quad (5)$$

式中,  $N_c(t)$  为第  $t$  帧时场景中群组数量,利用长度为  $m$  的平滑滤波器计算前  $m$  帧群组数量的均值,一般取  $m=10$ 。通过计算两者的比值,判别场景中群组数量的变化情况。最后通过比较群组运动强度变化量  $D_1$  和群组数量变化量  $D_N$  与预先设计的阈值 ( $T_1, T_N$ ) 检测异常事件的发生,考虑到归一化运动强度所带来的场景泛用性以及场景中无明显运动目标时不会发生异常事件的先验知识,对运动强度均值  $\overline{i_{\text{mag}}}$  设置双边最小和最大阈值分别为  $T_{\min}$ ,  $T_{\max}$ 。即:当  $D_1 > T_1$  且  $\overline{i_{\text{mag}}} > T_{\max}$  或  $D_N > T_N$  时判别场景中发生了异常事件;当上述条件不满足或  $\overline{i_{\text{mag}}} < T_{\min}$  时,则判别场景中未发生异常事件。

## 3 实验结果与分析

### 3.1 实验环境

为验证所提出的基于 GN 分裂的人群异常事件检测算法的性能,利用 2016 年公开的数据集 MED (Motion emotion dataset) [15] 进行评测。包含恐怖袭击、斗殴、枪击和抢劫等多种异常事件,异常事件种类丰富且贴近真实场景 [16]。MED 数据集根据是否存在异常还提供了图像级标注,可标注异常事件

发生的起始帧和结束帧,满足实验所需。

从MED数据集中挑选既满足场景假设条件又具有明显异常事件的视频片段,总计838帧异常事件视频和6475帧自然状态视频作为实验数据。使用的计算机处理器为Intel Core i7-7700,3.6 GHz,内存为8 GB,编程基于Python3.6实现。

### 3.2 异常事件检测连贯性实验

为验证基于群组分析的异常事件检测算法的连贯性,从数据集中挑选了三段视频进行实验,对比了使用本算法的检测结果与MED数据集标注

之间的差异。将所有待测视频分辨率归一化为 $640 \times 480$ ,设 $s=20$ 、 $T_1=1.5$ 、 $T_N=2$ 。用数据条带表现标注与检测结果,深色条带表示异常事件帧,浅色条带表示自然场景帧。结果如图4、图5和图6所示。

图4为因发现疑似炸弹背包而四散逃离场景的实验结果,与标注的真实值进行对比发现,该场景下本算法产生了较少的误检,但能覆盖场景中大多数的异常状况且检测连贯性较好。因对于异常事件的检测略有延迟,所以存在一定的漏检问题。



图4 实验场景1。(a)正常场景;(b)异常场景

Fig. 4 Experimental scene 1. (a) Normal scene; (b) abnormal scene

图5为恐怖袭击后人群逃散场景的实验结果。与标注的真实值进行对比发现,该算法检测得到的初始帧早于标注的初始帧,对整体异常事件能做到

较为完整的检测,在该场景下未发生漏检问题且检测连贯性较好。验证了所提出的算法对该场景的检测结果较好。




图5 实验场景2。(a)正常场景;(b)异常场景

Fig. 5 Experimental scene 2. (a) Normal scene; (b) abnormal scene

图6为演讲场景的实验结果,一开始人群处于静止状态,但伴随着演讲者的演说有挥手等动作。从场景中检出的运动特征并非由行人移动而产生,

此时计算得出运动强度特征失效,导致出现了多处误检。在该场景下的检测结果出现了断带,说明该算法存在一定的局限性。当异常事件发生后,人员




图6 实验场景3。(a)正常场景;(b)异常场景

Fig. 6 Experimental scene 3. (a) Normal scene; (b) abnormal scene

开始逃离,利用该算法仍能较为准确地覆盖所有异常帧,对异常事件的检测结果较为准确。

对实验结果进行分析可得:1)从检测连贯性角度来看,该算法在上述三个典型场景中未发生明显的断带情况,具有检测连贯性强的优点。对异常事件预警、后期归档分析都有较大的帮助;2)对条带数据进行直观的比较,发现该算法能检测出较多的真实异常事件。

