

# 密集场景下的人群拥挤检测研究综述

许敏<sup>1,2</sup>, 胡滨<sup>1,2,3</sup>

(1. 贵州大学计算机科学与技术学院公共大数据国家重点实验室, 贵州 贵阳 550025;

2. 贵州大学计算机科学与技术学院, 贵州 贵阳 550025;

3. 贵州大学人工智能研究院, 贵州 贵阳 550025)

**摘要:** 感知与检测公共场所密集人群发生的拥挤行为是计算机视觉领域极具挑战的课题。对该问题进行研究, 如人群运动特性分析、行为检测模型构建等, 可为揭示密集场景人群活动的运动特性和行为本质提供有益帮助, 同时可协助相关公共安全部门制定管理策略和应急响应措施, 从而有效避免人群灾难事件的发生与恶化。为此, 梳理与总结视觉场景下密集人群拥挤检测问题的研究工作。首先, 从人群动力学、社会力模型、流体力学理论等角度综述人群拥挤活动的定性特征; 其次, 调研现有人群拥挤检测算法及相关的计算模型; 接着, 给出此研究涉及的公共数据集与模型性能评估方法; 最后, 探讨人群拥挤检测研究的应用场景与未来研究方向。公共场所密集人群拥挤行为的定性、定量研究现状综述, 可为计算机视觉、智能监控、人工智能等领域的人群活动感知、行为分析理解、异常检测等提供有益参考。

**关键词:** 拥挤检测; 行为分析; 人群拥挤; 密集场景; 智能视频监控

中图分类号: TP183

文献标志码: A

DOI: 10.19678/j.issn.1000-3428.0069340

## Survey of Research on Crowd Congestion Detection in Dense Scenarios

XU Min<sup>1,2</sup>, HU Bin<sup>1,2,3</sup>

(1. State Key Laboratory of Public Big Data, College of Computer Science and Technology,  
Guizhou University, Guiyang 550025, Guizhou, China;

2. College of Computer Science and Technology, Guizhou University, Guiyang 550025, Guizhou, China;

3. Artificial Intelligence Research Institute, Guizhou University, Guiyang 550025, Guizhou, China)

**【Abstract】** Perceiving and detecting crowd congestion in public spaces is an extremely challenging task in computer vision. Research on this issue, such as analyzing the motion characteristics of crowds and constructing behavior detection models, can provide valuable insights into the motion traits and behavioral essence of crowd activities in dense scenarios. Additionally, it can assist relevant public safety departments in formulating management strategies and emergency response measures, thereby effectively preventing the occurrence and escalation of crowd-related disasters. To this end, this paper summarizes the research efforts on dense crowd congestion detection. First, an overview of the qualitative characteristics of crowd congestion from the perspectives of crowd dynamics, social force models, and fluid mechanics theory is presented. Second, existing crowd congestion detection algorithms and related computational models are investigated. Next, the public datasets and model performance evaluation methods relevant to this research are presented. Finally, the application scenarios and future research directions for crowd congestion detection are explored. A review of the current research status on the qualitative and quantitative analyses of dense crowd congestion behaviors in public spaces offers valuable references for crowd activity perception, behavior analysis and understanding, and anomaly detection in fields such as computer vision, intelligent surveillance, and artificial intelligence.

**【Key words】** congestion detection; behavioral analysis; crowd congestion; dense scenarios; intelligent video surveillance

## 0 引言

人群拥挤是一种非常规群体活动, 特指密集人群中的个体/群体无法按预期方向前行, 或无法移动

的异常人群行为<sup>[1]</sup>。人群拥挤检测以公共场所人群活动为研究对象, 从计算机视觉角度对人群空间位置、运动方向、运动模式、演化趋势等开展分析与理解, 从中检测人群活动的拥挤特性并预警异常的发

**基金项目:** 国家自然科学基金(62066006); 贵州省自然科学基金(黔科合基础[2020]1Y261); 贵州大学引进人才科研项目(贵大人基合字(2019)58号)。

**作者简介:** 许敏, 女, 硕士研究生, 主研方向为计算智能、计算机视觉; 胡滨(CCF 高级会员、通信作者), 教授、博士、博士生导师。

**收稿日期:** 2024-02-01

**修回日期:** 2024-06-03

**E-mail:** bhul@gzu.edu.cn

生。公共场所的人群活动具有不确定性,人群拥挤的前兆特征不明显,难以检测与预警,却易引发行人恐慌、推让、失稳、踩踏行为,导致严重的公共灾难事件<sup>[2]</sup>。例如,2015 年沙特麦加朝觐发生踩踏事故造成 1 399 人死亡,2022 年韩国首尔梨泰院人群拥挤踩踏导致 158 人死亡,2023 年德国“爱的大游行”音乐节人群拥挤造成 19 人死亡以及 342 人受伤。伴随世界各国城市化进程的加快,公共场所人群聚集安全监控及异常事件预警需求愈发迫切,对该问题的研究在智能监控、公共安全应急管理等领域具有重要意义。

世界各国/地区政府高度重视公共场所人群安全问题,颁布了相关政令法规。以我国为例:2020 年上海市政府颁布《关于加强公共场所人群聚集活动安全管理的若干规定》,要求举办大型聚集活动必须实施安全风险评估机制和启动应急预案;中华人民共和国国务院 2023 年颁发《加强公共场所人员聚集安全管理的通知》,强调提高安全检测预警水平以防范人群灾难事件。研究表明,实时检测与预警人群的异常行为能有效杜绝公共场所群体性灾难事件的发生<sup>[3]</sup>。然而,如何感知与理解人群拥挤活动并对其进行检测与预警,却是计算机视觉、人工智能等领域的前沿研究难题。

研究人群活动目前主要涉及人群分割<sup>[4]</sup>、密度估计<sup>[5-8]</sup>、行人跟踪<sup>[9-10]</sup>、行为理解<sup>[11-12]</sup>、异常检测<sup>[13-16]</sup>及相关的综述调研工作。就人群拥挤检测问题而言,尽管已有少量通用型的人群异常检测模型被初步探讨,但它们存在研究问题缺乏针对性,现有模型精度不高、泛化能力弱、场景适用性差等缺陷,现有方法技术亟待改进;另一方面,鲜有学术文献对该研究问题归纳整理,缺乏针对性的综述调研报告。因此,对密集场景人群拥挤检测技术及其研究现状开展调查研究,具有重要的科学意义以及潜在的工程应用价值。基于此,本文对该问题开展综述性调查研究工作,创新点如下:1)从定性角度调研密集人群的拥挤活动特性,归纳拥挤行为的动力学表征特征;2)从定量角度对涉及人群拥挤检测问题的现有计算模型进行归纳,提出可持续性发展建议;3)整理研究问题的公共数据集,给出计算模型的性能评价方法。

## 1 定性研究

图 1 所示为典型的人群拥挤场景,其中大量行人聚集于特定区域,彼此相互阻碍且无法动弹。如表 1 所示,可根据单位面积的人数  $D_e$  划分人群拥挤程度,分为 A~F 6 个等级<sup>[17]</sup>。其中,等级越高,人群越拥挤。



图 1 人群拥挤及灾难案例

Fig. 1 Crowded crowds and disaster cases

表 1 人群拥挤等级

Table 1 Level of crowd congestion

拥挤等级	人数 $D_e / (\text{个} \cdot \text{m}^{-2})$
A	$D_e \leq 0.31$
B	$0.31 < D_e \leq 0.43$
C	$0.43 < D_e \leq 0.72$
D	$0.72 < D_e \leq 1.08$
E	$1.08 < D_e \leq 2.17$
F	$D_e > 2.17$

为探讨人群活动的本质特性,研究人员开展了人群拥挤运动特性研究,获得的理论成果为预防特定场景的人群拥挤事件发挥了重要作用。文献[18]研究了人群运动自组织现象,为改进公共场所建筑结构规划提出有益建议。文献[19]对麦加穆斯林朝圣地的建筑物分布进行优化,在未来几年能有效杜绝该地曾频繁发生的朝觐人员踩踏事故。文献[20]分析了德国杜伊斯堡“爱的大游行”(Love parade)灾难事件,对事发现场的人群踩踏防范机制提出有益建议。本节从人群动力学、社会力学及流体力学理论角度,分别回顾密集人群拥挤活动的定性研究现状。

### 1.1 人群动力学特性

在对人群疏散方法的研究中,拥挤被认为是人群异常活动的重要特征,这吸引众多学者从动力学角度对高密度人群运动特性开展研究。文献[21]指出拥挤人群的行人运动呈现一定规律性,可在人群中展示独特的“运动波”(Motion Wave)效应。文献[22]公布的沙特阿拉伯米那/麦加穆斯林朝圣视频分析结果表明,高密度人流诱发人群产生“动荡”(Turbulence)运动特性。除了人群振荡效应,文献[23]指出高密度人群极易引发走走停停的运动,由此产生“停走波”(Stop-and-Go Wave)现象,诱发

行人个体失稳与摔倒。文献[24]基于 Mean-Shift 算法开展单行的行人动力学实验,提取包括速度、密度和横向振荡特征等运动参数,探讨行人微观动力学特性,并从侧面反映了运动波在高密度拥挤人群中的存在<sup>[25]</sup>。

借助人群堵塞瓶颈,文献[26]研究了运动人群拥挤问题,分析结果如图 2 所示(彩色效果见《计算机工程》官网 HTML 版,下同)。其中,图 2(a)模拟瓶颈区域的人群运动拥堵,颜色鲜艳度表征人群的局部拥挤程度。图 2(b)为靠近瓶颈口(内侧)与远

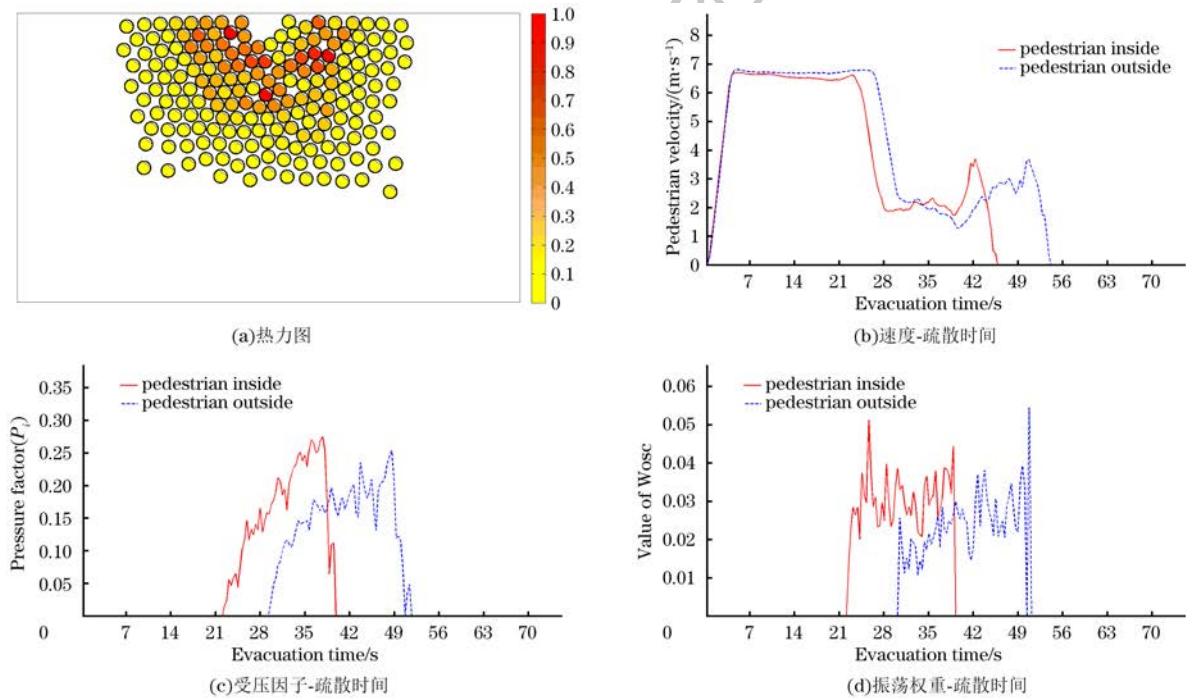


图 2 瓶颈疏散和拥挤分析

Fig. 2 Analysis of bottleneck evacuation and crowding

人群动力学理论对研究人群的活动特性具有重要意义,它揭示了人群拥挤呈现出的动力学特性。但是,此类研究方法绝大部分基于模拟仿真实验,难以再现人群在真实世界中的复杂情景,获得的仿真结果与现实世界依然存在差异。此外,由于人类个体具有主观意识,主观意识的存在必将引发人群运动个体的未知行为活动,例如行人逆行、错速、移位等,导致仿真实验无法再现行人个体主观活动及其对群体运动的不确定性影响。

