

基于物联网的旅游人群密集区踩踏风险图像监控方法研究

朱文忠^{1,2}, 蒋华龙¹, 周述文¹

(1 四川理工学院 计算机学院, 四川 自贡 643000;

2 江河流域生态环境的集成感知与应用院士(专家)工作站, 四川 自贡 643000)

摘 要: 旅游人群密集区踩踏的行为存在很大的突发性和随机性, 关键反映特征易受到遮挡, 存在监控死角, 传统监控方法缺少独立行为识别能力. 由于受到遮挡的影响, 对一些疑似行为的识别不够准确, 对此提出一种基于物联网的旅游人群密集区踩踏风险图像监控方法, 分析了物联网监控平台, 提取旅游人群密集区踩踏风险图像的 Hu 不变矩特征, 将其输入 RBF 神经网络中进行学习和分类, 获取各种类型的旅游人群密集区踩踏行为, 将测试样本输入建立的 RBF 神经网络模型中进行测试, 与 RBF 网络输出相应的测试样本即为旅游密集区踩踏风险图像, 从而实现旅游密集区踩踏风险图像监控. 仿真实验结果表明, 采用所提方法对旅游人群密集区踩踏风险图像进行监控, 识别准确率及效率均较传统方法有很大的改善.

关键词: 物联网; 旅游人群密集区; 踩踏风险; 监控

中图分类号: TP391

文献标识码: A

文章编号: 1000-7180(2016)02-0120-05

Image Monitoring Method Research Based on the Internet of Things Crowded Areas Tourism Trampling Risk

ZHU Wen-zhong^{1,2}, JIANG Hua-long¹, ZHOU Shu-wen¹

(1 School of Computer Science, Sichuan University of Science & Engineering, Zigong 643000, China;

2 Sichuan Provincial Academician (Expert) Workstation-Integrated Perception and Application of Eco-Environment in River Basins, Zigong 643000, China)

Abstract: The behavior that the crowded areas tourism is quite sudden and randomness, key to reflect the characteristics of susceptible to keep out, there is monitoring blind Angle, the traditional approach to monitoring recognition ability, lack of independent behavior is affected by the block, on some suspected behavior lack of accurate identification, puts forward a kind of based on Internet of things crowded areas tourism trampling risk image monitoring method, analyzes the Internet monitoring platform, to extract the crowded areas tourism trampling risk Hu moment invariant features of the image and the input of RBF neural network learning and classification, crowded areas for various types of tourism trampling behavior, will test samples in the input of RBF neural network model is established to test, and the RBF network output corresponding test sample trample risk image is the tourism concentration areas, so as to realize tourism cluster trample image monitoring risk. The simulation results show that the proposed method in crowded areas tourism trampling risk monitor image, accuracy and efficiency than traditional methods have greatly improved.

Key words: the Internet of things; tourism crowded areas; stamp on risk; monitoring

收稿日期: 2015-04-11; 修回日期: 2015-05-28

基金项目: 江河流域生态环境的集成感知与应用院士(专家)工作站项目(YSGZZ2015); 企业信息化与物联网测控技术四川省重点实验室项目(2014WYJ06, 2015WZJ01); 四川省智慧旅游研究基金(ZHZ14-02, ZHZ14-03)

1 引言

近年来,随着人们物质生活的不断提高,越来越多的人热爱旅游,踩踏事故在旅游人群密集区时有发生,给人们的生命财产安全带来了很大的威胁^[1-2]. 监控技术作为保证人身财产安全的重要手段之一被广泛应用,因此,研究一种有效的监控方法,从而预防踩踏事件的发生具有重要意义,这已成为相关学者研究的重点课题,受到越来越广泛的关注^[3-5].

