

doi: 10.3969/j.issn.0490-6756.2020.06.009

一种基于特征正则约束的异常检测方法

邓 描, 刘 强, 陈洪刚, 王正勇, 何小海

(四川大学电子信息学院, 成都 610065)

摘要: 异常检测是计算机视觉的一个经典问题。针对异常样本稀少在真实场景中异常很难被捕捉,且标签难以获取,提出一种仅用正常样本进行训练的端到端异常检测模型。首先,通过自动编码器对输入图像进行编码,得到它的低维特征;然后,用一个自回归概率密度估计器对低维特征的概率分布进行正则约束,解码器再将其恢复至原始输入大小;最后,使用一个分类器来判断生成图片的真假。编解码器之间使用了跳线连接,能够最大限度地提高该模型对正常样本的记忆能力。本文在 CIFAR-10 和 UCSD Ped2 数据集上进行了实验,测试结果显示,CIFAR-10 总共 10 个类别的平均曲线下面积(AUC)达到 73.5%,UCSD Ped2 的平均曲线下面积(AUC)达到 95.7%。结果证明,该模型能够明显提高异常检测的效果。

关键词: 异常检测; 自动编码器; 概率密度估计器; 自回归

中图分类号: TP391.41 **文献标识码:** A **文章编号:** 0490-6756(2020)06-1077-07

An anomaly detection method based on feature regular constraints

DENG Miao, LIU Qiang, CHEN Hong-Gang, WANG Zheng-Yong, HE Xiao-Hai

(College of Electronics and Information Engineering, Sichuan University, Chengdu 610065, China)

Abstract: Anomaly detection is a classic problem in computer vision. It is difficult to capture the anomalies in the real scene and is difficult to obtain the labels as well, an end-to-end anomaly detection model trained only with normal samples is proposed. First, the input image is encoded by an automatic encoder to obtain its low-dimensional features, and then an autoregressive probability density estimator is used to constrain the probability distribution of low dimensional features. The decoder restores it to the original input size. Finally, a classifier determines the authenticity of the generated picture. A jumper connection is used between the codecs to maximize the memory of the model for normal samples. In this paper, the experiments were conducted on the CIFAR-10 and UCSD Ped2 datasets. The results showed that the average area under the curve (AUC) of the 10 categories of CIFAR10 reached 73.5%, and the area under the average curve (AUC) of UCSDPed2 reached 95.7%. This model can effectively improve the effect of anomaly detection.

Keywords: Anomaly detection; Autoencoder; Probability density estimator; Autoregressive

收稿日期: 2019-11-26

基金项目: 国家自然科学基金面上项目(61871278); 四川省科技厅国际科技合作与交流研发项目(2018HH0143); 成都市产业集群协同创新项目(2016-XT00-00015-GX)

作者简介: 邓描(1996—), 女, 硕士研究生, 研究方向为异常行为识别. E-mail: 1367996253@qq.com

通讯作者: 何小海. E-mail: nic5602@scu.edu.cn

1 引言

随着人们安全意识增强,视频监控领域的异常检测引起了很多关注,逐渐成为一项重要且极具挑战性的任务^[1]. 因为不同场景下的某一行为异常的程度不同,即特定场景下的特定行为才能称为异常,尝试收集各种异常事件并用分类的方法解决问题几乎是不可行的,所以考虑获得更好的特征表示成为了解决问题的关键.

相较于传统的特征提取方法深度学习能够从大量的数据中自动提取出有用的特征,目前在异常检测领域取得了丰硕的成果。基于标记信息可以分为监督学习方法,如支持向量机(SVM)^[2]、主成分分析(PCANet)^[3]等;半监督学习方法,如自动编码器(Autoencoder)^[4-5]和生成对抗网络(GAN)^[6]等;无监督学习方法,如受限玻尔兹曼机(RBM),稀疏编码器(Sparse Coding)^[7-8]等。但由于异常标签很难获取,标注成本高,半监督学习和无监督学习在异常检测中的应用更为广泛。自动编码器作为一种常用的半监督学习方法其原理也比较简单:对于输入样本,首先通过编码器将其压缩为低维特征,然后通过解码器对每个样本点进行重建,还原到原来的维度,整个训练模型的目的就是减小重构误差。假设输入异常样本会产生更大的误差。传统的稀疏编码算法就使用这样的框架,并且将正常样本表示为几个基本分量的组合,通过无监督的方式学习有效的数据编码。Luo 等提出了时间相关稀疏编码方法^[9],它可以映射到 SRNN 中更方便地进行参数优化并提高了异常检测的速度。自编码器具有强大的重构能力,但正因为这种能力,即使是异常样本也能得到很好的重建,导致异常检测精度下降。