## 1.2 社会力模型

一些学者基于社会力模型(SFM)对人群拥挤过程中的行人特性开展研究,以揭示运动人流的群体密集度与个体行为之间的关系。文献[27]对拥挤人群逃生过程开展检测和定位,表明使用社会力模型估计个体间的相互作用力有助于检测人群异常拥挤行为。文献[28]模拟行人在自动扶梯

离瓶颈口(外侧)的不同区域人群之间的“运动速度-疏散时间”关系对比,其清晰反映了瓶颈拥挤人群移动速度并不受空间位置的影响,而受限于人群密度。图 2(c)显示了人群不同位置的行人受压和疏散时间的关系,图 2(d)是不同位置的人群振荡权重和疏散时间的关系。这两幅子图清晰表明,拥挤人群中的个体行人受压因子与区域振荡在空间位置具有不一致性。高密度人群中传播的运动压力和运动约束特性可用于探讨人群拥挤问题,该结论与文献[24]一致。

换乘中的拥堵疏散问题,发现局部人群的高密度特性是造成疏散风险的重要原因。文献[29]基于扩展的社会力模型模拟了拥挤人群的疏散,认为逃生出口能见度与宽度的关系直接影响拥挤人群制定最佳疏散策略。文献[30]发现拥挤人群在逃生过程中引发拱形效应(Arch Effect)<sup>[31]</sup>现象。值得注意的是,文献[32]通过社会力模型模拟了拥挤人群的疏散,发现拱形效应是人群逃生疏散的瓶颈<sup>[4]</sup>,其表征为社会力恐慌对人群逃生效果的影响。图 3 给出了上述的社会力恐慌度和逃生人数之间的关系。其中,图 3(a)展示实验模拟的人群逃生场景示意图,图 3(b)表明,在给定的时间内,人群社会力恐慌度对逃生人数有着正面影响,但当恐慌度达到特定阈值(0.42)后,两者呈反比关系。图 3(c)呈现了特定的行人数量内人群社会力恐慌度与行人逃生耗费时间最初是反比关系,

但在恐慌度达到特定阈值(0.4)后,两者呈正比。图 3(d)展示高密度人群的逃生方向偏好,即人群社会力恐慌系数直接影响着行人个体的逃生路径决策。文献[4]的研究表明,拥挤人群极易引发内

部的社会力恐慌效应,伴随人群拥挤加剧,逃生疏散难度增大,而人群自发的社会力恐慌最初有助人员疏散,但后期人流拥挤密度增大将导致疏散失控。

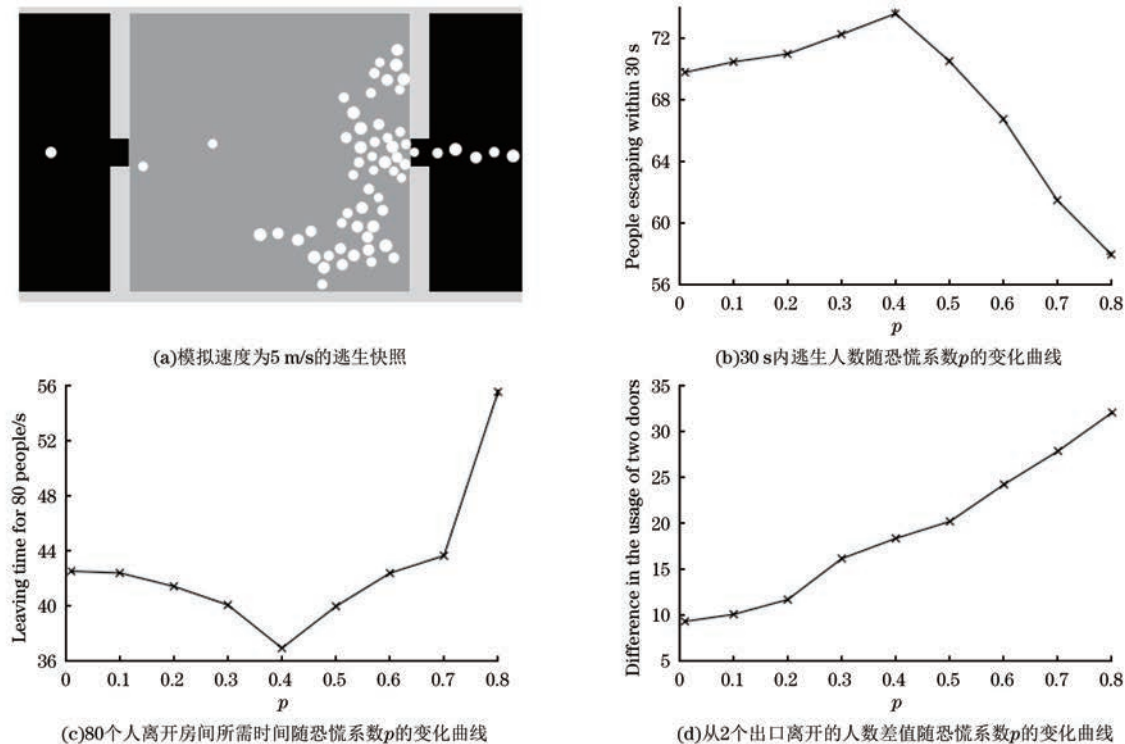


图 3 拥挤人群疏散测试

Fig.3 Crowd evacuation test

社会力模型揭示了运动人流中的群体密集度与个体行为之间的关系特性,但由于该方法需要将人群群体分解为行人个体,并计算单个行人在人群群体中的个体作用力,从而导致模型计算资源耗费巨大。尽管此类方法在一定程度上能有助探究人群活动的社会力特性,但在大规模人群活动的动态行为分析场景中并不具备优势。

### 1.3 流体力学理论

早在 20 世纪 70 年代,文献[33]就从流体力学理论角度分析了人群的运动特性,提出运动人群具有与流体(液体或气体)相似的运动特性假设,即流动人群存在运动、变形和相互作用的连续体特性。在对拥挤人群的流体力学特性研究中,文献[18]观察到活动密集人群中的运动冲击波(Shock Wave),从侧面验证了人群运动动力学研究所发现的人群运动波的存在客观性。文献[34]基于动量/能量守恒定理研究了可变宽度或部分阻塞通道的行人流动特性,发现运动人群的经验数据与流体动力学模型之间存在相似性。文献[35]在文献[34]的基础上引入行人意图和相互作用附加项,构建行人流体动力学方程以计算人群流体

行人之间的向异值。随后,文献[36]借助网格表示宏观人群的分布和运动趋势流体力学特征,允许人群中的少数智能体隐式更新,以达到拥挤人群局部路径规划和缓解人群拥挤的目的。文献[37]基于奇异压力动量与库朗数稳定条件提出一种运动人群渐进保持方案,进一步揭示了拥挤人群路径选择的自组织流体力学特性,如图 4 所示。图 4 展示的研究成果<sup>[37]</sup>表明,拥挤人群中存在着描述人群拥堵状态的奇异压力动量差与密度差特性,它们对人流在拥挤状态下的运动路径产生直接影响,是人群拥挤状态迁移的重要流体力学表征。

借助流体力学理论,人群可被看作流动的液体或气体从而开展运动特性研究,能揭示人流形成拥挤现象的一些动态表征特性。但是,该方法的研究需要假设人群的均匀流动性,即流体力学理论侧重于人群的整体性运动和排列性质,而忽略人群社会因素和个体意识差异对全局运动特性的影响。因此,尽管流体力学理论可探讨人群拥挤的某些流体特性,但在表征现实世界中人群拥挤状态的动态变化过程时仍然存在缺陷。




图 4 人群奇异压力动量与密度的关系

Fig.4 The relationship between crowd singular pressure momentum and density

上述工作采用仿真方法,分别从人群动力学特性、社会力模型、流体力学理论角度对人群拥挤的状态演化过程及其动态特性进行了研究,所获得的定性成果可归纳如下:1)人群中自发的运动波效应可反映其拥挤程度;2)过度拥挤的运动人群易引发行走波、冲击波效应,并沿着人流的移动方向传播;3)拥挤人群中的拱形效应可反映人群拥堵的时空区域特征;4)高密度流动人群的拥挤区域具有自发的振荡动力学特性;5)运动人流的流体力学动量差和密度差可反映其拥挤状态的变化趋势;6)拥挤人群自发的社会力恐慌对人群逃生疏散效率具有两面性。在对运动人群拥挤形成的理论研究中,所获得的理论成果可为揭示人群运动状态的迁移与演化机理提供探索思路,也为制定拥挤人群的疏散策略提供有益启发。

## 2 定量模型

一些学者从计算模型角度探讨了人群活动检测方法,并初步应用到不同场景,例如火车站出入通道、人群集会、宗教朝觐等,以解决人群的拥挤检测问题<sup>[38-45]</sup>。如图 5 所示,计算模型的研究大体可经历 3 个发展历程,即低阶特征检测、高阶特征提取和机器学习。低阶特征通过比较图像纹理估计人群规模,进而分析其拥挤程度<sup>[46-48]</sup>;高阶特征提取人群全局运动特性以实现拥挤检测<sup>[25,49-50]</sup>;机器学习则基于特定机器学习模型,开展学习训练,以对人群的拥挤进行分类识别。本节介绍与人群拥挤检测研究相关的定量模型<sup>[46-72]</sup>,根据实际采用的技术路线的不同,将其分为两类,即手工特征提取方法和机器学习技术。

