

DOI: 10.13382/j.jemi.B2003323

基于深度高斯过程回归的视频异常事件检测方法^{*}

王 栋¹ 张晓俊² 戴丽华¹

(1. 苏州工业职业技术学院 苏州 215000; 2. 苏州大学 光电科学与工程学院 苏州 215006)

摘要:针对现有异常检测方法忽视异常事件发生概率小而造成虚警这个问题,基于高斯过程回归(GPR)的框架,将GPR核函数非参数化所具有的灵活性与深度神经网络的结构特性相结合,并将卷积神经网络封装在GPR的核函数中,以同时实现异常检测任务中特征提取和检测两个步骤。在测试阶段,相对于训练样本集的后验概率的对数似然较小的被判定为异常。方法在一个模拟数据集和一个完全真实的数据集上进行了实验验证,实验结果证明所提出的方法在两个数据集上分别达到了83.9%的帧级AUC和34.4%的帧级AUC,在性能上达到了现有技术发展水平。

关键词:视频监控;异常事件;高斯过程回归;深度学习;卷积神经网络

中图分类号: TP 391.4 **文献标识码:** A **国家标准学科分类代码:** 520.20

Video anomaly detection and localization via deep Gaussian process regression

Wang Dong¹ Zhang Xiaojun² Dai Lihua¹

(1. Suzhou Vocational Institute of Industrial Technology, Suzhou 215000, China; 2. School of Optoelectronic Science and Engineering, Soochow University, Suzhou 215006, China)

Abstract: Aiming at the problem of false alarms caused by the low probability of abnormal events in existing anomaly detection methods, a novel video anomaly detection approach is proposed based on the Gaussian process regression framework. By integrating the structural properties of deep learning with the flexibility of kernel methods, a new deep learning technology called deep Gaussian process regression that fully encapsulates CNN structure is introduced to extract features and detect anomaly in one model. The results on the popular Avenue dataset and on a recently introduced real-event video surveillance dataset show that the detection model based on deep Gaussian process regression has achieved 83.9% frame-level AUC and 34.4% frame-level AUC on the two dataset, respectively, and has reached the state of the art in performance.

Keywords: video surveillance; anomalous event; Gaussian process regression; deep kernel learning; convolution network

0 引言

随着公共场所中监视摄像机的日益普及,监控视频数据步入了井喷时代,人们对自动检测视频中异常事件的需求愈发强烈。在现代智能视频监控系统中,异常检测起着至关重要的作用,特别是在安全领域,不仅大大提高了监控效率,而且减轻了传统视频监控系统中视频监控员的工作负担。视频异常检测(video anomaly detection, VAD)就是从海量监控视频数据中实时检测出

与大多数正常事件不一致的少量异常事件。然而,视频异常检测是一项艰巨的计算机视觉任务,主要出于两个特定原因,分别为异常事件十分稀少和异常事件定义的界限十分模糊。异常事件往往是和正常事件不一致且很少发生的,这使得它们在现实生活中很难被收集到,如汽车自燃很少见,并且很难收集或模拟这种异常。异常事件的定义往往取决于当时的环境,很难准确地区分正常事件和异常事件。在不同环境下,同一件事可以视为正常事件或异常事件,如一个人在银行追逐另一个人被认为是异常事件,而在操场上则是正常事件。