为解决上述问题,使正常样本和异常样本有更明显的界限,本文提出一种新的异常检测框架:首先,为自动编码器添加跳线连接结构,这种使用 U-Net 风格的编码解码网络能够实现对图像空间细节的多尺度捕捉,并能从模型所学习的分布中产生高质量的图像。然后,用分类器网络迫使自动编码器学习改进的分布模型并提取输入图像的特征,以便模型能重建出低维特征向量。最后,在自动编码器上配备一个密度估计器,用一个自回归过程对潜在向量的概率分布进行正则约束。通过联合优化整个网络,模型能在重建出质量更好的图片的同时,降低潜在特征向量表示异常的可能性。

2 基本原理

2.1 结构组成

本文采用无监督的方式对提出的卷积网络架构进行训练,输入数据集 D 被分成训练集 D_{trn} 和测试集 D_{tst} . D_{trn} 包含 m 个正常样本 $D_{\text{trn}} = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$, 其中, $y_i = 0$ 表示正常类。 D_{tst} 包括 n 个正常和异常样本 $D_{\text{tst}} = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, 其中, $y_i = 0$ 或 $y_i = 1$. 通常情况下 $m > n$.

基于上面定义的数据集,我们将在训练集 D_{trn} 上训练我们的模型,并在测试集 D_{tst} 上评估它的性能。训练目标不仅是在图像空间内捕获训练样本的分布,而且还包括潜在特征向量空间。通过最小化训练目标来捕获两个维度内的分布,使网络能够学习正常图像所特有的高维特征和低维特征。

整个网络结构如图 1 所示,分别包括编码器 EN,解码器 DE,分类器 C 和参数密度估计器 H,损失函数将在 2.2 节介绍。

自动编码器网络: 编码器 EN 通过将输入样本 x 下采样成低维特征 z 来捕获输入数据的分布,其过程可以表示为 $z = f(x)$, 其中, $x \in \mathbb{R}^{w \times h \times c}$; w 是输入图像的宽度; h 是输入图像的高度, c 是输入图像的通道数; $z \in \mathbb{R}^d$; d 是输出特征的通道数。解码器网络 DE 将低维特征 z 上采样回到输入图像维度并重建输出,表示为 $x' = g(z)$, 其中, x' 表示重建图像。在文献[10] 的推动下,自动编码器采用跳线连接方式,这是一种新型的特征融合方式:拼接,使得编码器网络中的每个下采样层被连接到通道数相同的上采样解码器层,形成更厚的特征层。使之能够直接地进行信息传递,保留了多尺度信息,因此能够产生更好的重建。

分类器网络: C 的任务是对由自动编码器生成的伪图像 x' 和真实图像 x 进行分类,它采用了与文献[11]中 DCGAN 的鉴别器类似的结构。网络 C 还用作特征提取器,提取输入图像 x 和重建图像 x' 的低维特征。

参数密度估计器网络: 想要提高模型区分正常和异常样本的能力,仅仅依靠自动编码器来缩小图像层面对正常样本的重建误差是不够的,因为它不能保证异常样本能产生很大的重构误差,所以提出在自动编码器上引入参数密度估计器 H,对低维特征向量 z 的概率密度进行正则化约束,正则化约束是指:找到能充分覆盖正常模式的最小潜在特征

向量空间,使异常值落在该子空间之外,以降低特征向量表示异常的可能性. 假设输入样本 x 和低维特征 z 之间存在这样的关系如下.