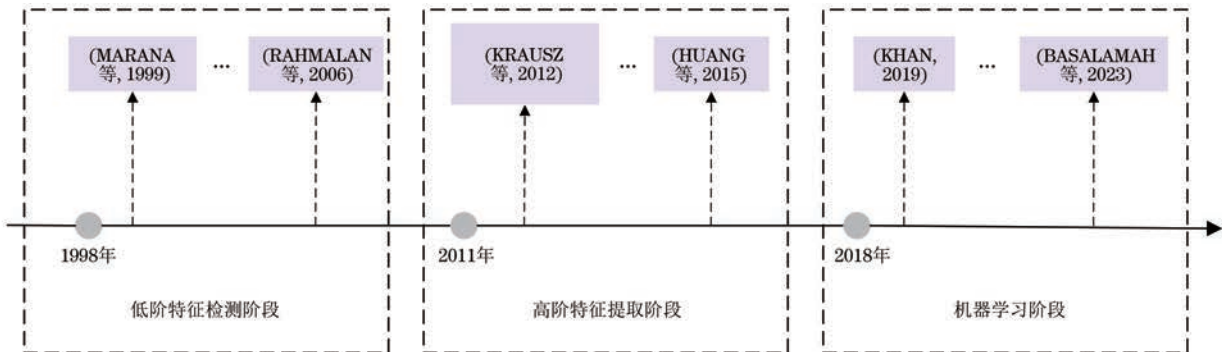


图 5 人群拥挤检测技术的发展历程

Fig.5 The development of crowd congestion detection technology

## 2.1 手工特征提取方法

### 2.1.1 数字图像处理技术

在早期对人群拥挤检测计算方法的研究中,研究人员借助数字图像处理技术,提取图像中人群低阶纹理特征以实现拥挤度估计。文献[46]利用灰度依赖矩阵(GLDM)提取人群的密度纹理等级特征,采用自组织映射(SOM)开展分类检测。文献[47]延续该研究,提出一种拥挤人群的密度估计算法,该算法计算图像中人群的明可夫斯基分形维数(MFD),使用 SOM 算法提升人群拥挤的分类正确率。文献[48]使用 GLDM、平移不变正交切比雪夫矩阵(TIOCM)提取人群纹理、形状和矩特征,以此设计人群拥挤仿真分类模型。基于数字图像处理技术的一种典型人群拥挤检测结果<sup>[46]</sup>如图 6 所示。该图所显示的被分割人群纹理表明,低密度人群的纹理呈现粗糙、灰度值分布局部化的视觉特性,而高密度人群则具有纹理细腻、灰度值分布均匀的低阶视觉特征。在纯净的视觉场景中,这种独特的人群图像纹理特征分布能清晰反映人群拥挤程度。然而,当视觉背景杂乱,存在光照阴影、信号噪声等干扰时,基于数字图像处理技术的检测方法易产生假阳性,导致模型性能严重下降。

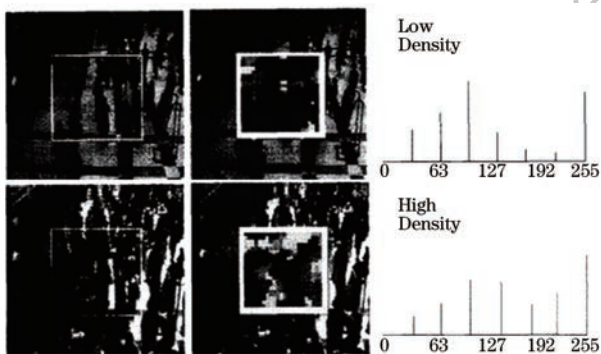


图 6 纹理特征提取的检测结果

Fig.6 Detection results of texture feature extraction

### 2.1.2 光流法

由于高阶视觉特征更能反映人群的全局运动特性,因此一些学者尝试借助光流(Optical Flow)法提取视频中人群拥挤的高阶运动特征。文献[51]提出一种危险人群事件的检测和预警系统,该系统基于光流计算检测人群拥挤的运动险模式。随后,文献[49]构建运动幅度和方向二维直方图,计算运动光流矢量以检测模拟人群中的拥挤振荡。文献[52]依据人群活动光流,对其分类处理以识别运动人群的瓶颈、源头、车道、拱门和拥挤 5 种特定行为。文献[50]利用光流法提取

人群前景目标速度直方图,提出一种全局上下文的人群拥挤检测高斯混合模型。文献[53]基于光流计算以检测人群的堵塞区域,提出一种大型人群聚集活动拥挤位置跟踪系统。文献[54]借助 KLT 算法计算人群运动光流,结合光流轨迹密度和局部惯性估计出人群的拥挤状态变化。一种典型的光流法提取人群高阶运动特征的实验结果<sup>[49]</sup>如图 7 所示,该图为文献[49]对“爱的大游行”(Love parade)人群灾难事件计算获得的人群拥挤光流变化图。其中,红色区域表示异常的人群拥挤光流警报。该图显示,光流法对人群拥挤产生了多次误报。具体而言,该事件出现真正的人群拥挤时间发生在当天 16:27 之后,但模型却错误地将随机出现的救护车、警车视作异常光流而产生报警。此外,人群中的剧烈活动也引发了类似 13:50 以及 14:30 的错误报警。

相比早期的纹理特征提取,基于光流法的人群拥挤检测模型可实时检测人群的活动变化以及异常的运动光流,在特定视觉场景中展示出较好的性能效果。但是,计算光流方程需要理想的视觉场景,采用光流法构建的计算模型对视觉场景的亮度恒定不变性有着极高的要求。因此,在视觉亮度变化大、时刻存在遮挡的人群活动真实监控视频中,光流模型的检测效果将受到严重影响。

## 2.2 机器学习技术

伴随着统计学理论在机器学习中的应用,学者们也使用机器学习方法研究计算机视觉的难点问题,尝试探讨人群活动检测模型的构建。依据机器学习的技术发展,现有涉及人群拥挤问题的计算模型可分为基于传统机器学习和基于深度学习两类<sup>[55]</sup>。

### 2.2.1 传统机器学习

文献[56]对地铁站台的拥挤人群检测问题开展了研究,借助神经模糊分类器提取表征人群拥挤程度的不同静态和运动像素特征,并用于地铁站的人群监控。文献[57]依据伦敦地铁站台的实际地理环境,使用多层前馈神经网络对人群背景像素进行过滤处理,设计了一种检测人群拥挤的自动监控系统。随着技术的发展,一些学者将机器学习方法与电子移动终端结合起来研究人群的拥挤模式。文献[58]对行人携带的手机信号进行聚类特征探测,依据信号聚集度检测人群的拥挤状态。文献[59]借助行人佩戴的信号传感器检测人群聚集状态,利用随机森林分类器对其队列长度及排队时间进行人群拥挤等级分类。文献[60]基于物联网(IoT)方法讨论了




图 7 高阶特征提取检测结果

Fig.7 Detection results of high-order feature extraction

一种人群的拥堵感知方法,该方法使用行人佩戴的电子腕带传感器实时收集行人时空定位数据,进行聚类处理以预测可能发生的人群拥挤状态变化。此外,亦有学者将人群力学特征融入人群拥挤检测任务。文献[61]受人群压力概念的启发,通过不同类型的监督实验分析人群拥挤及内在的风险系数,依据人群运动轨迹构建拥挤阈值以检测人群拥挤区域。文献[62]利用空间视角受限原理,设计了一种基于注意力机制的狭小空间人群拥挤度检测方法,以达到人群拥挤预测的目的。

近年来,中东地区的伊斯兰朝觐拥挤事故频发,这吸引了研究者对密集人群拥挤问题的关注。文献[63]对宗教朝觐中的人群拥挤检测进行了研究,提出一种人群局部拥挤的定位算法。该算法将视频划分为多个大小一致的重叠时间段并采用粒子平流法从每个段中提取人群的运动轨迹信息,之后计算轨迹振荡值以识别人群拥挤候选区域。为消除行人随机运动引发的错误警报,该模型对人群轨迹振荡图进行时空滤波,以确定拥挤区域的置信区间。该方法在人群流动平稳的场景中有一定检测效果,但当人群剧烈流动并引发运动轨迹紊乱后,直接导致模型性能急剧下降。

借助不同学习规则对模型开展训练,基于机器

学习的计算模型可检测不同密度的人群拥挤情况。但此类算法模型在面对真实人群的拥挤检测问题时仍然存在诸多局限,例如算法模型过度依赖训练样本的照明条件,对目标人群的群体纹理特征、场景空间布局 and 人群密度变化敏感。另外,模型的计算资源消耗量巨大,视觉场景泛化能力弱,模型在训练过程中易引发欠/过拟合等缺陷,成为现有机器学习算法亟待解决的难题<sup>[64]</sup>。

### 2.2.2 深度学习方法

传统机器学习的浅层学习较难提取样本中的行为特征。伴随着深度学习技术在大数据分析中的应用,一些学者扩大研究问题训练样本,把表征学习方法引入到对人群拥挤检测模型的开发中。文献[65]使用深度神经网络(DNN),通过BP算法调整神经元权重和偏差,以提升模型的非线性分类性能,用于估计人群拥挤程度。文献[66]提出一种双输入流的多列多级并行端到端训练算法,在单列卷积神经网络(CNN)的基础上,利用全局拥挤分析法对人群拥挤等级开展分类。文献[67]基于CNN设计了一种多视图框架生成服务的水平地图模型,并将其用于度量人群稀疏和密集场景数据集中的人群拥挤度。文献[68]基于CNN设计了一种人群拥挤检测深度学习框架,该框架学习行人运动轨迹,并转换为表征

二维时空图像的人群拥挤度。文献[69]提出人群规模稀疏性感知模型,该模型估算行人尺度并根据尺度与最近邻距离差值计算人群的区域局部稀疏度,以此获得人群拥挤感知的损失估计。文献[70]设计了一种 3 层单卷积神经网络(S-CNN3)模型,该模型计算人群场景密度,以此制定人群拥挤风险等级。文献[71]基于单阶段(one stage)目标检测模型YOLOv3 构建了一种人群拥堵知识图(CCKG),用于识别人群拥挤。文献[72]提出一种衡量火车站拥挤程度的深度学习框架,该框架以视频作为输入,并将其划分成多个大小相等的时间段,提取出每个时间段的运动轨迹之后计算其局部特征(形状、速度、距离等),然后将这些局部特征连接成特征矩阵,该矩阵以特征数量作为行,以特征长度作为列。接下来,训练双向长短期记忆(Bi-LSTM)模型,根据特征将轨迹分为“拥挤”和“正常”两类。最后,根据分类分数对轨迹编码获取分数图,再采用非极大值抑制(NMS)获得拥挤区域。由于现实生活中很少发生拥挤,所以该方法首先在合成数据上预训练模型,之后在真实数据上微调模型以弥合真实数据和合成数据的差距。从实验结果来看,比起没有进行域适应(预先在合成数据集上训练)的框架,进行域适应的框架在真实数据上训练的性能对于每个实验场景都有提升。

