

DOI:10.19651/j.cnki.emt.2210701

基于神经批采样的轮胎 X 光图像异常检测研究 *

刘韵婷^{1,2} 李绅科¹ 郭 辉² 于清松¹

(1. 沈阳理工大学 沈阳 110000; 2. 沈阳工业大学体育装备产业技术研究院 沈阳 110870)

摘要: 轮胎缺陷检测对轮胎定级有重要参考意义,研究高性能的轮胎异常检测方法尤为重要。本文以强化学习算法为基础,提出一个以损失值异常变化作为判断异常特征的图像自动分类算法。该方法首先通过大量的正向样本输入来降低数据在经过梯度更新之后的损失值,从而与少量异常样本输入时的损失值形成明显差异,再引入神经批采样器,放大异常样本与正向样本之间的损失轮廓差异并为空间变分编码器提供训练批次,然后将训练结果作为异常分类器的输入,最后完成异常检测的分类与定位工作,经过对比研究发现本文提出的异常检测算法在轮胎缺陷样本集上性能明显优于其他传统图像异常检测方法。

关键词: 异常检测;轮胎 X 光图像;强化学习

中图分类号: TP2 文献标识码: A 国家标准学科分类代码: 510

Research on tire X-ray image anomaly detection based on neural batch sampling

Liu Yunting^{1,2} Li Shenke¹ Guo Hui² Yu Qingsong¹

(1. Shenyang Ligong University, Shenyang 110000, China;

2. Sports Equipment Industry Technology Research Institute, Shenyang University of Technology, Shenyang 110870, China)

Abstract: Tire defect detection has important reference significance for tire grading, and it is particularly important to study the high performance tire anomaly detection method. Based on reinforcement learning algorithm, an automatic image classification algorithm based on abnormal loss value is proposed. This method firstly by a large number of positive samples input to reduce the loss value of data after gradient update, with a small amount of the loss of the abnormal sample input values form the obvious difference, introducing neural sampler, enlarge abnormal loss of contour difference between samples and the positive samples and provide training to sVAE batch, then put the training result as input of abnormal classifier. Finally, the classification and location of anomaly detection are completed. Through comparative study, it is found that the anomaly detection algorithm proposed in this paper is obviously superior to other traditional image anomaly detection methods in tire defect sample sets.

Keywords: anomaly detection; tire X-ray image; reinforcement learning

0 引言

异常检测是人工智能领域的重要分支,大量图像的产出为图像识别领域的发展提供了温床。近年来,图像异常检测也在多领域遍地生花^[1-4],给人们的生产生活带来了诸多便利,但是囿于实际生产中异常样本不足,导致样本集内样本不平衡,从而限制了检测精度的提升。传统的图像异常检测研究^[5-10]主要是在图像空间层面,主流思想是通过使用正向样本训练 Auto-encoder,使得重构的图像趋近于正向样本,即使输入的图像是异常样本,重构出来的图像也

会像正向样本,通过对比原图与重构出来的图像差异来完成分类定位工作。但是由于 Auto-encoder 所具备的泛化能力会导致测试阶段中输入的异常样本重构出来的图像趋近于异常样本本身,这就导致在实际测试中输出结果对比差异性不明显,从而无法进行有效判断,且轮胎气泡类缺陷检测难度大,其存在于轮胎内部某一小区域,肉眼几乎检测不到,其 X 光图与胎线背景融为一体,极难区分,故而很多网络对其检测的准确率不是很高。为了解决以上传统异常图像检测中的问题,本文提出了一种在特征空间层面完成异常检测的方法,从而达成在自制轮胎缺陷数据样本集中

收稿日期:2022-07-17

* 基金项目:辽宁省教育厅项目(LJGD2020019)资助

进行气泡类缺陷检测的目的。在实验中发现,每次梯度更新后,正向样本与异常样本的损失值差异对比度明显增强,该结果表明损失剖面可以作为评定图像是否异常的指标。

基于以上论证,本文使用 1 340 张轮胎 X 光图像数据训练后的自动编码器输出的损失轮廓波动信息作为输入,并且定期初始化自动编码器,为分类器提供多样化的输入信息,防止过拟合情况出现。本文的主要贡献有:1)在异常图像检测中成功应用神经批采样器,为自编码器提供训练批次。将图像信息区域化,增强正负样本之间损失值的差异性,从而使得损失值差异成为样本分类定位的有效判断指标;2)引入空间变分编码器(spatial variational auto-encoder, sVAE)结构,达成了生成 loss 损失图像、提高训练速度的目的;3)引入预测器,以自动编码器的重构损失配置文件作为输入。