$$p(x) = \int p(x|z)p(z)dz \quad (1)$$

本文仅用正常样本进行训练, $p(x)$ 为正常样本的分布, $p(x|z)$ 是在给定潜在向量的先验分布 $p(z)$ 的情况下所观察到的条件概率密度, 即在已知特征向量为 z 的情况下输入样本 x 为正常的概率. 为使低维特征 z 尽量不重建出异常图片, 需要找到使 $p(x|z)$ 最大的特征向量 z , 故提出使用参数密度估计器学习特征向量的分布 $p(z)$. 本文不强制要求特征向量服从某一分布(如高斯分布), 而是通过一个自回归过程来学习它的真实分布. 自回归模型为涉及顺序预测的任务提供了通用表述, 即每个输出都取决于先前的观察结果, 本文采用这种技术来分解联合概率密度, 分布情况如下.

$$p(z) = \prod_{i=1}^d p(z_i | z_{<i}) \quad (2)$$

其中, 我们把 $p(z)$ 分解成 d 个条件概率密度的乘积, 并且每个 z_i 的条件概率密度是根据它之前出现的 $\{z_1, \dots, z_{i-1}\}$ 的概率密度计算得出的, 其中, $<$ 表示一种顺序结构. 在实验中, 每个条件概率密度 $p(z_i | z_{<i})$ 被建模为 $B=100$ 量化区间的多项式, 为

了使每个输出条件概率密度具有自回归特性, 我们需要使估计器 H 的每一层有正确连接模式, 自回归估计器通过堆叠多个掩膜全链接(Masked Fully Connections)组成, 其结构如图 1 中 Density estimator 部分所示, 它输出条件概率密度 $p(z_i | z_{<i})$ 的参数, 表示为 $o = H(h)$, 输入参数为 $h \in \mathbb{R}^{d \times ci}$ (假设输入层的通道数 $ci=1$), 输出为 $o \in \mathbb{R}^{d \times co}$ (其中 $co=B$ 是输出通道的数量). 位置 i , 通道数为 k 的输入 $h_{i,k}$ 和位置为 j 通道数为 l 的输出 $o_{j,l}$ 之间的连接参数 ω 定义为

$$\begin{cases} \omega_{i,k;j,l}, & \text{if } i < j \\ \omega_{i,k;j,l}, & \text{if type} = B, \text{ and if } i = j \\ 0, & \text{if type} = A, \text{ and } i = j \\ 0, & \text{if } i > j \end{cases} \quad (3)$$

其中, 类型 A 强制严格依赖于先前的元素(并且仅用作第一个估计层), 而类型 B 仅屏蔽后续元素. 假设每个条件概率密度被建模为多项式, 则最后一个自回归层的输出(在 $\mathbb{R}^{d \times B}$ 中)提供构成空间量化的 B 个通道的概率估计.

$$o = \bigcup_{i=1}^d (\omega^{(i)} * h) \quad (4)$$

式中, \sqcup 表示将 d 个多项式拼接起来, 得到分布参数, 进而推断出概率分布 $q(z)$.

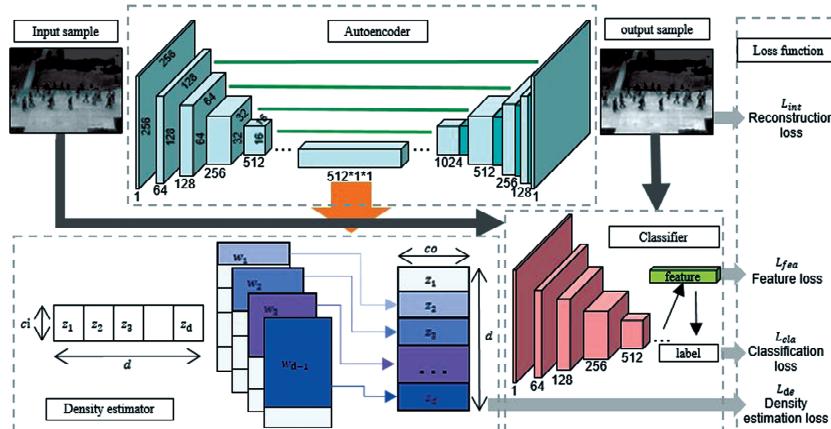


图 1 网络结构图
Fig. 1 Network structure diagram

2.2 损失定义

本文结合了 4 个损失值期望模型能够重建出更高质量的图片, 并且能在潜在向量空间学习到异常性, 从而区分正常样本和异常样本.