一种典型的手工特征提取与深度学习模型的检测效果如图 8 所示。图 8(a)是采用基于人群振荡手工特征提取<sup>[63]</sup>方法的检测效果,图 8(b)为 Bi-LSTM 深度学习模型<sup>[72]</sup>进行轨迹分类拥挤检测的实验结果。实验对比显示,图 8(b)所示的 Bi-LSTM 模型能检测到人群更多的异常拥挤区域,而图 8(a)的人群振荡手工特征方法仅对人群拥挤区域标记等级(颜色递进),其检测区域效果弱于图 8(b)中的深度学习算法。相比手工特征提取,基于表征学习的深度学习技术面对人群拥挤检测问题时,可实现对人群拥挤等级的划分,模型性能展示出良好的特性。但是,深度学习模型需要高质量的大量有限标记数据集开展训练。因此,目前基于深度学习的人群拥挤检测算法仍存在模型泛化能力弱的缺陷,即场景发生变化时,需要重新训练模型。此外,训练集的数据有限性也易引发现有深度学习模型的欠/过拟合问题。

### 2.3 定量模型对比

手工特征提取方法和机器学习技术在探讨人群拥挤检测问题的研究中,从不同的视觉特性和运动特征来对人群拥挤实现检测,但这些方法在




图 8 机器学习代表模型的拥塞检测结果

Fig. 8 Congestion detection results of machine learning representative models

技术特点上存在差异性。具体而言,手工特征提取关注图像视觉的低阶纹理特征,更为进阶的方法是使用光流提取运动人群的光流特征开展检测。而机器学习方法根据人群运动轨迹、方向、速度等,使用学习训练规则开展表征学习分类。表 2 列举了一些典型的人群拥挤检测量模型的优缺点及应用场景。从表 2 可以看出,尽管研究者探讨了不同的人群拥挤检测计算模型的构建方法,但现有算法仍存在如下不足:1)对人群的拥挤密度具有不同选择性,例如文献[46]模型、文献[48]模型仅适用于低密度的人群活动检测,而文献[69]模型、文献[70]模型具有对中高密度人群活动的偏好特性;2)模型的计算复杂度高,大部分算法依赖光流提取人群活动特性,例如文献[49]模型、文献[52]模型、文献[63]模型,导致模型计算资源消耗巨大,难以满足真实场景的实时需要;3)模型的场景泛化能力弱,例如文献[68]模型、文献[72]模型仅适用于流动人群,当人群拥挤发生运动停滞,它们的性能将严重下降。

## 3 数据集与模型评估方法

### 3.1 数据集与数据标记

各国/地区政府严格限制人群灾难事件的原始图像/视频数据外流,而拥挤场景人群极易引发严重伤亡事故,自行设计此类活动场景并拍摄实验数据的风险极高,这使得密集场景人群拥挤问题研究的图像/视频数据获取极为困难。在对人群活动特性及异常行为的探究过程中,科研机构逐步开放了一些有关的图像/视频数据,这些数据与密集场景人群拥挤问题的研究存在一定交集。因此,本节归纳整理了适合人群拥挤检测研究问题的实验数据,并对数据标记的常用方法进行介绍。依据数据类型不同,实验数据可分为两种,即图像库与视频序列。实验数据集的采样图如图 9 所示,表 3 则给出对不同数据集量化归纳的结果。

表 2 典型人群拥挤检测模型的优缺点对比

Table 2 Comparison of advantages and disadvantages of typical crowd congestion detection models

模型	方法类别	优点	缺点	适用场景
文献[46]模型 文献[48]模型	纹理特征	1)算法简单,耗时低; 2)低密度人群拥挤检测。	1)对于较高密度人群检测效果较弱; 2)检测正确率很容易受杂乱背景的影响; 3)只适用于静态图片。	适用于 D 级 <sup>[2]</sup> 以下且人群具有静止站立特征的区域,如车站候车人群。
文献[49]模型	光流法	1)可实时检测视频; 2)对于处于运动状态的密集人群检测效果良好。	1)光流法计算量大,耗时长; 2)由于提取的是行人运动模式,因此不适用于超高密度人群检测。	适用于人流密度属于 E 级 <sup>[2]</sup> 的大量流动人群区域,如旅客出入通道。
文献[52]模型	光流法	1)可对包含人群阻塞的多种人群行为进行检测; 2)对于密集人群更容易出现和系统设定一致的行为状态。	1)光流法计算量大,耗时长; 2)系统稳定性较弱,只能识别特定流动方向的人群行为。	适用于人群密度处于 E、F 级且出现阻塞状态的瓶颈区域,如火车站出入口人群。
文献[50]模型	速度熵	1)对于流动密集人群检测效果好; 2)提供实时检测并自动预警功能。	1)光流法计算量大,速度方向和大小在密集人群中难以提取; 2)不适用于超高密度人群拥挤检测。	适用于 E 级 <sup>[2]</sup> 密度的大型活动中流动人群,如广场音乐会人群。
文献[54]模型	轨迹密度和局部惯量	1)适用于视觉开阔区域人群检测; 2)算法简单,容易实现; 3)具有实时监测功能。	1)不适用于高密度人群; 2)无法解决遮挡问题。	适用于 D 级 <sup>[2]</sup> 以下且视野开阔环境中的人群,如露天游乐场游人。
文献[56]模型 文献[57]模型	多层前馈神经网络	算法简单,需区分低密度的静态和动态人群。	1)复杂场景下效果差; 2)不适用于密集人群场景。	适用于 D 级 <sup>[2]</sup> 以下且流动人群和静态人群区分很大的场景,如地铁站候车人群。
文献[61]模型	速度矢量	1)对人群拥挤程度进行等级划分,将拥挤问题聚焦到小范围区域; 2)对中高密度人群检测效果良好。	1)速度向量场分析法只适用于具有流动性的人群; 2)缺乏真实场景测试性能验证。	适用于 D、E 级 <sup>[2]</sup> 密度且运动特征明显的人群,如马拉松活动运动员。
TIS-MCMS-CNN <sup>[66]</sup> 文献[67]模型	CNN	1)能捕捉场景变化而视觉不变的特征; 2)实现不同等级密度的人群拥挤分析; 3)适用于低密度人群。	1)测试数据集都属于低密度人群,模型的泛化性缺乏验证; 2)照明变化和遮挡问题会对检测结果造成较大的影响。	适用于 D 级 <sup>[2]</sup> 密度以下的视野开阔场景,如运动场集会人群。
文献[69]模型 S-CNN3 <sup>[70]</sup>	CNN	1)适用于中高密度人群检测; 2)算法实现简单。	1)无法应对遮挡影响; 2)通过估计法会出现误判。	适用于 D、E 级 <sup>[2]</sup> 密度且视野开阔的场景,如街道人群。
文献[63]模型 文献[68]模型 文献[72]模型	LSTM	1)对于流动的高密度人群检测效果良好; 2)能定位人群拥挤区域。	1)不适用于流动运动特性弱的密集人群; 2)提取人群的运动轨迹光流计算量巨大。	适用于 E 级 <sup>[2]</sup> 密度且具有振荡运动特征的流动人群,如宗教朝觐活动人群。
文献[58]模型 文献[59]模型 文献[60]模型 WiCount <sup>[65]</sup>	聚类算法、随机森林分类算法	1)借助辅助电子设备采集更多人群信息; 2)适用于低密度人群检测。	1)检测效率较低; 2)行人流动影响模型的性能稳定性。	适用于 D 级 <sup>[2]</sup> 密度以下且人群用户的移动终端协作应用场景,如车站候车室人群。

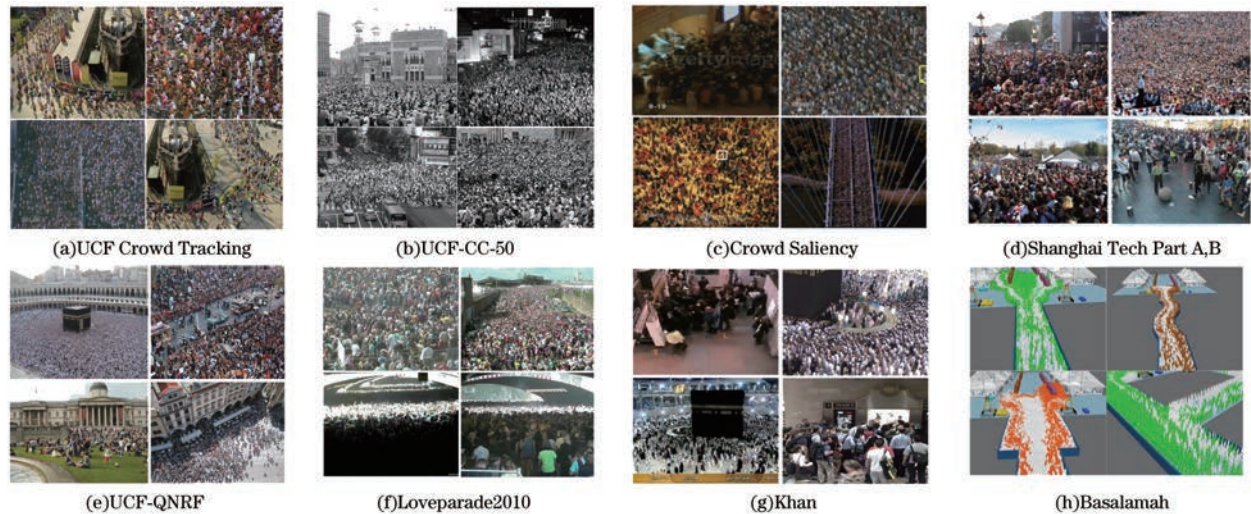


图 9 人群拥挤数据集

Fig. 9 Datasets of crowd congestion

表 3 人群拥挤数据集比较

Table 3 Comparison of crowd congestion datasets

名称	类型	数量	平均人头数	分辨率/像素	年份	应用场景	参考文献
UCF Crowd Tracking	图片	1 289	N/A	480×360	2008	人群的全局拥挤检测	文献[73]
UCF-CC-50	图片	50	1 279	2 101×2 888	2013	人群计数、人群拥挤检测	文献[74]
Crowd Saliency	图片	N/A	N/A	820×621	2014	显著性检测、拥挤检测、人群计数	文献[75]
Shanghai Tech Part A,B	图片	482	501	589×868	2016	人群计数、密度估计、拥挤检测	文献[76]
UCF-QNRF	图片	1 535	815	2 013×2 902	2018	人群计数和定位、拥挤检测	文献[77]
Loveparade2010	视频	7	N/A	588×783	2010	人群局部拥挤检测、人群跟踪	文献[78]
Khan	视频	15	N/A	1 080×1 440	2019	人群局部拥挤检测	文献[63]
Basalamah	视频	5	10 000	2 006×3 050	2023	人群跟踪、拥挤检测	文献[72]

### 3.1.1 实验数据集

#### 1) 图像库。

(1) UCF Crowd Tracking<sup>[73]</sup>。该数据图形库由中佛罗里达大学于 2008 年获得,包含 1 289 张图像,涉及 3 种不同的马拉松运动场景,即静态、动态和边界层场。按人群的拥挤密度区分,图像中的人群包含低、中、高 3 种。这些场景中的不同密度人群可用于密集人群拥挤检测的算法模型性能测试。

(2) UCF-CC-50<sup>[74]</sup>。UCF-CC-50 数据集是中佛罗里达大学于 2013 年提供,主要来自 FLICKR 网站,它由 50 个不同分辨率的图像组成,每张图像分别包含 94~4 543 人不等,图均 1 279 人,囊括音乐厅、示威集会、体育馆等多种场景。由于此数据集具有十分拥挤的人群场景,因此可用于人群拥挤检测模型的性能测试。