收稿日期: 2020-07-11 Received Date: 2020-07-11

^{*} 基金项目: 2019年度江苏省高等学校自然科学研究面上项目(19KJD510007)、2019年江苏高校青蓝工程优秀教学团队项目资助

为了解决以上两个问题,研究人员提出仅通过正常事件训练检测模型,这实际上是一种半监督学习问题。那么,与预训练模型不一致的事件样本被视为异常。此外,根据模型输入的类型,所有现有的半监督异常检测方法往往可以分为两类^[1]:1)手工特征方法,这些方法往往采用人工设计的特征来表示事件,如一些物体轨迹特征^[2]、时空梯度^[3-4]、光流直方图^[5-6]、动态混合纹理^[7-8]。这类方法在获得表示事件的特征之后,接下来的步骤是采用常见的机器学习模型如单类支持矢量机^[9]、高斯过程回归(Gaussian process regression, GPR)^[10]等建立异常检测模型。2)深度学习方法。由于手工特征很难适应各种异常事件,因此深度学习将原始视频帧作为模型的输入来代替手工特征。最常见的方法是采用深度重构^[11]的策略,通过深度自编码学习正常事件的视频帧,然后通过重构误差的大小判断测试事件是否异常。除此之外,生成对抗网络^[12-14]也被广泛应用于异常检测任务中,通过生成器和判别器的竞争,生成器不断学习生成的异常样本,判别器则学习如何区分正常样本和异常样本以实现异常检测。然而,这些方法仅考虑到异常事件和正常事件不一致这个特性,而忽视了异常事件发生概率小的特点,因此可能会把大量的未出现的正常样本误判为异常,导致了虚警。

与上述方法不同,本文提出了一种深度高斯过程回归框架(deep Gaussian process regression, DGPR)用于异常事件检测。具体而言,该方法基于GPR理论^[15],即采用所有样本训练高斯过程模型,测试样本在高斯过程模

型中出现的概率较小则被判定为异常。文献[10]曾采用这种思路,通过提取手工特征,并建立样本空间的高斯过程模型进行异常检测。与文献[10]不同,本文采用的方法不需要提取手工特征,基于深度核学习(deep kernel learning)理论^[16],将GRP核函数非参数化所具有的灵活性与深度神经网络的结构特性相结合,将深度卷积网络(CNN)作为GPR的核函数进行封装。这样,采用的方法可以看作是在CNN内部额外增加一个结构为GPR的神经网络层,也可以看作是具有CNN的高斯过程回归。通过这样的形式,能够代替手工特征提取的过程,事件表示和异常检测模型是联合优化的,泛化能力强。受双流神经网络^[17]的启发,通过对视频帧和光流图的局部区域块分别训练深度高斯过程回归模型,分别检测外观异常和运动异常,并将二者融合以确定最终的检测结果。在两个公开数据集上进行实验结果表明,本文提出的方法泛化能力强,检测效果达到现有技术发展水平。

1 算法原理

本文所提出的方法总流程如图1所示。在训练阶段,训练样本的RGB图像和光流图被密集采样,并分别学习两个DGPR模型的参数;在测试阶段,给定测试样本,通过已训练好的深度高斯过程模型,计算测试样本在深度高斯过程模型中的异常得分;最后在融合决策阶段,将外观和运动新奇得分进行融合,并设定相应的检测门限获得最后的检测结果。

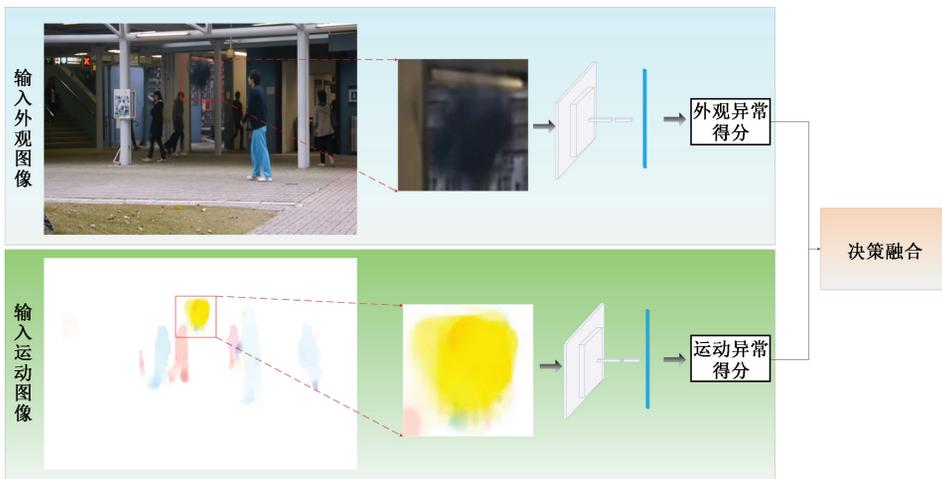


图1 基于深度高斯过程回归的视频异常事件检测方法流程

Fig. 1 The flow chart of video anomaly detection based on deep Gaussian process regression