(1) 分类损失: 式(5)中所示的该损失确保网络 EN 和 DE 尽可能逼真地重建正常图像 x 至 x' , 而分类器网络 C 对样本进行分类得到 $C(x)$ 和 $C(x')$. 分类损失的期望表示为

$$L_{\text{cla}} = E_x[\ln C(x)] + E_{x'}[\ln(1 - C(x'))] \quad (5)$$

(2) 重建损失: 为明确地学习表现特征以充分捕获输入数据分布, 我们将 1-范数正则化应用于输入 x 和重构输出 x' . 这种正则化确保模型能生成与输入样本类似的图像. 重建损失的期望如下.

$$L_{\text{int}} = E_x|x - x'| \quad (6)$$

(3) 特征损失: 分类器 C 除了对样本进行分类还提取 x 和 x' 的特征得到 $f(x)$ 和 $f(x')$. 因此, 特

征向量的损失期望为

$$L_{\text{fea}} = \mathbb{E}_{x'} |f(x) - f(x')|_2 \quad (7)$$

(4) 密度估计损失: 估计器用一种自回归的方式获取真实分布 $p(z)$ 的参数模型, 得到近似分布 $q(z)$. 为了确保它和真实分布之间的信息差距很小, 从而降低特征向量表示异常的可能性, 用 L_{de} 来表示真实分布与拟合分布的 KL 散度, 定义为

$$L_{\text{de}} = D_{\text{KL}}(p(z) \| q(z)) \quad (8)$$

最终, 总损失定义为

$$L = \lambda_{\text{cla}} L_{\text{cla}} + \lambda_{\text{int}} L_{\text{int}} + \lambda_{\text{fea}} L_{\text{fea}} + \lambda_{\text{de}} L_{\text{de}} \quad (9)$$

其中, λ_{cla} 、 λ_{int} 、 λ_{fea} 和 λ_{de} 是权重参数.

2.3 异常分数定义

对于异常性的评估是通过计算异常分数, 假设正常样本的异常分数小, 异常样本的分数更高. 因此, 对于给定样本 x , 它的异常分数 $s(x)$ 定义为

$$s(x) = \alpha I(x) + \gamma V(x) \quad (10)$$

其中, $I(x)$ 和 $V(x)$ 分别表示给定样本和特征向量的重建分数; α 和 γ 是他们的权重. 最后将整个测试集中所有图像的异常分数归一化到 $[0, 1]$ 范围, 并使用以下等式计算每个测试样本的异常分数 $As(x)$ 为

$$As(x) = \frac{s(x) - \min s(x)}{\max s(x) - \min s(x)} \quad (11)$$

3 分析与讨论

为评估本文的异常检测模型, 我们使用两种类型的数据集. CIFAR-10: 该数据集共有 6×10^4 张彩色图像, 这些图像是 32×32 像素, 标签包含 10 个类别(飞机、汽车、鸟、猫、鹿、狗、青蛙、马、船、卡车)每类 6×10^3 张图. 本文选取其中一类视作异常, 其他为正常, 根据选取异常类别的不同总共有 10 种

情况(如图 4, 每一列代表一种异常类别), 每种情况都有 4.5×10^4 个正常训练样本, 9×10^3 个正常测试样本, 6×10^3 个异常测试样本. UCSD Ped2: 该数据集由加州大学圣地亚哥分校创建, 通过安装在一定高度、俯视人行道的摄像机来采集自然状态下发生的异常行为, 主要针对人群中个体行为的识别研究, 是一个被广泛认可及应用的视频异常检测数据集, 它的异常情况包括: 开车、骑自行车、滑冰等, 其中含有 16 个训练图像序列以及 12 个测试图像序列, 图像大小均为 360×240 像素.