1 神经批采样器异常检测研究

1.1 算法概述

现有的方法^[11-14]都是试图直接从给出的训练数据中学

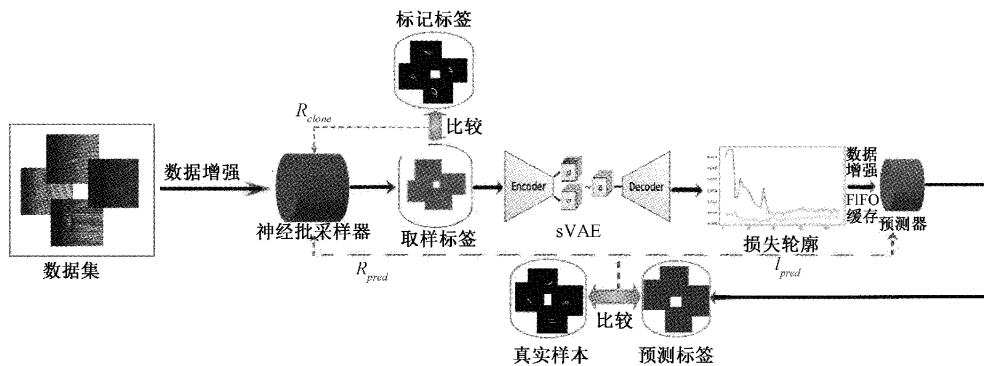


图 1 Nbsad-Net 网络结构

不平衡的数据集上训练自动编码器,当计算自编码器的重建损失并更新其权重时,发现大部分的损失是由非异常区域造成的。因此,自编码器主要优化了非异常区域的重建,导致异常区域的损失剖面高度波动,而非异常区域的损失剖面更加收敛。基于这一观察结果,本文训练了一个基于 CNN 的预测器来根据产生的损失轮廓剖面对异常波动的损失数据进行分类。为了放大异常区域和非异常区域的损失轮廓之间的差异,并使预测器的分类更容易进行,采用强化学习^[21-22]对神经批采样器进行训练,向自编码器提供训练批次。

1.2 神经批采样器异常检测算法的实现

1) 神经批采样器设计

基于强化学习的神经批采样器为自编码器产生训练批次,将图片信息区域化,使异常区域和非异常区域的损失轮廓之间的差异最大化。通俗的讲,神经批采样器会感知到正向样本随着梯度更新损失值会逐渐减小,而较大的损失值可能对应于异常,产生具有鉴别的损失轮廓。故

习特征,文献[15]使用来自 ImageNet^[16]预训练的 ResNet^[17]特征,该方法仅限于每幅图像的预测,而不是空间异常图。文献[18]使用 GMMs 或变分模型从非异常图像中手工制作的特征,但它们的性能低于标准水平。综合考虑,本文采用了一个半监督^[19]的设置,它只使用少量的标记异常数据来训练一个分类器,可实现将有监督方法中精度的优势和无监督^[20]方法中对大量数据需求大幅减少的优势结合起来。

本文介绍了一种半监督异常检测和分割算法,数据集 D 被分为两组: D_l : 标记好的图像数据集; D_u : 未标记的图像数据集。本文的目标是利用整个数据集($D_l \cup D_u$)来预测 D_u 中图像的相应标签。本文提出的神经批采样异常检测网络(neural batch sampling anomaly detection network, Nbsad-Net)模型如图 1 所示。

图 1 中黑色实线表示正向传递的管道,红色虚线表示用来训练预测器和神经批采样器的损失和奖励项的流动。如图所示本文的网络框架主要包含 3 个模块:一个神经批采样器、一个 sVAE 自编码器和一个异常预测器。在高度