1.1 高斯过程回归原理

高斯过程^[15]是一种随机过程,是有限个随机变量均是符合高斯分布的集合。具体来说,对于任意一组训练样本 $\mathbf{X} = [x_1, x_2, \dots, x_n]$ (RGB图像块或者动态流图图像

块),与之对应的过程状态 $\{f(x_1), f(x_2), \dots, f(x_n)\}$ 的联合分布服从高斯分布。它由均值函数 $m(\mathbf{X})$ 和协方差函数 $K(\mathbf{X}, \mathbf{X}')$ 唯一确定:

$$f(\mathbf{X}) \sim N(m(\mathbf{X}), K(\mathbf{X}, \mathbf{X}')) \quad (1)$$

其中,均值函数 $m(\mathbf{X})$ 可表示为 $m(\mathbf{X}) = E(f(\mathbf{X}))$, 而协方差函数矩阵中的元素 $K(\mathbf{X}, \mathbf{X}')_{ij} = k_r(x_i, x_j)$, $k_r(\cdot, \cdot)$ 为参数为 r 的核函数,用于衡量两组数据之间的关系。

GPR 则是使用高斯过程先验对数据进行回归分析。由于受到噪声的影响,输出值 \mathbf{Y} 是可以表示为:

$$\mathbf{Y} = f(\mathbf{X}) + \varepsilon \quad (2)$$

式中: ε 即 $\varepsilon \sim N(0, \sigma_n^2)$ 。因为噪声 ε 是独立于 $f(\mathbf{X})$ 的高斯白噪声,当 $f(\mathbf{X})$ 服从高斯分布时, \mathbf{Y} 同样服从高斯分布,则其有限观测值联合分布的集合可表述为高斯过程,即:

$$\mathbf{Y} \sim N(0, K(\mathbf{X}, \mathbf{X}') + \sigma_n^2 \mathbf{I} \delta_{ij}) \quad (3)$$

式中: \mathbf{I} 为 $n \times n$ 的单位矩阵; δ_{ij} 为 Kronecker delta 函数。

实际上,高斯过程回归根据从训练集中学习输入 \mathbf{X} 和输出 \mathbf{Y} 之间的非线性映射关系 $f(\mathbf{X})$, 从而根据新观测的输入 \mathbf{X}_* 预测其输出 \mathbf{Y}_* 。当有新的测试输入 \mathbf{X}_* , 其测试输出 \mathbf{Y}_* 同样服从高斯分布,根据贝叶斯后验概率公式,可以得到测试样本输出向量 \mathbf{Y}_* 的后验分布,即 GPR 预测模型,即:

$$\mathbf{Y}_* | \mathbf{X}, \mathbf{Y}, \mathbf{X}_* \sim N(\bar{\mathbf{Y}}_*, \text{cov}(\mathbf{Y}_*)) \quad (4)$$

式中: $\bar{\mathbf{Y}}_*$ 和 $\text{cov}(\mathbf{Y}_*)$ 分别为高斯过程回归预测值 \mathbf{Y}_* 的均值和协方差,且分别满足式(5)和(6)。

$$\bar{\mathbf{Y}}_* = K(\mathbf{X}_*, \mathbf{X}) (K(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I})^{-1} \mathbf{Y} \quad (5)$$

$$\text{cov}(\mathbf{Y}_*) = K(\mathbf{X}_*, \mathbf{X}) (K(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I})^{-1} K(\mathbf{X}, \mathbf{X}_*) + K(\mathbf{X}_*, \mathbf{X}_*) \quad (6)$$

综上,在已知训练集的输入输出以及测试样本的输入时,便可通过式(4)来获得测试样本的输出 $\bar{\mathbf{Y}}_*$ 的均值和方差,它们分别表示了估计结果和不确定性。