实验平台为: Ubuntu 16.04.5, Nvidia GTX 1080 Ti GPU, Intel(R) Xeon(R) CPU E5-2686. 深度学习框架是 Pytorch0.3. CIFAR-10 的原尺寸 32×32 , UCSD Ped2 的尺寸批量修改为 256×256 . 通过 Adam 优化器优化训练目标, 初始学习速率 $lr = 2 \times 10^{-4}$, 具有权重衰减, 动量 $\beta_1 = 0.5$, $\beta_2 = 0.999$. 实验表明, 总损失的加权参数为 $\lambda_{\text{cla}} = 1$, $\lambda_{\text{int}} = 40$, $\lambda_{\text{fea}} = 1$, $\lambda_{\text{de}} = 1$ 时模型性能最佳. 在对 CIFAR-10 进行训练时, 最初设定训练 15 个 epoch, UCSD Ped2 训练 100 个 epoch. 但在大多数情况下, 它们在较少的训练周期内能够学习足够的信息. 因此, 当模型的性能开始下降时, 我们保存网络的参数, 防止其出现过拟合的情况.

模型性能由接受者操作特征曲线(Receiver Operating Characteristic Curve, ROC)和曲线下面积(Area Under Curve, AUC)评估, 该函数由真阳性率(True Positive Rate, TPR)和假阳性率(False Positive Rate, FPR)绘制. 表 1 可看出本文的算法在 CIFAR-10 数据集的 Cat, Deer, Dog, Frog, Plane, Ship 类别上的表现都高于其他算法.

表 1 CIFAR-10 数据集的 AUC 结果

Tab. 1 AUC results for CIFAR-10 dataset

Model	CIFAR-10										
	Bird	Car	Cat	Deer	Dog	Frog	Horse	Plane	Ship	Truck	Average
AnoGAN ^[12]	0.411	0.492	0.399	0.335	0.393	0.321	0.399	0.516	0.567	0.511	0.434
EGBAD ^[13]	0.383	0.514	0.448	0.374	0.481	0.353	0.526	0.577	0.413	0.555	0.462
VAE ^[14]	0.679	0.368	0.535	0.748	0.523	0.687	0.493	0.700	0.696	0.386	0.581
GANomaly ^[6]	0.510	0.631	0.587	0.593	0.628	0.683	0.605	0.633	0.616	0.617	0.610
Skip-GANomaly ^[15]	0.448	0.953	0.607	0.602	0.615	0.931	0.788	0.797	0.659	0.907	0.730
Ours	0.537	0.796	0.615	0.784	0.648	0.959	0.604	0.827	0.802	0.783	0.735

从表 2 可知, 本文提出的算法与当前的流行算法相比具有高的准确率.

图 2 是测试数据的正常和异常分数的柱状图, 其中, 蓝色区域代表样本为正常时分数的分布情

况, 黄色区域代表样本为异常时分数的分布. 通过对这些数据的仔细观察发现, 该模型在输出异常分数上产生了明显的分离.

表 2 UCSD Ped2 数据集的 AUC 结果

Tab. 2 AUC results for UCSD Ped2 dataset

UCSD Ped2	
ConvAE ^[16]	0.850
ConvLSTM-AE ^[17]	0.881
AbnormalGAN ^[18]	0.935
Hinami <i>et al.</i> ^[19]	0.922
Unmasking ^[20]	0.822
Stacked RNN ^[8]	0.922
AE ^[20]	0.917
MemAE-nonSpar ^[21]	0.929
MemAE ^[21]	0.941
ours	0.957

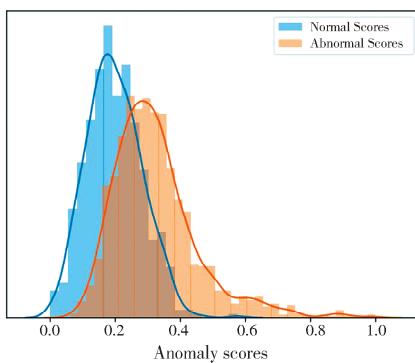


图 2 UCSD Ped2 数据集的异常分数直方图

Fig. 2 Abnormal score histogram for UCSD Ped2

图 3 是各个损失的 ROC 曲线图, 黄色曲线代表仅存在分类损失时的 ROC 曲线; 绿色曲线表示分类损失和重建损失一起存在时的 ROC 曲线; 蓝色曲线是分类损失, 重建损失和特征损失同时存在时的检测效果; 最后加上密度估计损失后的检测效果由红色曲线来体现。由图可知随着各个损失的添加, 检测效果有了明显的提升, 证明添加的每个损失都起到了相应的作用。