目前,旅游人群密集区踩踏风险图像监控方法有很多,主要包括贝叶斯网络方法、SVM 分类方法和信息熵方法. 相关研究也取得了一定的成果,其中,文献[6]提出一种基于运动轨迹的旅游人群密集区踩踏风险图像监控方法,该方法包括了人体检测、人体剪影提取、躯体四肢识别、头部跟踪等处理步骤. 但目标在运动过程中通常存在自身、外界遮挡干扰,实用性有限;文献[7]提出一种基于贝叶斯网络的旅游人群密集区踩踏风险图像监控方法,通过贝叶斯网络对人群进行建模,采用不同层次的语义识别实现监控,但该方法识别率不高;文献[8]提出一种基于颜色信息的旅游人群密集区踩踏风险图像监控方法,采用聚类的方式进行颜色分块,以实现监控,但该方法计算负担大,相同颜色块之间的前后图像帧匹配无法实现;文献[9]提出一种基于线性 SVM 算法的旅游人群密集区踩踏风险图像监控方法,其视觉特征主要采用 SIFT 算法,但该方法适应性不高;文献[10]提出一种基于隐随机场的旅游人群密集区踩踏风险图像监控方法,通过视觉信息对旅游人群密集区踩踏行为场景进行识别,但该方法具有分类困难的问题,监控效果不佳.

本文提出了一种基于物联网的旅游人群密集区踩踏风险图像监控方法,分析了物联网监控平台,提取旅游人群密集区踩踏风险图像的 Hu 不变矩特征将其输入至 RBF 神经网络中进行学习,获取各种类型的旅游人群密集区踩踏行为,从而实现监控. 经实验验证,所提方法具有很高的精度和效率.

2 基于物联网的旅游人群密集区踩踏风险图像监控方法

2.1 物联网监控平台

物联网技术可有效解决旅游人群密集区踩踏风险图像监控中遇到的问题. 针对海量图像监控信息,通过物联网感知、分析、整合旅游人群密集区踩踏风

险图像的各项关键信息,将各项应用集中于一个统一的平台.

物联网监控平台主要包括感知层、网络层与应用层技术. 将物联网各层次技术和旅游人群密集区踩踏风险图像监控体系相结合,即可建立基于物联网的旅游人群密集区踩踏风险图像监控平台,上述平台的框架如图 1 所示.




图 1 物联网监控平台

旅游人群密集区踩踏风险图像通过感知层的传感器、RFID 等将旅游人群密集区踩踏风险的 Hu 不变矩特征信息传输至识别模块中,识别模块通过 RBF 网络对旅游密集区踩踏风险图像进行识别,将识别结果发送至应用层中,从而实现旅游密集区踩踏风险图像的监控.

2.2 旅游人群密集区踩踏风险图像的 Hu 不变矩特征的提取

Hu 不变矩能够有效描述旅游人群密集区踩踏风险图像位置、大小等特征,不但具有很高的识别稳定性,而且具有缩放、旋转和平移不变性等特点. 所以本文提取旅游人群密集区踩踏风险图像的 Hu 不变矩特征,将其输入至 RBF 神经网络中进行学习,为旅游人群密集区踩踏的识别提供依据.

首先给出旅游人群密集区踩踏风险图像矩阵 $f(m, n)$ 的 $p + q$ 阶矩:

$$M_{pq} = \sum_{m=1}^M \sum_{n=1}^N m^p n^q f(m, n) \quad (1)$$

其中心距为

$$u_{pq} = \sum_{m=1}^M \sum_{n=1}^N (m - \bar{x})^p (n - \bar{y})^q f(m, n) \quad (2)$$

式中, $p, q = 0, 1, 2, \dots$.

$$\bar{x} = \frac{\sum_{m=1}^M \sum_{n=1}^N m f(m, n)}{\sum_{m=1}^M \sum_{n=1}^N f(m, n)} \quad (3)$$

$$\bar{y} = \frac{\sum_{m=1}^M \sum_{n=1}^N n f(m, n)}{\sum_{m=1}^M \sum_{n=1}^N f(m, n)} \quad (4)$$