1.2 深度卷积核学习

核函数在 GPR 中起重要作用,因为它能够根据先验假设挖掘数据中的丰富结构(如平滑性、周期性和非静态性)。具体来说,GPR 可以通过核函数对数据集进行先验表达,且将非线性关系映射到特征空间并转换为线性关系,从而使复杂的非线性问题转换为线性问题。理论上只要选择合适的核函数就能逼近任何非线性模型。本文为了代替传统的手工特征提取过程以对事件进行表示,采用将多层 CNN 封装到高斯回归模型核函数中,使得获得的深度高斯过程模型同时具有事件表示和异常检测的能力。其中,作为深度学习中最为成功的技术, CNN^[18-21] 已经在图像分类、物体识别和行为识别等领域取得了极大的成功。具体来说,深度高斯过程模型可以看作是基核的一个扩展,可表示为:

$$k(x_i, x_j | \theta) \rightarrow k'(g(x_i, W), g(x_j, W) | \theta, W) \quad (7)$$

式中: $g(X, W)$ 是输入样本 \mathbf{X} 经过 GRU-RNN 后所获得的非线性输出; θ 和 W 分别为基核和 CNN 的参数集合。

如果基核采用高斯基核,那么提出的深度高斯过程核函数可以表示为:

$$k(x_i, x_j) = \alpha \exp\left(-\frac{1}{2\beta} \|g(x_i, W) - g(x_j, W)\|^2\right) \quad (8)$$

其中, $\theta = [\alpha, \beta]$ 为高斯基核的参数。

因此,整个模型包含 CNN 的网络权重 W 和高斯基核参数 θ , 需要采用负对数边缘似然对其进行联合优化^[16,22]。

1.3 检测异常事件

对于给定的测试样本 y (RGB 图像块或者动态流程图图像块),如果其为正常样本,其相对于高斯过程会出现较大的概率。其异常得分可以通过其相对于训练样本集的后验概率的对数似然计算获得,即:

$$S(y) = -\log(p(y | \mathbf{X}, \mathbf{Y}, \mathbf{X}_*)) \quad (9)$$

正常样本 $S(y)$ 得分较大,异常样本则较小。假设外观和运动新奇得分分别是 $S_{\text{appearance}}$ 和 S_{motion} 。则总新奇得分可以看成外观新奇得分和运动新奇得分的和:

$$S_{\text{overall}} = \alpha S_{\text{appearance}} + \beta S_{\text{motion}} \quad (10)$$

本文设定外观异常和运动异常权重相同,即 $\alpha = \beta = 0.5$ 。最后,设定阈值 ζ 判断是否为异常。

$$S_{\text{overall}} > \zeta \quad (11)$$

2 实验

本文在和 Avenue 数据集^[3]和 LV 数据集^[23]两个数据集上进行了实验验证,并将实验结果与现有方法进行对比。

2.1 实验数据及评价指标

Avenue 数据集通过固定摄像机记录学校走廊前的场景,镜头角度略微倾斜,它包含 15 个正常和 21 个异常大小为 360×240 的视频片段,该数据集总共有 30 652 帧。正常事件包含与摄像机平行行走的行人,而异常事件包含人们跑步,投掷物体和游荡。

LV 数据集是一个真实的视频数据集,它包含 16 个正常和 14 个异常视频片段,每个视频片段大小不一(从 $176 \times 144 \sim 1280 \times 720$)而且。正常事件包含正常行走的行人,异常事件包括打架、人群冲突、持械抢劫等。两个数据集的部分事件示例如图 2 所示。

帧级评价指标被用于评估检测方法的性能。对于帧级评价指标来说,如果测试样本中的某帧中包含至少一个异常像素,则判定该帧为异常帧。为了进行定量分析,帧级 AUC 被计算以进行对比分析。具体来说,先计算方法的检测率(true positive rate, TPR)和虚警率(false positive rate, FPR),然后通过改变式(11)中的阈值 ζ 画 ROC 曲线,并计算曲线下面积 AUC。



(a) Avenue数据集
(a) The Avenue dataset



(b) LV数据集
(b) The LV dataset

图 2 异常事件检测数据集的部分事件示例

Fig. 2 Examples of video frames for the UCSD dataset and the Avenue dataset.