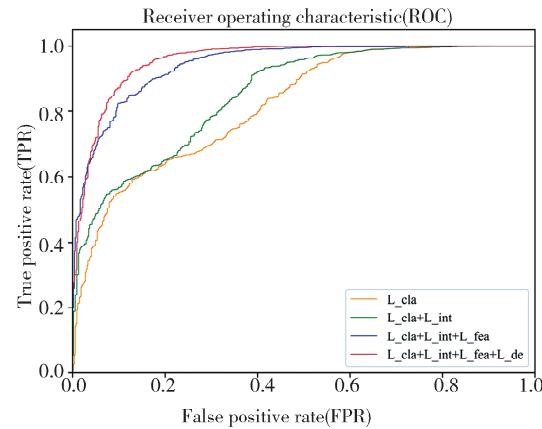


图 3 各个损失的 ROC 曲线图

Fig. 3 ROC of each loss

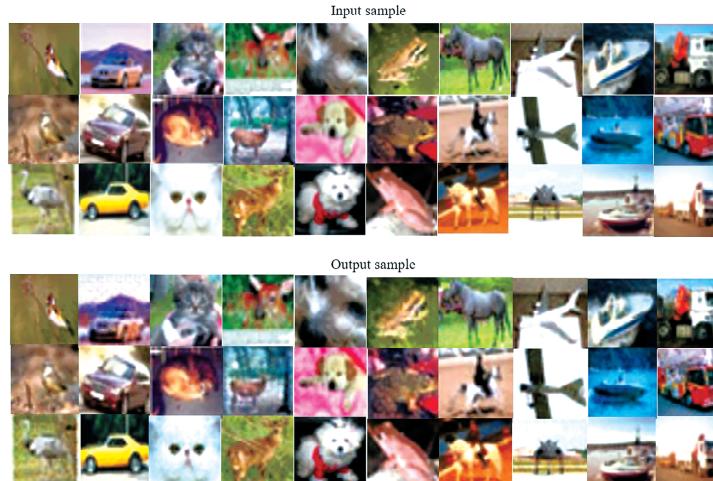


图 4 CIFAR-10 输入样本和输出样本, 每一列分别代表一种类别(鸟、汽车、猫、鹿、狗、青蛙、马、飞机、船、卡车)

Fig. 4 Input sample and output sample for CIFAR-10 dataset, each column represents a category (bird, car, cat, deer, dog, frog, horse, aircraft, ship, truck)

图 4 和图 5 分别是 CIFAR-10 的测试集和 UCSD Ped2 的测试集输入模型后生成的图像。从外观上来看, 生成图像和输入的图像具有很高的相似度, 从图 5 可以看到, 异常样本也能得到一定程度的重建, 这是使用自动编码器生成图片的普遍问题, 但是, 如 2.3 节所示, 异常分数能够在特征向量空间体现。

图 6 上面一排是 CIFAR-10 数据集的输入、文献[6]的重建输出以及本文的重建输出, 将红框圈

中的船这一类别作为异常类别, 其余类别的图像作为正常。可以看出除异常类别的图片外其他图片的重建效果都比文献[6]的效果好。下面一排是 UCSD Ped2 数据集的输入、文献[16]以及本文的重建输出, 红框圈中的地方是异常(自行车)出现的地方, 可以看出本文的总体重建效果要优于文献[16], 但异常部分(自行车)能够部分重建。这是由于自动编码器极强的重建能力。