式中, $\bar{x} = M_{10}/M_{00}, \bar{y} = M_{01}/M_{00}; \bar{x}, \bar{y}$ 表示旅游人群密集区踩踏风险图像的重心。

完成对中心矩 u_{pq} 的归一化处理:

$$\eta_{pq} = u_{pq}/u'_{00} \quad (5)$$

式中, $r = \{(p+q)/2\} + 1, p+q = 2, 3, \dots$

以下 7 个对平移、旋转及尺度变换不变的矩是利用归一化的二阶和三阶中心矩组合得到的:

$$M_1 = \eta_{20} + \eta_{02} \quad (6)$$

$$M_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2 \quad (7)$$

$$M_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \quad (8)$$

$$M_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2 \quad (9)$$

$$M_5 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12}) \cdot [(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03}) \cdot [3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \quad (10)$$

$$M_6 = (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \quad (11)$$

$$M_7 = (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12}) \cdot [(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + (\eta_{30} - 3\eta_{12})(\eta_{21} + \eta_{03}) \cdot [3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \quad (12)$$

上述矩阵即为旅游人群密集区踩踏风险图像的 7 个不变矩特征。

2.3 基于 RBF 神经网络的旅游人群密集区踩踏风险图像识别

RBF 神经网络具有学习效率高、并行高速处理等优点,因此,本文将 RBF 神经网络作为旅游人群密集区踩踏风险图像识别的方法。

首先对 RBF 神经网络进行分析。径向基(RBF)神经网络是一种具有单隐含层的三层前馈神经网络,其映射关系通常由输入层和隐层间的非线性映射及隐含层与输出层间的线性变化构成。详细分析如下所示。

(1) 从输入空间到隐含层空间的非线性转换。假设 RBF 网络的输入为 $X = [X_{1l}, X_{2l}, \dots, X_{nl}]^T (l = 1, 2, \dots, N)$, 将高斯函数作为 RBF 神经网络隐含层的激活函数,则隐含层输出如下:

$$h_{li} = \exp \frac{-(\|X_l - c_i\|)^2}{2\sigma_i^2} \quad (13)$$

式中, $\varphi(\cdot)$ 表示隐单元的变换函数; X_l 表示 n 维输入向量; $\|\cdot\|$ 表示欧氏距离; c_i 表示第 i 个隐含层神经元的数据中心; σ_i 用于描述聚类宽度。

(2) 从隐含层空间到输出层空间的线性组合。第 k 个节点的输出为

$$y_k = \sum_{i=1}^p w_{ik} \exp \frac{-(\|X_l - c_i\|)^2}{2\sigma_i^2} \quad (14)$$

式中, w_{ik} 表示第 i 个隐单元和第 k 个输出之间的联接权; p 表示隐单元量; m 表示输出维数。

利用 RBF 神经网络对物联网感知层传来的旅游人群密集区踩踏风险图像进行识别,实质上就是将旅游人群密集区踩踏风险图像的 7 个 Hu 不变矩作为 RBF 神经网络的输入,通过学习与分类,获取各种类型的旅游人群密集区踩踏行为,详细实现过程如下:

(1) 将物联网感知层采集的 Hu 不变矩特征构成特征矩阵 $M = [M_1, M_2, \dots, M_N]$ 作为 RBF 神经网络的输入向量,对应的目标输出矩阵则可描述成 $Y = [Y_1, Y_2, \dots, Y_N]$, 将其作为全部样本的输出;

(2) 假设隐含层节点个数为 p_0 , 利用 k 均值聚类算法进行聚类,获取聚类中心 c_i 与聚类宽度 σ_i ;

(3) 通过下式对聚类目标函数 S 进行计算,若 $S < \omega$, 则停止聚类;反之,对隐含层节点个数 P 值进行更新,重新进行步骤(2),直至 $S < \omega$, 则有:

$$S = \frac{1}{N} \sum_{i=1}^N \frac{b_i - a_i}{\max(b_i - a_i)} \quad (15)$$

式中, N 表示输入层样本个数; a_i 表示样本 i 与同类样本之间的平均距离; b_i 表示样本 i 及其余类别最近一个聚类样本的平均距离;