2.2 实验设置

对于两个数据集,每帧都被调整为大小 320×240 , 为了获得运动图像,采用文献中提供的光流法^[24]计算光流图。针对 RGB 图像和光流图,接下来分别建立了两个独立的 DGPR 模型,以检测外观和运动异常。在训练阶段,所有的图像(包括 RGB 图像和动态流图)都通过大小为 20×20 步长为 10 的滑动窗进行采样,对于每个模型获得约 10 000 个图像块作为最终的训练集。在测试阶段,测试样本通过相同大小的滑动窗获得,输入到 DGPR 模型中计算异常得分,这意味着每帧图像最终输出大小为 16×12 得分图,并通过融合后判断最终异常区域。CNN 的结构采用常见的 $C32 \times (3 \times 3) - P(2 \times 2) - C64 \times (3 \times 3) - P(2 \times 2) - D128 - D32$ 的结构,即首先为 32 个大小 3×3 卷积核的卷积层,接下来采用大小 2×2 的融合层,然后采用 64 个大小 3×3 卷积核的卷积层和大小 2×2 的融合层,最后采用两个大小 128 和大小 32 的全连接层,并将输入传递给 GPR 层,具体结构如图 1 所示。GPR 层计算是基于 MATLAB 中的 GPML 工具箱实现^[25],而 CNN 的参数优化选取的是 Adam 优化器,初始学习率为 0.001,并且在

每 1 000 次迭代后减少到 1/10,停止在 10 000 次迭代。动量(momentum)参数为 $\rho_1 = 0.9, \rho_2 = 0.999$,批尺寸为 100。实验硬件平台为 NVIDIA GTX1050TI,显存 4 GB,软件环境为 Tensorflow1.13,Python3.6 和 MATLAB2017。

2.3 实验结果

图 3(a) 和表 1 所示分别给出了 UCSD Ped1 帧级 ROC 曲线和帧级 AUC 结果。Avenue 是一个新公开的数据集,因此只有最近提出的几种方法在该数据集上进行了测试,3 种方法被用于对比,分别为 Detection at 150 FPS^[3], Learning Temporal Regularity^[11], GPR^[10],前两种方法的结果都从相关文献获得,后一种方法在本文复现。其中,150 FPS 方法提取时空梯度特征后采用稀疏重构法进行异常检测,而 Learning Temporal Regularity 方法采用深度自编码进行重构以检测异常,GPR 法则通过提取手工特征并建立样本空间的高斯过程模型进行异常检测。

由图 3(a)可以看出,相比于其他两种对比方法,本文方法在 Avenue 数据集上取得了最优的结果。表 1 给出了 Avenue 数据集上不同算法在帧级检测的比较结果,