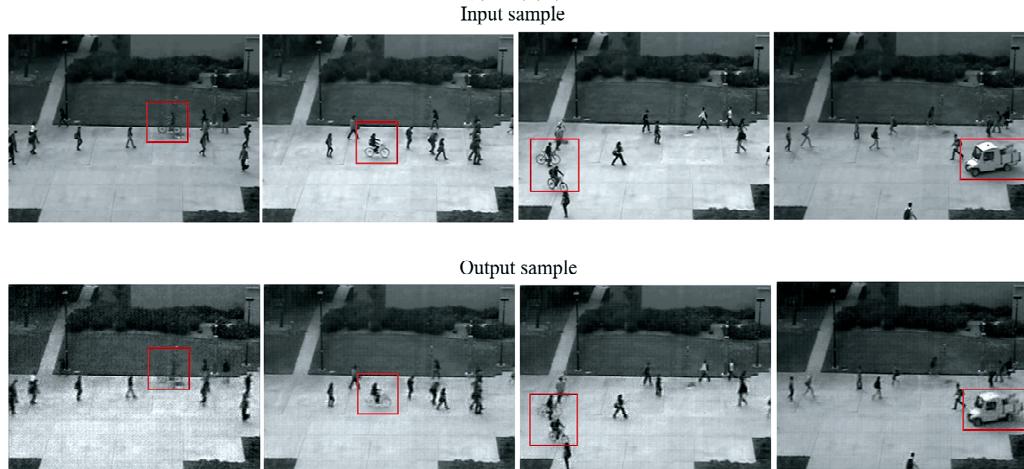


图 5 UCSD Ped2 输入样本和输出样本, 骑自行车表示异常

Fig. 5 Input sample and output sample for UCSD Ped2 dataset, cycling and car show abnormality

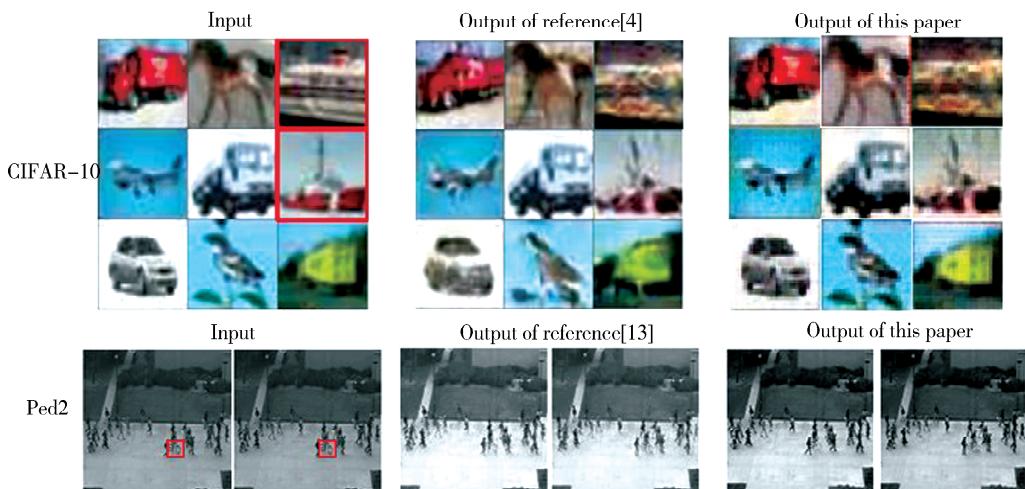


图 6 CIFAR-10 数据集(上排)输入样本、文献[6]的重建样本以及本文的重建样本,UCSD Ped2 数据集(下排)输入样本、文献[16]的重建样本以及本文的重建样本

Fig. 6 Input samples of cifar-10 data set (top row), reconstruction samples of reference[6] and reconstruction samples of this paper, input samples of UCSD ped2 data set (bottom row), reconstruction samples of reference [16] and reconstruction samples of this paper

4 结 论

本文提出了一新颖的异常检测框架,在传统自动编码器上结合跳线结构使模型能对样本细节进行捕捉,并引入了自回归密度估计器通过最大似然原理约束潜在特征向量的分布,一方面提高了模型的重建能力,另一方面使它能够在样本的潜在向量空间捕获到异常。CIFAR-10 和 UCSD Ped2 两个数据集上的 AUC 测试结果表明,该方法能够提升异常检测的效果,并在一定程度上优于现有方法,证明了本文的异常检测模型的有效性。

参考文献:

[1] 顾振飞, 袁小燕, 张登银, 等. 一种基于区域显著

性识别的红外图像增强方法[J]. 江苏大学学报: 自然科学版, 2019, 40: 681.