(3) Crowd Saliency<sup>[75]</sup>。马来亚大学于 2014 年整理 UCF 人群数据构建了 Crowd Saliency。该数据集涵盖由瓶颈、高密度、不规则运动引起的不同类

型人群拥挤情况,符合对密集人群拥挤检测的实验数据场景要求。

(4) Shanghai Tech Part A,B<sup>[76]</sup>。该数据集由上海科技大学于 2016 年提供,包含 1 198 幅注释图像,总计 330 165 人。数据集由两部分组成:A 部分的 482 幅图像从互联网上随机采集;B 部分的 716 幅图像是从上海大都市区的繁华街道上拍摄而得。此数据集涵盖多个场景中的不同密度级别的人群,适用于密集人群拥挤检测模型的静态特性测试。

(5) UCF-QNRF<sup>[77]</sup>。中佛罗里达大学于 2018 年发布了 UCF-QNRF 数据集,它包含 1 535 幅图像,分为训练集(1 201 幅图像)和测试集(334 幅图像),图均 815 人,该数据集包含建筑物、植被、道路等真实户外场景中的拥挤人群流,可以用于人群拥堵检测模型的测试。

#### 2) 视频序列。

(1) Basalamah 数据集<sup>[72]</sup>。该数据集由阿卜杜勒-阿齐兹国王大学于 2023 年提供,它模拟了中东米娜地区的宗教朝圣场景,包含直走廊、平滑曲线走

廊、宽-窄-宽形状的走廊、交叉口走廊以及多交叉口走廊场景。在该模拟的视频序列中,有 10 000 个人工智能体从 7 个不同的起点出发,沿着走廊流动形成拥挤人群。该仿真数据集可用于流动人群的拥挤检测模拟研究。

(2)Loveparade2010<sup>[78]</sup>。该数据集收集于 2010 年德国杜伊斯堡的一场人群聚集活动灾难事件。约有 140 万人参加了这起聚集活动,但随之引发的人群拥挤事件直接导致 21 人死亡、652 人受伤。事故发生前的视频被上传到 YouTube 网站,可用于探讨真实场景中的大规模人群拥挤活动特性。

(3)Khan 数据集<sup>[63]</sup>。该数据集是由沙特哈伊勒大学的研究者 KHAN 于 2019 年从 YouTube 上收集的短视频制作而成,包含火车站、音乐会、朝觐等拥挤人群场景。数据集中真实的人群存在局部拥挤活动现象,可用于对密集人群中的局部拥挤定位检测问题开展研究。

### 3.1.2 数据标记

数据标记是机器学习方法在模型学习训练过程中识别原始数据的重要步骤,数据标记的好坏直接影响模型的学习训练效果。人群拥挤检测属于计算机视觉/人工智能的研究范畴,因此对此类研究问题的数据集标记常采用图像数据标记,或创建有边界数字图像(边界框)的方式实现标注。文献[56]通过提取数据的低级视觉特征,使用包含人数的信息特征区域对图像作标注,以定义不同的模糊集以及相应的拥挤级别隶属函数。文献[57]消除图像中的背景,由此获得前景人员图像,进而把图像纹理特征、能量、熵和最大概率标记到图像中作为模型学习训练的分类特征。文献[63]、文献[68]以及文献[72]提取视频数据的人群运动轨迹,对轨迹形状、距离作特征标记,以定义人群的“拥塞”和“正常”类型。文献[61]将数据对象分类为不同的拥挤等级,以对数据集中的人群密度开展标记,继而以标注的拥挤等级训练模型。文献[62]将注意力得分机制注入模型,依据注意力得分的数据标记开展模型训练。文献[66]根据人群的拥挤程度对数据集标记了五级拥挤密度注释,再以人群密度等级值训练模型。文献[67]将图像划分为网格单元,并通过代数法、投票法和博尔达计数法获取网格单元服务标签级别,以此为基础标签训练模型。文献[69]对图像中的人员尺度做手工标记,使用二阶线性回归方法估计人群规模的拟合曲线。文献[70]标注图像中的人员头部数量,再根据头部数量实现人群拥挤检测的识别分类。

数据标记是数据预处理的重要组成部分,通过

对实验数据标记,添加有意义的信息标签,有助于机器学习模型获得有用知识,以提升模型的学习训练效果。在人群拥挤检测数据的标注中,可依据数据类型不同选择恰当的标注方式。例如,针对拥挤人群中的图像分类问题,可为整个图像分配标签或类别属性;针对人群的区域拥挤检测问题,可对检测的定位场景拥挤区域作对象边界标注;针对人群的拥挤视频数据集,需要在视频帧的剪辑对象上添加标签属性特征。此外,公共场所人群的活动具有明显的动态视觉特性,对此类视频数据进行标注需要进一步解释研究对象的时空维度关系,对视频数据的标注可逐帧分析人群活动变化,有助于训练模型识别人群的拥挤行为。

## 3.2 模型性能评估

人群拥挤检测隶属于分类问题,本节介绍该研究问题相关的模型性能评价方法。首先介绍分类模型常用的性能评估,其次介绍对该问题更具针对性的一种评价方法,最后给出基线模型的横向比较结果。

### 3.2.1 通用评估方法

分类问题常使用真阳性(TP,  $N_{TP}$ )、真阴性(TN,  $N_{TN}$ )、假阳性(FP,  $N_{FP}$ )、假阴性(FN,  $N_{FN}$ )作为模型的基础性能评价指标。真阳性表示正类类别被正确预测为正类的数量;真阴性表示负类类别被正确预测为负类的数量;假阳性表示负类类别被错误预测为正类的数量;假阴性表示正类类别被错误预测为负类的数量。

由此可进一步获得模型的准确率(Accuracy,  $A$ )、精准率(Precision,  $P$ )、召回率(Recall,  $R$ )、误报率(FPR,  $R_{FPR}$ )、漏报率(FNR,  $R_{FNR}$ )。各项含义及计算方法如下:

1)准确率表示预测正确的结果占总样本的百分比,计算如下式:

$$A = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{TN} + N_{FP} + N_{FN}} \times 100\% \quad (1)$$

2)精确率也称查准率,表示所有被预测为正的样本中实际为正的样本概率。精确率越大,说明误检越少,精确率越小,说明误检越多。

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \times 100\% \quad (2)$$

3)召回率也称查全率,用来描述在实际为正的样本中被预测为正样本的概率。召回率越大,说明漏检越少,反之亦然。

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \times 100\% \quad (3)$$

另外,在模型的性能评价中,也使用“真正类率”

(TPR)描述模型检测结果中返回的正类占有所有正类的比例。TPR 的计算公式与式(3)完全相同,在此不再赘述。

4)误报率表示负样本被预测为正样本占总负样本的比例。该值越小,模型的性能表现越好。

$$R_{FPR} = \frac{N_{FP}}{N_{TN} + N_{FP}} \times 100\% \quad (4)$$

5)漏报率表示正样本被预测为负样本占总正样本的比例。漏报率越小,模型性能表现越好。

$$R_{FNR} = \frac{N_{FN}}{N_{TN} + N_{FN}} \times 100\% \quad (5)$$

上述评价指标从数值量化的角度描绘了模型的检测效果,在一定程度上可反映模型数值测试中的性能。然而,由于实验数据很难获得均衡样本,即数据不平衡缺陷,因此更多的评价指标被提出。具有代表性的是 P-R (Precision-Recall) 曲线和 ROC (Receiver Operating Characteristic) 曲线。其中, P-R 曲线是评估分类模型性能的一种图形工具,它将召回率作为横轴、精确率作为纵轴绘制而成; ROC 曲线被用于描述模型的测试灵敏度,又称感受曲线,它将 FPR 作为横轴,用 TPR 作为纵轴。文献[79]给出了两种分类算法在 P-R 曲线和 ROC 曲线上的性能比较结果,分别如图 10 和图 11 所示。图 10 所示的 P-R 图中曲线越朝着右上角的方向凸起,表示模型性能越好,而图 11 中 ROC 曲线越凸向左上方,则表示分类器把真正的正样本排在前面的概率越高,算法分类性能越好。

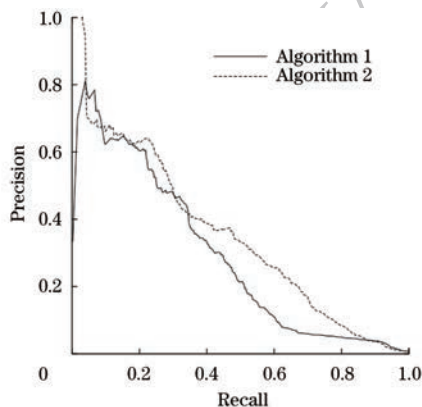


图 10 P-R 曲线  
Fig. 10 P-R curves

### 3.2.2 Khan 评价方法

在对人群拥挤检测问题的研究中,文献[63]提出一种新的模型评估方法,即 Khan 评价方法。该方法使用检测区域与真实拥挤区域之间的差异度作为模型的性能评价指标,能更好地实现人群拥挤区域的定位检测与预警。图 12 展示了 Khan 评价方

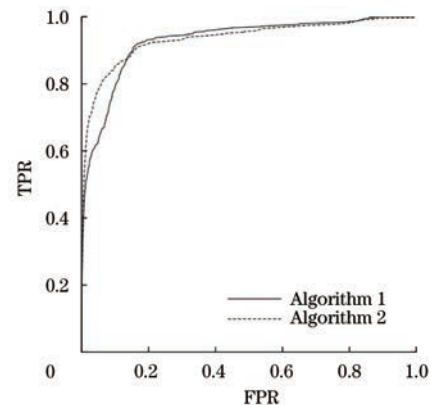


图 11 ROC 曲线  
Fig. 11 ROC curves

法的评估策略流程,如下<sup>[63]</sup>:

**步骤 1** 将输入的视频划分为固定长度的时间段,依据整个段的光流场并将光流场划分成  $m \times n$  个固定大小的非重叠块网格,计算第  $n$  块的平均拥挤度预测值  $p_b$ :

$$p_b = \frac{1}{N} \sum_{k=1}^N T_{osc} \quad (6)$$

式中: $N$  表示轨迹总数; $T_{osc}$  是轨迹  $k$  的振荡值。

**步骤 2** 使用网格平均绝对差  $G_{mad}$  评估算法对人群拥挤检测的质量,如下:

$$G_{mad} = \frac{1}{K} \sum_{i=1}^K \left( \sum_{b=1}^B |p_i^b - g_i^b| \right) \quad (7)$$

式中: $K$  是整个时间片段的总帧数; $p_i^b$  表示在第  $i$  帧时刻第  $b$  个网格块的预测值; $g_i^b$  为第  $i$  帧时刻第  $b$  个网格块的真实值; $B$  是第  $i$  帧时刻图像中的块数。 $G_{mad}$  值越小,表示模型性能越好。