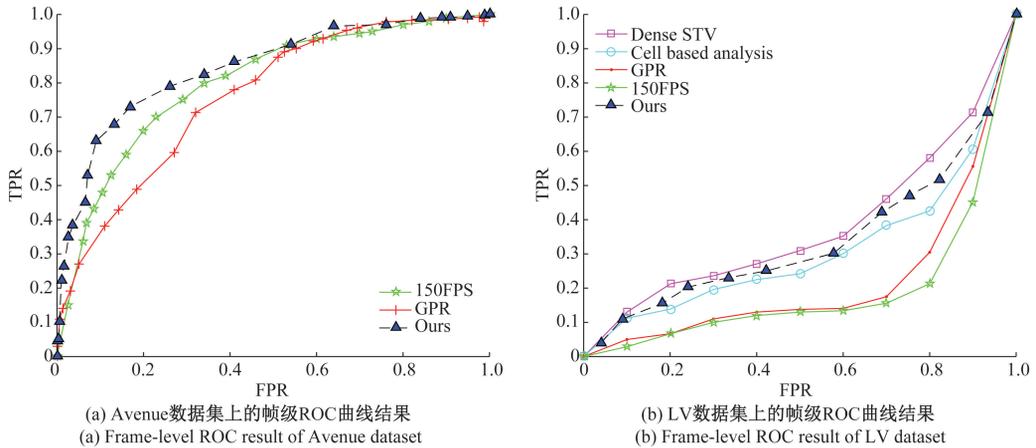


图 3 两个数据集上的 ROC 曲线结果

Fig. 3 ROC curves for the two datasets

本文提出的方法取得了 83.9% 的帧级 AUC, 优于其他所有对比方法。相比于文献[10]提出的 GPR 方法, 本文提出的 DGPR 方法在帧级 AUC 上取得了 5.6% 的提升, 证明了将卷积神经网络封装到核函数后对于异常检测的优势。此外, 本文提出的方法不需要进行手工特征提取步骤, 节省了大量手工特征设计的人力消耗。

表 2 Avenue 数据集帧级检测结果

Table 2 Comparison with the state of the art methods in terms of AUC% for the Avenue dataset

方法	AUC/%
文献[7]	80.9
文献[10]	78.3
文献[20]	70.2
本文	83.9

接下来在 LV 数据集上进行了实验验证, 相比于 Avenue 数据集, LV 数据集更具有挑战性。考虑到 LV 数据集上每个视频片段处于不同的场景, 而在一个场景上学习的 DGPR 模型是无法在另一个场景上使用的, 对于本数据集的每个视频片段, 选用前 10% 视频帧进行训练, 而之后的 90% 视频帧进行测试, 实验结果如图 3(b) 和表 3 所示。对比方法包括 Dense STV^[5], Cell based analysis^[8], GPR^[10] 和 150 FPS^[3], 其中除了 GPR 方法由本文参照文献[10]实现外, 其余方法的结果来自文献[23]。显然, 所有的方法在该数据集上取得的结果都逊于在 Avenue 数据集上取得的实验结果。具体来说, 本文提出的方法实现了 34.4% 的 ROI 级 AUC, 性能差于 Dense STV 方法, 这可能是因为本方法只采用了前 10% 视频帧进行训练, 训练样本量相对较少未能学习到场景变化规律, 而 Dense STV 方法采用了在线更新过程不断优化模型, 对场景变化的适应力更强。一种可能的改进

方案是利用新观察到的正常事件来不断优化 HGPR 检测模型。此外, 相比于 GPR 方法, 本文提出的 DGPR 方法同样取得了较大提升, 证明了方法的泛化能力强。

表 3 LV 数据集帧级检测结果

Table 3 Comparison with the state of the art methods in terms of AUC% for the LV dataset

方法	AUC/%
文献[2]	42.7
文献[3]	32.5
文献[4]	17.1
文献[5]	11.2
本文	34.4

两个数据集上的部分正确检测结果如图 4 所示, 其中图 4(a) ~ (d) 为 Avenue 数据集检测结果, 图 4(e) ~ (h) 为 LV 数据集检测结果。由图 4 可以观测到, 本文提出方法能够检测出不同类型的异常事件, 走向镜头(图 4(b)和(c)), 徘徊(图 4(a)、(g)), 扔纸(图 4(d)), 绑架(图 4(f)), 恐慌(图 4(h))以及错误行驶(图 4(i))。

3 结论

本文基于采用高斯过程异常检测的思路, 提出了一种深度高斯过程回归的方法用于解决异常检测问题。方法将 CNN 和高斯过程相结合, 把 CNN 封装到高斯过程的核函数中, 以达到仅采用一个模型就同时实现事件表示和异常检测的目的。提出的方法在一个模拟数据集和一个真实数据集上进行实验结果表明, 本文提出的方法泛化能力强, 检测效果达到现有技术发展水平。下一步研究将考虑对模型进行在线更新, 提高检测模型随场景变化的适应能力。