### 3.3 异常事件检测对比实验

采用 HOF 模型、DT 模型、EM 与所提出的基于 GN 分裂的人群异常事件检测算法进行对比。将所有待测视频分辨率归一化为  $640 \times 480$ , 设本算法中的  $s = 20$ 、 $T_1 = 1.5$ 、 $T_N = 2$ 、 $T_{\min} = 0.02$ 、 $T_{\max} = 0.5$ 。分别统计正常和异常场景下预测正确和错误的帧数,进而得出混淆矩阵(由正常场景下结果判定为正常场景、异常场景的帧数和异常场景下结果判定为正常场景、异常场景的帧数组成),结果如表 1 所示。

表 1 异常事件检测实验结果

Table 1 Abnormal event detection experiment

Algorithm	True value	Detection result	
		abnorml	normal
HOF	abnorml	721	117
	normal	150	6325
DT	abnorml	739	99
	normal	90	6385
EM	abnorml	635	203
	normal	210	6265
Our algorithm	abnorml	766	72
	normal	121	6354

由表 1 可得:1)与 HOF 模型和 EM 相比,该算法在各项指标上都有更优结果,对异常或是正常场景错误检测的帧数更少。2)与 DT 模型相比,在各项数值上都有优劣,对于异常场景的检测该算法表现更好,对正常场景的检测 DT 模型的错误检测更少。结果表明,该算法对于异常事件更为敏感,能够做到对异常事件及时准确的检测与预警。通过描述群组运动强度与群组数量的变化检测异常事件的发生,同时描述群组的属性,丰富了对于场景语义信息的描述,也提高了对于异常事件的检测精度。

利用实验所得的混淆矩阵,计算各个算法的准确率、精确率、召回率和特异度等二级指标以及三级指标 F1 分数,结果如表 2 所示。

表 2 异常事件检测算法性能对比

Table 2 Performance comparison of abnormal event

Algorithm	detection algorithms				unit: %
	Accuracy	Accuracy rate	Recall rate	Specificity	F1 score
HOF	96.3	82.8	86.0	97.7	84.4
DT	97.4	89.1	88.2	98.6	88.7
EM	94.4	75.1	75.8	96.8	75.5
Our	97.4	86.4	91.4	98.1	88.8

由表 2 可得:1)所提出的异常事件检测算法的准确率、召回率以及 F1 分数指标都优于其他算法,对异常事件更敏感,检测性能更好,且综合性较优;2)在精确率和特异度指标上略低于 DT 模型,但优于其他算法。对于正常场景的误检较多,存在一定的不足,但是总体性能较优。与其他算法相比最大不同点在于,其先将场景内行人分组,然后利用群组的运动特征和结构的变化分析场景中是否发生异常事件,可解释性强、符合人类认知。除此之外,还可根据群组划分的结果获得场景中大致群组个数,丰富对群组规模以及群组运动方向和强度等场景的语义描述,提高异常事件的检测率。

## 4 结 论

针对人群异常事件的检测问题进行研究,提出了一种基于 GN 分裂的人群异常事件检测算法。利用复杂网络中用于社区发现的 GN 分裂算法和光流算子将具有相似运动特征且位置相近的目标划分为多个群组,利用群组运动强度和群组数量变化两项指标描述了群组在正常和异常场景中运动特性和结构的差异,并以此检测场景中异常事件的发生。实验结果表明,该算法能够及时、准确地对场景中发生的异常事件进行预警,具有检测连贯性好、检测率高、符合人类认知方式等优点,与同类型算法相比在多项指标上都具有一定的优势。