将 RGB 信息 x_i 、一个图像的当前像素级重建损失 l_i 、另外单独提供了二进制采样历史记录 h_i ,这 3 个信息源(x_i, l_i, h_i)连接起来表示状态,然后输入 5 个卷积层和 2 个全连接层,产生一个表示策略动作概率的输出张量。策略的动作空间包含 9 个动作,它对应于 8 个不同的方向,自主选择移动采样中心位置。

2) sVAE 编码器模型设计

本文对自编码器结构进行改进,采用 sVAE 编码器结构,加快自编码器训练速度,抑制其自身泛化能力强带来的生成样本不准确问题,具体介绍如下:

本文利用传统自编码器的自适应性建立一个从神经批采样器输入的采样补丁 $x \in R^{H \times W}$ 到低维表示 $z \in R^d$ 的参数映射,并使用编码器 $Enc(\cdot, \theta)$ 和解码器 $Dec(\cdot, \phi)$ 返回高质量图像重建: $\hat{x} \in R^{H \times W}$

$$z \sim Enc(x, \theta) \quad (1)$$

$$\hat{x} = Dec(z, \phi) \quad (2)$$

由式(1)、(2)可得式(3):

$$z \sim N(0, I)$$

潜在空间 z 被限制遵循一个多元正态分布(MVN) N

输入层 隐藏层1 隐藏层2 输出层 输入层 隐藏层1 隐藏层2 输出层 输入层 隐藏层1 隐藏层2 输出层

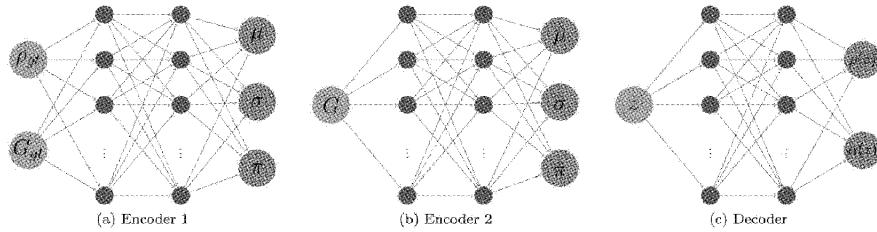


图 2 sVAE 拓扑结构图

图 2(a)用于将 X 光图像真值 ρ_{gt} 和 G_{gt} 转换为描述高斯混合模型中 z 分布的参数 μ 、 σ 和 α 的编码器。该编码器产生给定 ρ_{gt} 和 G_{gt} 的 z 的概率, 即 $Q(z | \rho_{gt}, G_{gt})$ 。中间图: 类似于左图, 但对于输入是随机数据 G 。该编码器产生给定 G 的 z 的概率, 即 $P(z | G)$ 。右图用于将潜在码 z 转换为输出光谱函数 $\rho(z)$ 和 $\alpha(z)$ 的解码器。在所有这 3 个图中, 每个图的最左侧的点代表输入, 而最右侧的点表示来自编码器的输出。

sVAE 仅用于产生预测器的损失轮廓, 改进后的 sVAE 在编码器和解码器之间添加了快捷方式连接, 以加快训练速度。但随着 sVAE 训练和收敛, 更新后的权值变得更小, 导致损失轮廓的多样性减少。为了解决这个问题, 本文采用定期初始化和重新训练 sVAE, 这对于产生用于训练预测器的不同损失轮廓至关重要。因为每次重新训练 sVAE 时, 它都从不同的权值开始, 并对不同的局部最小值进行优化。为了存储用于训练预测器的损失配置文件, 本文将它们添加到一个固定大小的 FIFO 缓冲区中, 缓冲区按照输入数据的顺序输出数据。

3) 预测器设计

本文设计的预测器是一个在“损失空间”而不是在图像空间上进行图像分割的分类器, 实现了一个全卷积网络的扩张。以规格 $W \times H \times T$ 为输入损失历史剖面, 其中 W 和 H 对应图像的宽度和高度, 输出规格 $W \times H \times 1$ 的二值信息。为了降噪, 需要对抽样损失历史执行规范化处理后, 取其平均值, 这使得预测器能够关注单个像素上的损失轮廓之间的相对差异。

2 实验

2.1 实验配置及数据集

本文实验搭建的开发平台配置为: CPU 选用 intel(R) core(TM) i7-8700, GPU 选用 NVIDIA GeForce GTX 1070Ti, 操作系统选用 Ubuntu16.04TS, 操作系统选用 Ubuntu16.04TS, 强化学习框架为 Pytorch。