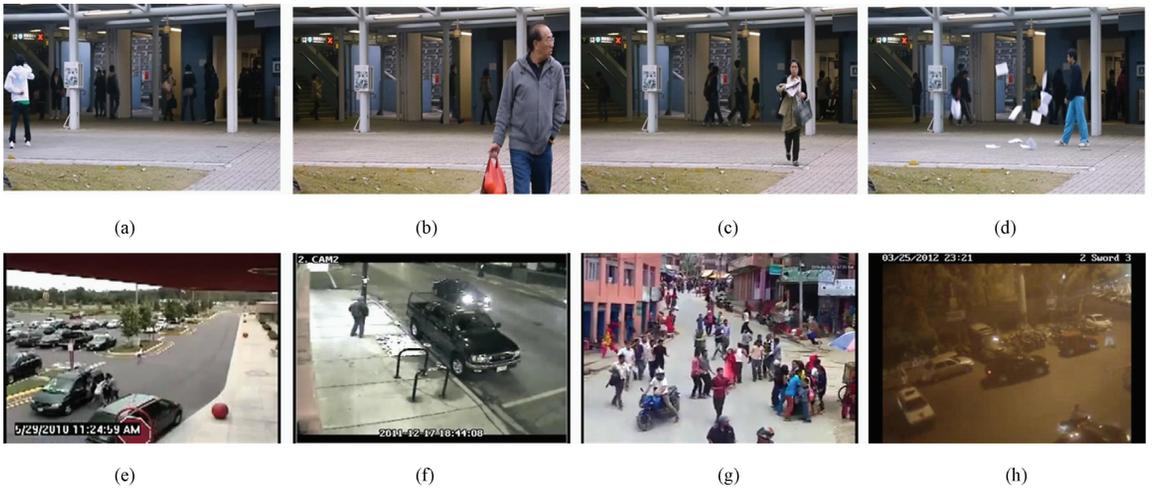


图4 部分检测结果示例

Fig. 4 Examples of the detection results

参考文献

- [1] POPOOLA O, ANG K. Video-based abnormal human behavior recognition-a review[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews, 2012, 42(6): 865-878.
- [2] BERA A, KIM S, MANCOCH D. Real-time anomaly detection using trajectory-level crowd behavior Learning[C]. IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2016, 1289-1296.
- [3] LU C, SHI J, JIA J. Abnormal event detection at 150 FPS in MATLAB [C]. Proceedings of IEEE International Conference on Computer Vision (ICCV), 2013, 2720-2727.
- [4] ROSHTKHATI M J, LEVINE M D. Online dominant and anomalous behavior detection in videos[C]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 2013, 2611-2618.
- [5] CONG Y, YUAN J, LIU J. Abnormal event detection in crowded scenes using sparse representation [J]. Pattern Recognition, 2013, 46(7): 1851-1864.
- [6] YUAN Y, FANG J, WANG Q. Online anomaly detection in crowd scenes via structure analysis [J]. IEEE Transactions on Cybernetics, 2015, 45(3): 562-575.
- [7] LI W, MAHADEVAN V, VASCONCELOS N. Anomaly detection and localization in crowded scenes [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(1): 18-32.
- [8] REDDY V, SANDERSON C, LOVELL B. Improved anomaly detection in crowded scenes via cell-based analysis of foreground speed, size and texture[C]. IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2011: 55-61.
- [9] XU D, YAN Y, RICCI E, et al. Detecting anomalous events in videos by learning deep representations of appearance and motion[J]. Computer Vision and Image Understanding, 2017, 156: 117-127.
- [10] CHENG K, CHEN Y, FANG W. Gaussian process regression-Based video anomaly detection and localization with hierarchical feature representation [J]. IEEE Transactions on Image Processing, 24 (12): 5288-5301, 2015.
- [11] HASAN M, CHOI J, NEUMANN J, et al. Learning temporal regularity in video sequences[C]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, 2016, 770-778.
- [12] RAVANBAKHSH M, SANGINETO E, NABI M, et al. Abnormal event detection in videos using generative adversarial nets [C]. Proceedings of the IEEE International Conference on Image Processing (ICIP) 2017, 1-5.
- [13] RAVANBAKHSH M, SANGINETO E, NABI M, et al. Training adversarial discriminators for cross-channel abnormal event detection in crowds [C]. Winter Conference on Applications of Computer Vision, 2019: 1896-1904.
- [14] 戴俊, 王俊, 朱忠奎, 等. 基于生成对抗网络和自动编码器的机械系统异常检测[J]. 仪器仪表学报, 2019, 40(9): 16-26.
- DAI J, WANG J, ZHU ZH K, et al. Anomaly detection of mechanical systems based on generative adversarial network and auto encoder [J]. Chinese Journal of