(4) 通过式(13) 求出隐含层单元的输出;

(5) 对 w_{ik} 进行初始化操作,计算隐含层到输出层的实际输出,则第 k 个输出可通过式(14) 求出。

(6) 通过式(16) 对网络输出均方根误差 $RMSE$ 值进行计算,若 $RMSE$ 值低于既定目标误差,则结束训练;否则,调整权值,继续进行迭代。

$$RMSE = \sqrt{\frac{\sum_{l=1}^N \sum_{k=1}^p (Y - Y_{lk})^2}{pN}} \quad (16)$$

式中, Y 表示 RBF 神经网络的输出; Y_{lk} 表示真实值。

(7) 将测试样本输入建立的 RBF 神经网络模型中进行测试。

图 2 描述的是 RBF 网络识别过程。

图 2 方框中的区域表示 Hu 不变矩特征的提取结果,也就是提取人群非常拥挤时,摔倒的人的 Hu 不变矩特征,将该特征输入 RBF 神经网络中,则和 RBF 网络输出相应的测试样本就是旅游密集区踩踏风险图像,从而实现旅游密集区踩踏风险图像



图 2 RBF 网络识别过程

监控.

3 仿真实验分析

为了验证本文提出的基于物联网的旅游人群密集区踩踏风险图像监控方法的有效性,需要进行相关的实验分析.实验在 VC 与 OPENCV 库下进行.实验环境为 XP 系统平台,计算机的配置如下:AMD AthlonTM 64 X2Dual Core Processor 3800 + , 2. 00 GHz,1.00 GB 内存.实验将信息熵方法作为对比进行分析,从识别精度和效率两个方面验证本文方法的有效性.

3.1 识别精度分析

任意选择一段旅游人群密集区监控视频图像,分别采用本文方法和信息熵方法对旅游人群密集区踩踏风险图像进行识别,得到的结果如图 3 所示.

分析图 3 可以看出,和信息熵方法相比,本文方法能够有效识别出旅游密集区的踩踏图像,这是因为本文方法依据 Hu 不变矩特征信息,不仅能够有效描述旅游人群密集区踩踏风险图像位置、大小等特征,而且具有缩放、旋转和平移不变性等特点,使得识别结果更加准确.

为了进一步验证本文方法的有效性,任意选择 10 段视频,分别采用本文方法和信息熵方法对其进行监控,对两种方法的查准率与查全率进行了对比,用表 1 进行描述.

表 1 两种方法识别结果比较

	查准率		查全率	
	本文方法	信息熵方法	本文方法	信息熵方法
视频 1	0.983	0.815	0.911	0.652
视频 2	0.991	0.783	0.906	0.624
视频 3	0.966	0.725	0.915	0.635
视频 4	0.937	0.834	0.909	0.659
视频 5	0.957	0.801	0.918	0.683
视频 6	0.948	0.822	0.924	0.671
视频 7	0.982	0.755	0.932	0.653
视频 8	0.975	0.767	0.919	0.639



(a) 本文方法识别结果



(b) 信息熵方法识别结果

图 3 本文方法和信息熵方法识别结果比较

视频 9	0.949	0.736	0.927	0.628
视频 10	0.953	0.811	0.935	0.664

分析表 1 可以看出,采用本文方法对旅游人群密集区踩踏风险图像进行监控,查准率与查全率较信息熵方法具有很大的提高,一直优于信息熵方法,说明本文方法具有很高的精度,验证了本文方法的有效性.

此外,还对本文方法和信息熵方法的误识别率进行比较分析,得到的结果用图 4 进行描述.