借助 Khan 评价方法<sup>[63]</sup>,表 4 展示了文献[72]对人群拥挤检测问题有关的 SOTA (State-of-the-Arts) 模型性能的横向对比结果(最优结果加粗标注)。表 4 数据表明,随着深度学习技术在人群拥挤检测问题中的应用,表征学习经历底层、中层再到高层语义特征的转换,对解决视频数据中的人群拥挤检测问题有着积极的促进作用。相比以往的机器学习模型,文献[72]使用 Bi-LSTM 模型开展研究,并在表 4 的对比实验中取得最佳性能。这是因为,记录人群活动的视频序列可看作图像帧时间序列计算问题。而传统机器学习模型由于缺乏时序信号处理,在面对视频数据时性能不佳。而传统循环神经网络由于梯度消失/爆炸极易引发长程依赖问题,只能学习人群状态短期依赖关系,难以建模人群活动的长距离依赖。由于 Bi-LSTM 引入门控机制调节人群活动的状态时序积累,这使得文献[72]模型在视频数据的人群活动检测问题研究中展示出性能提升。

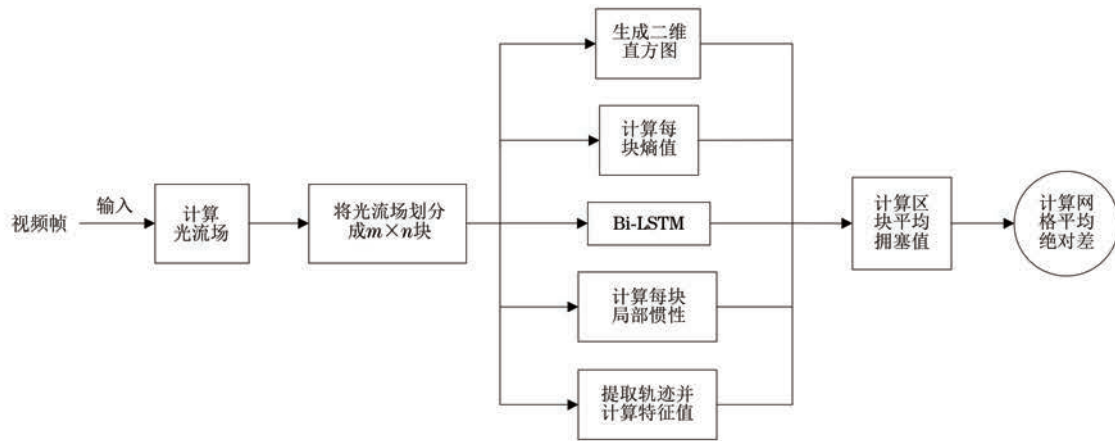


图 12 Khan 评价方法操作流程

Fig. 12 Operation process of Khan evaluation method

表 4 SOTA 模型性能横向对比

Table 4 Horizontal comparison of SOTA models performance

场景	文献[49]模型	文献[50]模型	文献[54]模型	文献[63]模型	文献[68]模型	文献[72]模型
Station1	0.54	0.54	0.46	0.35	0.39	<b>0.21</b>
Station2	0.85	0.55	0.44	0.25	0.29	<b>0.18</b>
Penn station	0.66	0.62	0.40	0.34	0.37	<b>0.27</b>
Seq30	0.45	0.45	0.64	0.40	0.43	<b>0.32</b>
Hseq01	0.96	0.94	0.38	0.29	0.34	<b>0.27</b>
Hseq02	0.94	0.92	0.34	0.27	0.33	<b>0.21</b>
Hseq03	0.47	0.48	0.40	0.35	0.39	<b>0.29</b>
Hseq04	0.82	0.82	0.35	0.27	0.32	<b>0.19</b>
Hseq05	0.76	0.78	0.55	0.45	0.51	<b>0.37</b>
Hseq06	0.93	0.93	0.33	0.25	0.31	<b>0.20</b>
Hseq07	0.90	0.92	0.26	0.16	0.21	<b>0.10</b>
Hseq08	0.86	0.87	0.23	0.19	0.20	<b>0.15</b>
Average	0.76	0.73	0.39	0.29	0.34	<b>0.23</b>

## 4 应用场景与未来挑战

### 4.1 应用场景

人群拥挤检测与预警有着广泛的工程应用场景,尤其在视频监控、人流管理、公共空间结构设计等领域。基于该问题现有的研究成果对其应用场景进行以下归纳:

1)公共场所智能视频监控。在一些公共场所,例如火车站、音乐会场所、商场等,极易出现密集的人群拥挤,而很多人群灾难又源于相关部门未能及时检测并采取正确的应急措施导致<sup>[19]</sup>。如果将人群拥挤检测技术应用到智能视频监控,可以节省大量排查危险的人工操作并做及时的人员安全疏散,有助于避免人群灾难事件的发生和恶化。例如,如图 13(a)所示,针对事故频发的穆斯林宗教朝觐,文献[63]开发了密集人群拥挤检测预警系统,用于协助管理部门排查安全隐患,有效降低所在地随后几

年的宗教朝觐群体性踩踏事故。但该系统只适用于正常流动的群体,当人流密度过大时,其检测性能下降。针对旅客的实时流量监测问题,我国丰石科技公司开发了相应的人群客流检测系统,如图 13(b)所示。该系统展示了监控区域中的人流数量、场馆热力分布及周边交通路况等实时信息<sup>[80]</sup>,可用于绘制区域人群热力图,以达到观察人群拥挤状况、调整人流密度的目的。然而,该系统所采用的人群计数法严重依赖图像清晰度。此外,场景人群拥挤估计仅仅关注人群数量,并未考虑场景的变化,这可能导致系统面对狭窄通道中的人群拥挤时检测性能下降。

2)场区人群调控管理。通过监控设备监测特定区域的人群拥挤密度,可提醒管理人员及时疏散人群拥挤区域,避免踩踏事故的发生,同时也从全局视角把握实时人群客流量的变化趋势,掌握监控区域发生拥挤的动态信息变化,以确保人群活动的安



(a)朝觐场景 (b)客流量监测平台

图 13 智能视频监控应用

Fig. 13 Application of intelligent video surveillance

全<sup>[38]</sup>。例如,我国海康威视推出的人数统计技术被用于某些室内公共场所的人群流量监控。该系统在特定环境中的人数达到阈值时,发出警报并限制游客密度以确保场内人群的安全。图 14 展示了海康威视所开发的智慧景区管理客流监测和分析系统示意图<sup>[81]</sup>。该方法考虑了平台所在的景区应用环境,在售票环节即可根据人流密度限制游客数量,以避免人群拥挤现象的发生。同时,在确保场内游客安全的情况下,在易发生拥挤踩踏的场景区域(例如瓶颈)设置警报装置,及时提醒安全管理人员。



图 14 智慧景区游客流量分析平台

Fig. 14 Smart scenic area tourist flow analysis platform

3)公共场所空间结构设计。人群动力学研究成果可为公共场所环境中的空间结构设计提供有益指导,提高类似火车站、剧院、音乐会等密集人群场所的安全性及人群活动的监管效率<sup>[82]</sup>。文献[19]于2007年对米那地区的穆斯林朝圣人群灾难视频开展人群动力学研究,所获得的运动人群行进轨迹及拥挤定位区域优化了该地的建筑物空间分布结构,之后的几年未曾发生过重大人群拥挤踩踏事件;2023年日本株式会社电装天公司优化了公共场所疏散通道的结构分布,有利于大型人群集聚活动后的退场人群在滞留期间的“时间”和“地点”疏导。此外,该公司正在研发一款对上述离场人群提供疏导服务的智能手机 App,以达到协助退场人员选择合理离场时机的目的<sup>[83]</sup>。

4)人群社会行为学研究。研究人员可基于人群拥挤数据深入研究人类的行为模式。文献[4]对恐

慌状态下的人群活动特征开展研究,发现拥挤人群中的个体具有盲从效应,而群体盲从效应则会随着人群恐慌程度的增加而正比增长,这种人群盲从效应在对拥挤人群的疏散过程中应被考虑。文献[30]研究了人群在瓶颈处的行为模式,发现拥挤人群在堵塞瓶颈会形成拱形效应,这种特殊的人群行为可为人群社会学提供新的研究点。简而言之,研究拥挤人群中的群体及个体行为模式有助于掌握社会群体的行为动态特性,增进对人类社会发展趋势的理解,对揭示人类群体行为活动机制以及制定相应的人群管理策略具有重要的社会科学研究价值。

#### 4.2 未来挑战

尽管学者们从定性研究、定量模型等角度对人群拥挤检测问题开展了研究并取得相应成果,但人类群体活动的复杂性和独特性,为深入理解人群活动的内在本质与行为理解的数据分析处理带来了极大的困难与挑战。现阶段对人群拥挤检测问题的研究依然存在诸多开放问题亟待解决。下文归纳了几个开放性问题,并合理预测未来研究的一些潜在方法和思路:

1)提升模型场景泛化能力。人群拥挤活动的发生具有场景多样性,不会集中于某种特定的活动场景。人群拥挤在不同场景中展示不同的运动特性,例如广场、出入通道的人群拥挤状况各不相同。这是解决该问题、研究计算模型场景局限性的未来挑战之一。

2)复杂场景的检测适应性。大规模的人群活动不仅发生在白昼,也可能发生在夜间。由于夜间光线的昏暗、灯光阴影、物体遮挡等加剧了模型的检测难度,因此复杂视觉场景中的人群拥挤检测是现有模型需要解决的重要问题。

3)模型计算资源消耗高。基于机器学习、深度学习方法的计算模型对计算资源有着极高的需求。在对人群拥挤检测问题的研究中,主流 SOTA 方法建立在对样本的学习训练上,需要耗费大量的计算资源。如何降低模型参数、提升计算效率是未来模型性能优化中的重要问题。

4)合理度量人群拥挤动态等级。目前的研究方法采用的数据集几乎都是低密度人群或者是能够自由活动的高密度人群。人类是拥有自主意识的高级动物,在不受外界因素约束时将自由行走,以最大限度地避免拥挤。尽管现有模型对人群拥挤检测问题具有一定效果,但却忽视了人群拥挤状态的动态变化,从而引发误检。因此,合理制定人群拥挤动态等级的度量方法,更加科学地探讨此类问题,也是未来

需要解决的问题之一。

近年来,深度学习成为计算模型的研究热点,对该问题的研究可延拓表征学习,以深入挖掘人群拥挤的深层表征特性。伴随 CPU/GPU 算力的提升,具有大规模参数和复杂计算结构特征的新型机器学习大模型(Large Models)<sup>[84-85]</sup>在面向更加复杂的计算任务和数据处理时崭露头角,展示提升表达能力和预测性能的巨大潜力。人群拥挤检测是计算机视觉中大规模数据输入、加工处理、识别推理分析的复杂处理过程。大模型的使用,可通过增加网络深度与宽度捕捉更加复杂的行为模式和依赖关系,在处理大规模数据过程中获得更好的模型可扩展性及泛化能力,非常适合人群拥挤检测问题研究中所涉及的语义分割、图像描述、场景理解等复杂问题。在未来,可深入挖掘大模型面对大规模图像/视频数据的处理潜力,以有效探究人群拥挤活动的本质特性,提高计算模型的检测性能。