- Scientific Instrument, 2019,40(9):16-26.
- [15] RASMUSSEN C E, WILLIAMS C K I. Gaussian processes for machine learning (GPML) toolbox [J]. Journal of Machine Learning Research, 2010 (11): 3011-3015.
- [16] WILSON A G, HU Z, SALAKUTDINOV R, et al. Deep kernel learning [C]. International Conference on Artificial Intelligence and Statistics, 2016:1-8.
- [17] SONG M. A mean field view of the landscape of two-layer neural networks [C]. Proceedings of the National Academy of Sciences, 2018, 115 (33): 7665-7671.
- [18] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016, 770-778.
- [19] SCHMIDHUBER J. Deep learning in neural networks: An overview [J]. Neural Networks, 2015, 61: 326-366.
- [20] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521: 436-444.
- [21] 余博, 田福庆, 梁伟阁. 基于深度卷积变分自编码网络的故障诊断方法[J]. 电子测量与仪器学报, 2018, 39(10): 27-35.
- YU B, TIAN F Q, LIANG W G. Fault diagnosis based on a deep convolution variational autoencoder network [J]. Journal of Electronic Measurement and Instrumentation, 2018, 39(10): 27-35.
- [22] AL-SHEDIVAT M, WILSON A G, SAATCHI Y, et al. Learning scalable deep kernels with recurrent structure[J]. Journal of Machine Learning Research, 2017, 18:1-37.
- [23] LEYVA R, SANCHEZ V, LI C T. The LV dataset: A realistic surveillance video dataset for abnormal event detection [C]. Proceeding of the 5th International Workshop Biometrics Forensics (IWBF), 2017: 1-6.
- [24] BAKER S, SCHARSTEIN D, LEWIS J, et al. A database and evaluation methodology for optical flow [J]. International Journal of Computer Vision, 92: 1-31.
- [25] RASMUSSEN C E, NICKISCH H. Gaussian processes for machine learning (GPML) toolbox [J]. Journal of Machine Learning Research, 2018(11): 3011-3015.

- [26] GIORNO A D, BAGNELL J A, HEBERT M. A discriminative framework for anomaly detection in large videos [C]. European Conference on Computer Vision, 2016, 1-8.

作者简介



王栋, 2004 年于杭州电子科技大学获得学士学位, 2010 年于苏州大学获得硕士学位, 现为苏州工业职业技术学院副教授, 主要研究方向为嵌入式人工智能、物联网应用技术。

E-mail: strong_wong@21cn.com

Wang Dong received his B. Sc. degree from Hangzhou Dianzi University in 2004, M. Sc. degree from Soochow University in 2010, respectively. Now he is an associate professor at Suzhou Vocational Institute of Industrial Technology. His main research interests include embedded system development, Wireless measurement, and Sensor development technology.



张晓俊, 2004 年于苏州大学获得学士学位, 2007 年于苏州大学获得硕士学位, 现为苏州大学高级实验师, 主要研究方向为电子信息科学与技术、多媒体信息处理。

E-mail: xiaojun_zh@163.com

Zhang Xiaojun received the B. Sc. degree and M. Sc. degree in Soochow University in 2004 and 2007, respectively. Now he is a senior experimentalist at Soochow University. His main research interests include electronic information science and technology, multimedia information processing.



戴丽华, 2008 年于南京师范大学获得学士学位, 2013 年于南京师范大学获得博士学位, 现为苏州工业职业技术学院讲师, 主要研究方向为嵌入式系统开发、无线测量与传感器技术开发。

E-mail: dailihua123@sina.com

Dai Lihua received her B. Sc. Degree from Nanjing Normal University in 2008, Ph. D. Degree from Nanjing Normal University in 2013. Now she is a lecturer at Suzhou Vocational Institute of Industrial Technology. Her main research interests include Embedded system development, wireless measurement, and Sensor development technology.