图 4 两种方法误识别率比较结果

分析图 4 可以看出,采用本文方法对视频中的旅游人群密集区踩踏风险图像进行识别,得到的误识别率明显低于信息熵方法,进一步验证了本文方法的准确性.

通过上述实验可知,本文方法能够有效提高旅游人群密集区踩踏风险图像的识别准确率,从而保证了人们的安全.

3.2 识别效率分析

在上述实验的基础上,对本文方法和信息熵方法识别每段视频所需的时间进行对比分析,得到的结果如表 2 所示.

表 2 两种方法效率比较

	本文方法	信息熵方法
视频 1	3.21	6.41
视频 2	1.93	5.23
视频 3	2.45	7.16
视频 4	2.72	6.93
视频 5	3.44	5.78
视频 6	2.89	6.68
视频 7	2.26	7.36
视频 8	3.13	7.25
视频 9	3.52	6.98
视频 10	2.68	5.97

分析表 2 可以看出,针对同一段视频,本文方法所需的时间明显低于信息熵方法,说明采用本文方法对视频中的旅游人群密集区踩踏图像进行识别的效率更高,这是因为本文方法通过物联网平台实现了旅游人群密集区踩踏风险图像的监控,大大减少了计算量,提高了监控效率.

通过上述分析可以看出,本文方法不仅具有很高的识别精度,而且具有很高的识别效率,验证了本文方法的有效性.

4 结束语

本文提出一种基于物联网的旅游人群密集区踩踏风险图像监控方法,分析了物联网监控平台,提取旅游人群密集区踩踏风险图像的 Hu 不变矩特征,

将其输入 RBF 神经网络中进行学习和分类,获取各种类型的旅游人群密集区踩踏行为,将测试样本输入建立的 RBF 神经网络模型中进行测试,与 RBF 网络输出相应的测试样本即为旅游密集区踩踏风险图像,从而实现旅游密集区踩踏风险图像监控. 仿真实验结果表明,采用所提方法对旅游人群密集区踩踏风险图像进行监控,识别准确率及效率均较传统方法有很大的改善.

参考文献:

[1] 米晓萍,李雪梅. 基于物联网智能的独居老人自动监控方法研究[J]. 计算机仿真, 2014, 31(2):378-381.

[2] 洪英汉,陈平华,刘竹松,等. 基于物联网人流图像匹配的密度估计方法[J]. 计算机仿真, 2013, 30(6):389-392.

[3] 胡文艺,王绪本,阚媛珂,等. 基于物联网的旅游安全监测信息服务站的设计与实现[J]. 测控技术, 2013, 32(6):136-139.

[4] 夏于,杜克明,孙忠富,等. 基于物联网的小麦气象灾害监控诊断系统应用研究[J]. 中国农学通报, 2013, 27(23):129-134.

[5] 王哲梁,李文钧. 基于 GPRS 和嵌入式 Linux 的远程图像监控系统[J]. 物联网技术, 2013, 3(12):65-67.

[6] 刘蔚. 计算机视觉下半监督学习的人员踩踏风险预警[J]. 科技通报, 2014, 30(4):128-130.

[7] 张立茂,刘梦洁,吴贤国,等. 基于 DEA 的地铁站拥挤踩踏风险分析[J]. 土木工程与管理学报, 2014, 26(4):76-82.

[8] 陈平. 面向公共安全图像监控的人群行为分析[J]. 电视技术, 2013, 37(17):136-138.

[9] 宁利君. 人员密集场所人群聚集风险监测与预警系统研究[J]. 安全, 2013, 33(11):59-60.

[10] 史云静,郑海波,韩小莹,等. HSV 下的基于图像内容的监控视频检索方法[J]. 电视技术, 2015, 39(4):16-20.

作者简介:

朱文忠 男,(1971-),硕士研究生,教授.研究方向为计算机技术.

蒋华龙 男,(1969-),副教授.研究方向为物联网技术.

周述文 男,(1973-),副教授.研究方向为电子商务.

E-mail:fangzz3@163.com