另一方面,人群拥挤检测属于计算机视觉、人工智能、生物视脑神经学等交叉领域的科学问题,该问题所涉及的视觉感知、前景分割、行为理解、危险预警等是模仿动物的智能,这与人工智能的发展方向不谋而合。因此,借助动物视感神经机理、视脑危险预警机制,构建适用于计算机视觉场景下的人群拥挤检测与预警计算模型将成为对该问题研究的一种可行技术手段。目前,一些学者已前瞻性地从生物视感机制用于人群活动感知计算模型的构建。文献[86]基于蝗虫小叶巨型运动检测器(LGMD)提出一种改进神经网络(CEBDNN),用于检测公共场所中的人群逃逸行为。文献[87]基于 LGMD 提出一种人工视觉系统(CGBPNN),用于预警公共场所突发的人群局部聚集活动。在未来,借助生物视脑认知神经机制开展对人群拥挤活动感知与异常行为的检测工作,将把人工智能的发展推进新进程。

## 5 结束语

围绕定性研究和定量模型两方面,梳理现阶段人群活动感知与拥挤检测的研究成果。对该问题的定性研究阐述了人群拥挤状态下的行为特性,对定量模型的调研则归纳了人群拥挤状态的检测方法。在此基础上,总结该问题研究在现实世界中的应用,最后探讨人群拥挤检测的未来挑战和发展方向。本文涉及计算机视觉、人工智能领域中的人群活动感知与拥挤行为检测研究,可为深入探讨人群活动本质特性与拥挤行为检测方法提供有益启发。

## 参考文献

- [1] KHAN S D, TAYYAB M, AMIN M K, et al. Towards a crowd analytic framework for crowd management in Majid-al-Haram [EB/OL]. [2024-01-05]. <https://arxiv.org/abs/1709.05952>. pdf.
- [2] PIN S C, HARON F, SARMADY S, et al. Applying TRIZ principles in crowd management [J]. *Safety Science*, 2011, 49(2): 286-291.
- [3] HELBING D, FARKAS I, VICSEK T. Simulating dynamical features of escape panic [J]. *Nature*, 2000, 407(6803): 487-490.
- [4] KOK V J, LIM M K, CHAN C S. Crowd behavior analysis: a review where physics meets biology [J]. *Neurocomputing*, 2016, 177: 342-362.
- [5] ZHAN B, MONEKOSSO D N, REMAGNINO P, et al. Crowd analysis: a survey [J]. *Machine Vision and Applications*, 2008, 19(5/6): 345-357.
- [6] SILVEIRA J J J, MUSSE S, JUNG C. Crowd analysis using computer vision techniques [J]. *IEEE Signal Processing Magazine*, 2010, 8: 66-77.
- [7] LAMBA S, NAIN N. A literature review on crowd scene analysis and monitoring [J]. *International Journal of Urban Design for Ubiquitous Computing*, 2016, 4(2): 9-20.
- [8] TOMAR A, KUMAR S, PANT B. Crowd analysis in video surveillance: a review [C]//*Proceedings of the International Conference on Decision Aid Sciences and Applications (DASA)*. Washington D. C., USA: IEEE Press, 2022: 162-168.
- [9] THIDA M, YONG Y L, CLIMENT-PÉREZ P, et al. A literature review on video analytics of crowded scenes [EB/OL]. [2024-01-05]. [https://link.springer.com/chapter/10.1007/978-3-642-41512-8\\_2](https://link.springer.com/chapter/10.1007/978-3-642-41512-8_2).
- [10] AL-SHAERY A M, ALSHEHRI S S, FAROOQI N S, et al. In-depth survey to detect, monitor and manage crowd [J]. *IEEE Access*, 2020, 8: 209008-209019.
- [11] GAYATHRI H, APARNA P M, VERMA A. A review of studies on understanding crowd dynamics in the context of crowd safety in mass religious gatherings [J]. *International Journal of Disaster Risk Reduction*, 2017, 25: 82-91.
- [12] 王曲, 赵炜琪, 罗海勇, 等. 人群行为分析研究综述 [J]. *计算机辅助设计与图形学学报*, 2018, 30(12): 2353-2365. WANG Q, ZHAO W Q, LUO H Y, et al. Research on crowd behavior analysis: a review [J]. *Journal of Computer-Aided Design & Computer Graphics*, 2018, 30(12): 2353-2365. (in Chinese)
- [13] SJARIF N N A, SHAMSUDDIN S M, HASHIM S Z. Detection of abnormal behaviors in crowd scene: a review [J]. *International Journal of Advances in Soft Computing and Its Applications*, 2012, 4(1): 12-22.
- [14] SODEMANN A A, ROSS M P, BORGHETTI B J. A review of anomaly detection in automated surveillance [J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 2012, 42(6): 1257-1272.
- [15] LI T, CHANG H, WANG M, et al. Crowded scene analysis: a survey [J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2015, 25(3): 367-386.
- [16] 徐涛, 田崇阳, 刘才华. 基于深度学习的人群异常行为检测综述 [J]. *计算机科学*, 2021, 48(9): 125-134. XU T, TIAN C Y, LIU C H. Deep learning for abnormal crowd behavior detection: a review [J]. *Computer Science*, 2021, 48(9): 125-134. (in Chinese)
- [17] HILLEBRAND A, HOOGEVEEN H, GERAERTS R. Comparing different metrics quantifying pedestrian safety [J].

- Collective Dynamics, 2020, 5: 46.
- [18] HELBING D, MOLNÁR P, FARKAS I J, et al. Self-organizing pedestrian movement [J]. *Environment and Planning B: Planning and Design*, 2001, 28(3): 361-383.
- [19] HELBING D, JOHANSSON A, AL-ABIDEEN H Z. Dynamics of crowd disasters: an empirical study[J]. *Physical Review E-Statistical, Nonlinear, and Soft Matter Physics*, 2007, 75(4): 1-7.
- [20] HELBING D, MUKERJI P. Crowd disasters as systemic failures: analysis of the love parade disaster[J]. *EPJ Data Science*, 2012, 1(1): 7.
- [21] HELBING D. A mathematical model for the behavior of pedestrians[J]. *Behavioral Science*, 1991, 36(4): 298-310.
- [22] STILL G K. Crowd dynamics [EB/OL]. [2024-01-05]. <https://www.crowddynamics.com/>.
- [23] SEYFRIED A, PORTZ A, SCHADSCHNEIDER A. Phase coexistence in congested states of pedestrian dynamics[EB/OL]. [2024-01-05]. <https://arxiv.org/pdf/1006.3546>.
- [24] LIU X, SONG W G, ZHANG J. Extraction and quantitative analysis of microscopic evacuation characteristics based on digital image processing[J]. *Physica A: Statistical Mechanics and Its Applications*, 2009, 388(13): 2717-2726.
- [25] KRAUSZ B, BAUCKHAGE C. Analyzing pedestrian behavior in crowds for automatic detection of congestions[C]//*Proceedings of the IEEE International Conference on Computer Vision Workshops (ICCV Workshops)*. Washington D. C., USA: IEEE Press, 2011: 144-149.
- [26] LI L, LIU H, HAN Y B. An approach to congestion analysis in crowd dynamics models [J]. *Mathematical Models and Methods in Applied Sciences*, 2020, 30(5): 867-890.
- [27] MEHRAN R, OYAMA A, SHAH M. Abnormal crowd behavior detection using social force model[C]//*Proceedings of 2009 IEEE Conference on Computer Vision and Pattern Recognition*. Washington D. C., USA: IEEE Press, 2009: 935-942.
- [28] LI W H, GONG J H, YU P, et al. Simulation and analysis of congestion risk during escalator transfers using a modified social force model[J]. *Physica A: Statistical Mechanics and Its Applications*, 2015, 420: 28-40.
- [29] MA Y, LEE E W M, YUEN R K K. Dual effects of pedestrian density on emergency evacuation [J]. *Physics Letters A*, 2017, 381(5): 435-439.
- [30] SABOIA P, GOLDENSTEIN S. Crowd simulation: applying mobile grids to the social force model [J]. *The Visual Computer*, 2012, 28(10): 1039-1048.
- [31] LI L, LIU H, HAN Y B. Arch formation-based congestion alleviation for crowd evacuation[J]. *Transportation Research Part C: Emerging Technologies*, 2019, 100: 88-106.
- [32] HELBING D, MOLNÁR P. Social force model for pedestrian dynamics[J]. *Physical Review E*, 1995, 51(5): 4282-4286.
- [33] HENDERSON L F. The statistics of crowd fluids [J]. *Nature*, 1971, 229(5284): 381-383.
- [34] HENDERSON L F. On the fluid mechanics of human crowd motion[J]. *Transportation Research*, 1974, 8(6): 509-515.
- [35] HELBING D. A fluid dynamic model for the movement of pedestrians[EB/OL]. [2024-01-05]. <https://arxiv.org/abs/cond-mat/9805213>.
- [36] HE X, CHEN L, ZHU Q. A novel method for large crowd flow[J]. *Lecture Notes in Computer Science*, 2011, 6758: 67-78.
- [37] DEGOND P, HUA J L. Self-organized hydrodynamics with congestion and path formation in crowds [J]. *Journal of Computational Physics*, 2013, 237: 299-319.
- [38] FELEMBAN E A, REHMAN F U, ALI BIABANI S A, et al. Digital revolution for Hajj crowd management: a technology survey [J]. *IEEE Access*, 2020, 8: 208583-208609.
- [39] CHEONG K H, POESCHMANN S, LAI J W, et al. Practical automated video analytics for crowd monitoring and counting[J]. *IEEE Access*, 2019, 7: 183252-183261.
- [40] ALMER A, PERKO R, SCHROM-FEIERTAG H, et al. Critical situation monitoring at large scale events from airborne video based crowd dynamics analysis [EB/OL]. [2024-01-05]. [https://link.springer.com/chapter/10.1007/978-3-319-33783-8\\_20](https://link.springer.com/chapter/10.1007/978-3-319-33783-8_20).
- [41] SHALASH W M, ALZAHIRANI A A, AL-NUFAII S H. Crowd detection management system[C]//*Proceedings of the 2nd International Conference on Computer Applications & Information Security (ICCAIS)*. Washington D. C., USA: IEEE Press, 2019: 1-8.
- [42] SAMONTE M J C, GARCIA A C, GORRE J E E, et al. CrowdSurge: a crowd density monitoring solution using smart video surveillance with security vulnerability assessment [J]. *Journal of Advances in Information Technology*, 2022, 13(2): 22-30.
- [43] ALAFIF T, ALZAHIRANI B, CAO Y, et al. Generative adversarial network based abnormal behavior detection in massive crowd videos: a Hajj case study [J]. *Journal of Ambient Intelligence and Humanized Computing*, 2022, 13(8): 4077-4088.
- [44] 王保云, 王婷, 张玲莉, 等. 人群聚集场所的拥挤踩踏危险度评估算法[J]. *中国安全科学学报*, 2019, 29(6): 152-157. WANG B Y, WANG T, ZHANG L L, et al. Risk assessment algorithm of crowd crushing and trampling in crowd-gathered place [J]. *China Safety Science Journal*, 2019, 29(6): 152-157. (in Chinese)
- [45] 吕伟, 姜雅娟, 李晓恋, 等. 人群聚集拥挤度的量化表征方法[J]. *中国安全生产科学技术*, 2023, 19(1): 14-20. LÜ W, JIANG Y J, LI X L, et al. Quantitative method for characterizing congestion degree of gathering crowd [J]. *Journal of Safety Science and Technology*, 2023, 19(1): 14-20. (in Chinese)
- [46] MARANA A N, VELASTIN S A, COSTA L F, et al. Automatic estimation of crowd density using texture [J]. *Safety Science*, 1998, 28(3): 165-175.
- [47] MARANA A N, DA FONTOURA COSTA L, LOTUFO R A, et al. Estimating crowd density with Minkowski fractal dimension [C] // *Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing*. Washington D. C., USA: IEEE Press, 1999: 3521-3524.
- [48] RAHMALAN H, NIXON M S, CARTER J N. On crowd density estimation for surveillance [C]//*Proceedings of the IET Conference on Crime and Security*. Washington D. C., USA: IEEE Press, 2006: 540-545.
- [49] KRAUSZ B, BAUCKHAGE C. Loveparade2010: automatic video analysis of a crowd disaster[J]. *Computer Vision and Image Understanding*, 2012, 116(3): 307-319.
- [50] HUANG L D, CHEN T, WANG Y, et al. Congestion detection of pedestrians using the velocity entropy: a case study of Love Parade 2010 disaster[J]. *Physica A: Statistical Mechanics and Its Applications*, 2015, 440: 200-209.
- [51] KRAUSZ B, BAUCKHAGE C. Automatic detection of dangerous motion behavior in human crowds[C]//*Proceedings of the 8th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS)*. Washington D. C., USA: IEEE Press, 2011: 224-229.
- [52] SOLMAZ B, MOORE B E, SHAH M. Identifying behaviors in crowd scenes using stability analysis for dynamical systems[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*,