## 参 考 文 献

- [1] Mehran R, Oyama A, Shah M. Abnormal crowd behavior detection using social force model[C]//2009 IEEE Conference on Computer Vision and Pattern Recognition, June 20-25, 2009, Miami, FL, USA. New York: IEEE, 2009: 935-942.
- [2] Wang T, Snoussi H. Detection of abnormal visual events via global optical flow orientation histogram [J]. IEEE Transactions on Information Forensics and

- Security, 2014, 9(6): 988-998.
- [3] Wang H, Kläser A, Schmid C, et al. Dense trajectories and motion boundary descriptors for action recognition [J]. *International Journal of Computer Vision*, 2013, 103(1): 60-79.
- [4] Xiong G G, Cheng J, Wu X Y, et al. An energy model approach to people counting for abnormal crowd behavior detection [J]. *Neurocomputing*, 2012, 83: 121-135.
- [5] Ravanbakhsh M, Nabi M, Mousavi H, et al. Plug-and-play CNN for crowd motion analysis: an application in abnormal event detection [C] // 2018 IEEE Winter Conference on Applications of Computer Vision (WACV), March 12-15, 2018, Lake Tahoe, NV, USA. New York: IEEE, 2018: 1689-1698.
- [6] Hu X, Huang Y P, Zhang H L, et al. Video anomaly detection using deep incremental slow feature analysis network[J]. *IET Computer Vision*, 2016, 10(4): 258-267.
- [7] Zhang X S, Zhang H W, Zhang Y D, et al. Deep fusion of multiple semantic cues for complex event recognition [J]. *IEEE Transactions on Image Processing*, 2016, 25(3): 1033-1046.
- [8] Zhu W J, Wang G L, Tian J, et al. Detection of moving objects in complex scenes based on multiple features [J]. *Acta Optica Sinica*, 2018, 38 (6): 0612004.  
朱文杰, 王广龙, 田杰, 等. 基于多特征的复杂场景运动目标检测 [J]. *光学学报*, 2018, 38 (6): 0612004.
- [9] Farneback G. Two-frame motion estimation based on polynomial expansion[M] // Bigun J, Gustavsson T. *Image analysis. Lecture notes in computer science*. Berlin, Heidelberg: Springer, 2003, 2749: 363-370.
- [10] Newman M E J, Girvan M. Finding and evaluating community structure in networks [J]. *Physical Review E*, 2004, 69(2): 026113.
- [11] Zeigarnik B, Ellis W D. *A sourcebook of gestalt psychology*[M]. Michigan: Humanities Press, 1967.
- [12] Felzenszwalb P F, Huttenlocher D P. Efficient graph-based image segmentation [J]. *International Journal of Computer Vision*, 2004, 59(2): 167-181.
- [13] He Q Y, Li Z L, Wang X Z, et al. Automated retinal layer segmentation based on optical coherence tomographic images [J]. *Acta Optica Sinica*, 2016, 36(10): 1011003.  
贺琪欲, 李中梁, 王向朝, 等. 基于光学相干层析成像的视网膜图像自动分层方法 [J]. *光学学报*, 2016, 36(10): 1011003.
- [14] Zhao P R, Wu X Y, Tang X Y, et al. An algorithm of small object detection region proposal search based on GN splitting [J]. *Acta Optica Sinica*, 2018, 38 (9): 0915005.  
赵沛然, 吴新元, 汤新雨, 等. 基于 GN 分裂的小目标检测区域推荐搜索算法 [J]. *光学学报*, 2018, 38 (9): 0915005.
- [15] Rabiee H, Haddadnia J, Mousavi H, et al. Novel dataset for fine-grained abnormal behavior understanding in crowd [C] // 2016 13th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS), August 23-26, 2016, Colorado Springs, CO, USA. New York: IEEE, 2016: 95-101.
- [16] Zhou P P, Ding Q H, Luo H B, et al. Anomaly detection and location in crowded surveillance videos [J]. *Acta Optica Sinica*, 2018, 38(8): 0815007.  
周培培, 丁庆海, 罗海波, 等. 视频监控中的人群异常行为检测与定位 [J]. *光学学报*, 2018, 38(8): 0815007.