- [2] Ionescu R T, Khan F S, Georgescu M I, et al. Object-centric auto-encoders and dummy anomalies for abnormal event detection in video[C]//proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach, CA, USA: IEEE, 2019.
- [3] Fang Z, Fei F, Fang Y, et al. Abnormal event detection in crowded scenes based on deep learning [J]. Multimed Tools Appl, 2016, 75: 14617.
- [4] Hongchao S, Zhuqing J, Aidong M, et al. A hybrid semi-supervised anomaly detection model for high-dimensional data [J]. Comput Intell Neurosci, 2017, 2017: 1.

- [5] Abati D, Porrello A, Calderara S, *et al.* Latent space autoregression for novelty detection [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach, CA, USA: IEEE, 2019.
- [6] Akcay S, Atapour-Abarghouei A, Breckon T P. Ganomaly: semi-supervised anomaly detection via adversarial training [C]// Proceedings of the Asian Conference on Computer Vision. Cham: Springer, 2018.
- [7] Zhao B, Li F F, Xing E P. Online detection of unusual events in videos via dynamic sparse coding [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Providence, RI: IEEE, 2011.
- [8] Cong Y, Yuan J, Liu J. Sparse reconstruction cost for abnormal event detection [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Providence, RI: IEEE, 2011.
- [9] Luo W, Liu W, Gao S. A revisit of sparse coding based anomaly detection in stacked rnn framework [C]// Proceedings of the IEEE International Conference on Computer Vision (ICCV). Venice: IEEE, 2017.
- [10] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation [C]// Proceedings of the International Conference on Medical image computing and computer-assisted intervention. Cham: Springer, 2015.
- [11] Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks [DB/OL]. arXiv preprint arXiv: 1511.06434.
- [12] Schlegl T, Seeböck P, Waldstein S M, *et al.* Unsupervised anomaly detection with generative adversarial networks to guide marker discovery [C]// Proceedings of the International Conference on Information Processing in Medical Imaging. Cham: Springer, 2017.
- [13] Zenati H, Foo C S, Lecouat B, *et al.* Efficient GAN-Based anomaly detection [DB/OL]. arXiv preprint arXiv: 1802.06222, 2018.
- [14] Kingma D P, Welling M. Auto-encoding variational bayes [C]// Proceedings of the International Conference on Learning Representations (ICLR). Banff, AB, Canada: ICLR, 2014.
- [15] Akçay S, Atapour-Abarghouei A, Breckon T P. Skip-ganomaly: Skip connected and adversarially trained encoder-decoder anomaly detection [DB/OL]. arXiv preprint arXiv: 1901.08954, 2019.
- [16] Hasan M, Choi J, Neumann J, *et al.* Learning temporal regularity in video sequences [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV: IEEE, 2016.
- [17] Luo W, Liu W, Gao S. Remembering history with convolutional lstm for anomaly detection [C]// Proceedings of the International Conference on Multimedia and Expo (ICME). Hong Kong, China: IEEE, 2017.
- [18] Ravanbakhsh M, Nabi M, Sangineto E, *et al.* Abnormal event detection in videos using generative adversarial nets [C]// Proceedings of the IEEE International Conference on Image Processing (ICIP). Beijing, China: IEEE, 2017.
- [19] Hinami R, Mei T, Satoh S. Joint detection and recounting of abnormal events by learning deep generic knowledge [C]// Proceedings of the IEEE International Conference on Computer Vision. Venice: IEEE, 2017.
- [20] Tudor Ionescu R, Smeureanu S, Alexe B, *et al.* Unmasking the abnormal events in video [C]// Proceedings of the IEEE International Conference on Computer Vision (ICCV). Venice: IEEE, 2017.
- [21] Gong D, Liu L, Le V, *et al.* Memorizing normality to detect anomaly: memory-augmented deep autoencoder for unsupervised anomaly detection [DB/OL]. arXiv preprint arXiv: 1904.02639, 2019.

引用本文格式:

- 中 文: 邓描, 刘强, 陈洪刚, 等. 一种基于特征正则约束的异常检测方法 [J]. 四川大学学报: 自然科学版, 2020, 57: 1077.
- 英 文: Deng M, Liu Q, Chen H G, *et al.* An anomaly detection method based on feature regular constraints [J]. J Sichuan Univ: Nat Sci Ed, 2020, 57: 1077.