- 2012, 34(10): 2064-2070.
- [53] REEJA S R, KAVYA D N P. A system for movement detecting congestion [J]. *International Journal of Computers & Technology*, 2014, 13(3): 4302-4307.
- [54] BEK S, MONARI E. The crowd congestion level—a new measure for risk assessment in video-based crowd monitoring[C]//*Proceedings of the IEEE Global Conference on Signal and Information Processing (GlobalSIP)*. Washington D. C., USA: IEEE Press, 2016: 1212-1217.
- [55] CHAHAL A, GULIA P. Machine learning and deep learning[J]. *International Journal of Innovative Technology and Exploring Engineering*, 2019, 8(12): 4910-4914.
- [56] COIANIZ T. Estimating the crowding level with a neuro-fuzzy classifier [J]. *Journal of Electronic Imaging*, 1997, 6(3): 319.
- [57] LO B P L, VELASTIN S A. Automatic congestion detection system for underground platforms[C]//*Proceedings of 2001 International Symposium on Intelligent Multimedia, Video and Speech Processing*. Washington D. C., USA: IEEE Press, 2001: 158-161.
- [58] KJÆRGAARD M B, WIRZ M, ROGGEN D, et al. Detecting pedestrian flocks by fusion of multi-modal sensors in mobile phones [C] // *Proceedings of the 2012 ACM Conference on Ubiquitous Computing*. New York, USA: ACM Press, 2012: 240-249.
- [59] ELHAMSHARY M, YOUSSEF M, UCHIYAMA A, et al. CrowdMeter: congestion level estimation in railway stations using smartphones [C] // *Proceedings of the IEEE International Conference on Pervasive Computing and Communications (PerCom)*. Washington D. C., USA: IEEE Press, 2018: 1-12.
- [60] ISLAM S, KAFI A, ISLAM M Z, et al. IoT based crowd congestion and stampede avoidance in Hajj using wemos D1 with machine learning approach[C]//*Proceedings of the 4th International Conference on Electrical Information and Communication Technology (EICT)*. Washington D. C., USA: IEEE Press, 2019: 1-5.
- [61] FELICIANI C, NISHINARI K. Measurement of congestion and intrinsic risk in pedestrian crowds [J]. *Transportation Research Part C: Emerging Technologies*, 2018, 91: 124-155.
- [62] 张菁, 陈庆奎. 基于注意力机制的狭小空间人群拥挤度分析[J]. *计算机工程*, 2020, 46(9): 254-260, 267. ZHANG J, CHEN Q K. Analysis of crowd congestion degree in narrow space based on attention mechanism[J]. *Computer Engineering*, 2020, 46(9): 254-260, 267. (in Chinese)
- [63] KHAN S D. Congestion detection in pedestrian crowds using oscillation in motion trajectories [J]. *Engineering Applications of Artificial Intelligence*, 2019, 85: 429-443.
- [64] KHAN S D, MAHMUD M, ULLAH H, et al. Crowd congestion detection in videos[J]. *Electronic Imaging*, 2020, 32(6): 721-727.
- [65] LIU S Q, ZHAO Y C, CHEN B. WiCount: a deep learning approach for crowd counting using WiFi signals [C] // *Proceedings of the IEEE International Symposium on Parallel and Distributed Processing with Applications and 2017 IEEE International Conference on Ubiquitous Computing and Communications (ISPA/IUCC)*. Washington D. C., USA: IEEE Press, 2017: 967-974.
- [66] TRIPATHY S K, SRIVASTAVA R. A real-time two-input stream multi-column multi-stage convolution neural network (TIS-MCMS-CNN) for efficient crowd congestion-level analysis[J]. *Multimedia Systems*, 2020, 26(5): 585-605.
- [67] LI Y, SARVI M, KHOSHELHAM K, et al. Multi-view crowd congestion monitoring system based on an ensemble of convolutional neural network classifiers [J]. *Journal of Intelligent Transportation Systems*, 2020, 24(5): 437-448.
- [68] FELEMBAN E, DAUD KHAN S, NASEER A, et al. Deep trajectory classification model for congestion detection in human crowds[J]. *Computers, Materials & Continua*, 2021, 68(1): 705-725.
- [69] JEONG J, CHOI J, JO D U, et al. Congestion-aware Bayesian loss for crowd counting [J]. *IEEE Access*, 2022, 10: 8462-8473.
- [70] ALASHBAN A, ALSADAN A, ALHUSSAINAN N F, et al. Single convolutional neural network with three layers model for crowd density estimation[J]. *IEEE Access*, 2022, 10: 63823-63833.
- [71] DUAN J, LIU H, GONG W, et al. Crowd evacuation under real data: a crowd congestion control method based on sensors and knowledge graph [J]. *IEEE Sensors Journal*, 2023, 23(8): 8923-8931.
- [72] BASALAMAH S, KHAN S D, FELEMBAN E, et al. Deep learning framework for congestion detection at public places via learning from synthetic data [J]. *Journal of King Saud University-Computer and Information Sciences*, 2023, 35(1): 102-114.
- [73] ALI S, SHAH M. Floor fields for tracking in high density crowd scenes[J]. *Lecture Notes in Computer Science*, 2008, 5303(2): 1-14.
- [74] IDREES H, SALEEMI I, SEIBERT C, et al. Multi-source multi-scale counting in extremely dense crowd images [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Washington D. C., USA: IEEE Press, 2013: 2547-2554.
- [75] LIM M K, KOK V J, LOY C C, et al. Crowd saliency detection via global similarity structure [C] // *Proceedings of the 22nd International Conference on Pattern Recognition*. Washington D. C., USA: IEEE Press, 2014: 3957-3962.
- [76] ZHANG Y, ZHOU D, CHEN S, et al. Single-image crowd counting via multi-column convolutional neural network [EB/OL]. [2024-01-05]. <https://ieeexplore.ieee.org/document/7780439>.
- [77] IDREES H, TAYYAB M, ATHREY K, et al. Composition loss for counting, density map estimation and localization in dense crowds [EB/OL]. [2024-01-05]. [https://link.springer.com/chapter/10.1007/978-3-030-01216-8\\_33](https://link.springer.com/chapter/10.1007/978-3-030-01216-8_33).
- [78] Loveparadeduisburg. Official documentary of the loveparade 2010 disaster (English!) [EB/OL]. [2024-01-05]. [https://mbd.baidu.com/newspage/data/videoland?nid=sv\\_12241752367291196180](https://mbd.baidu.com/newspage/data/videoland?nid=sv_12241752367291196180).
- [79] DAVIS J, GOADRICH M. The relationship between precision-recall and ROC curves [C] // *Proceedings of the 23rd International Conference on Machine Learning*. New York, USA: ACM Press, 2006: 233-240.
- [80] 丰石科技. 实时客流量监测平台 [EB/OL]. [2024-01-05]. [http://www.richstonedt.com/product\\_traffic\\_passengerflow.html](http://www.richstonedt.com/product_traffic_passengerflow.html). Fengshi Technology. Real-time passenger flow monitoring platform [EB/OL]. [2024-01-05]. [http://www.richstonedt.com/product\\_traffic\\_passengerflow.html](http://www.richstonedt.com/product_traffic_passengerflow.html). (in Chinese)
- [81] 海康威视. 智慧文博管理平台 [EB/OL]. [2024-01-05]. <https://www.hikvision.com/cn/software-product/infovision-CTMP-cultural-museum/>. Hikvision. Smart blog management platform [EB/OL]. [2024-01-05]. <https://www.hikvision.com/cn/software-product/infovision-CTMP-cultural-museum/>. (in Chinese)
- [82] 王起全, 杨鑫刚, 蓝军, 等. 多源流理论视域下的地铁拥挤踩踏事故应急管理策略 [J]. *中国安全科学学报*, 2023, 33(11): 181-188.

- WANG Q Q, YANG X G, LAN J, et al. Emergency management strategy of subway stampede accident based on multi-stream theory[J]. China Safety Science Journal, 2023, 33(11): 181-188. (in Chinese)
- [83] Denso Ten. VISION 2030[EB/OL]. [2024-01-05]. [https://www.denso-ten.com/jp/company/publication/img/brochure\\_cn.pdf](https://www.denso-ten.com/jp/company/publication/img/brochure_cn.pdf).
- [84] DEVLIN J, CHANG M W, LEE K, et al. BERT: pre-training of deep bidirectional transformers for language understanding[EB/OL]. [2024-01-05]. <https://arxiv.org/abs/1810.04805>.
- [85] RADFORD A, NARASIMHAN K, SALIMANS T, et al. Improving language understanding by generative pre-training [EB/OL]. [2024-01-05]. <https://www.cs.princeton.edu/courses/archive/spring20/cos598C/lectures/lec4-pretraining.pdf>.
- [86] HU B, ZHANG Z H, LI L. Lgmd-based visual neural network for detecting crowd escape behavior[C]//Proceedings of the 5th IEEE International Conference on Cloud Computing and Intelligence Systems (CCIS). Washington D. C., USA: IEEE Press, 2018: 772-778.
- [87] 刘倡, 胡滨. 生物启发的人群突发局部聚集感知神经网络[J]. 计算机工程与应用, 2022, 58(16): 164-174.
- LIU C, HU B. Bio-inspired neural network for perceiving suddenly localized crowd gathering [J]. Computer Engineering and Applications, 2022, 58(16): 164-174. (in Chinese)

文字编辑 吴云芳  
栏目编辑 宋圆

计算机工程  
www.ecice06.com