本文使用实验室已有的轮胎 X 光图像来自制数据集。对从轮胎制造厂获取的轮胎 X 光射线图片进行预处理, 减少图像标注过程产生的误差, 提高网络模型的训练效率。

(3) $(0, I)$, 本文利用它来对轮胎 X 光图像进行编码, 改进后的自编码器结构如图 2 所示。

输入层 隐藏层1 隐藏层2 输出层 输入层 隐藏层1 隐藏层2 输出层 输入层 隐藏层1 隐藏层2 输出层

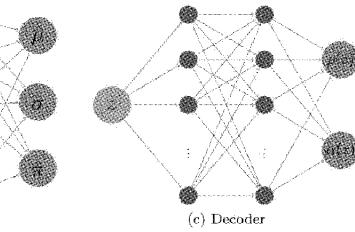


图 2 sVAE 拓扑结构图

如图 3 所示, 左图表示的是轮胎 X 光钢丝圈正常图像, 右图表示的是轮胎 X 光带束层正常图像。此类正常图像易获取, 对网络训练及后续工作提供很大便利。

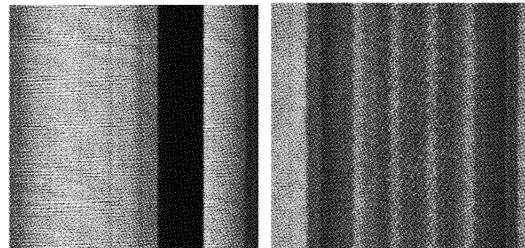


图 3 轮胎 X 光正常图像

由于工业提炼问题、人工操作不规范问题和生产机器波动问题的存在, 子午线轮胎在生产中会出现各种类型的异常。图 4 中, 依次为轮胎 X 光杂质类、气泡类、帘线分布不均匀类和零度散线类缺陷图像。

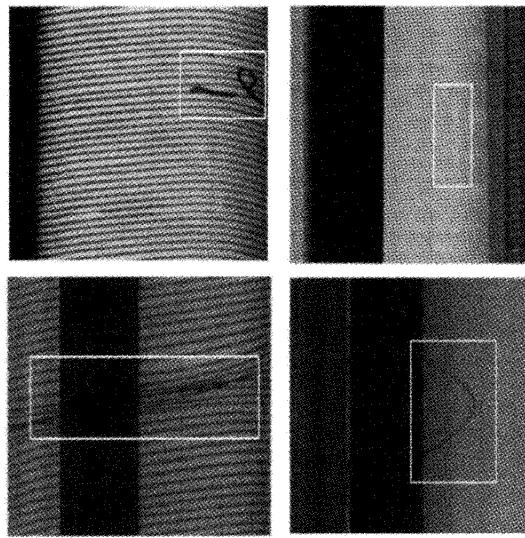


图 4 轮胎 X 光异常图像

本文主要使用 OpenCV 工具, 采用同态滤波的方法对图片进行降噪以及采用拉普拉斯算子对图像进行增强^[23]。

1) 同态滤波降噪

首先对输入图片做对数变换, 得到两个加性分量, 即:

$$\ln f(x, y) = \ln f_i(x, y) + \ln f_r(x, y) \quad (4)$$

通过对对数图像做傅里叶变换, 得到相应的频域表示式, 将图像从空间域转换到频域, 公式如下:

$$\begin{aligned} DFT[\ln f(x, y)] &= DFT[\ln f_i(x, y)] + \\ &DFT[\ln f_r(x, y)] \end{aligned} \quad (5)$$

根据实际需求设定频域滤波器, 通过缩小光强分量的变化范围, 弱化背景, 以及增强反射分量的变化, 凸显缺陷目标。经过傅里叶反变换, 最后对对数图像取指数, 输出图像 $g(x, y)$ 。

2) 拉普拉斯处理

拉普拉斯算子通过找到图像上某个目标像素到周围像素突变程度差异, 对图片进行锐化处理, 如式(6)所示。

$$\nabla^2[f(x, y)] = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2} \quad (6)$$

根据二阶微分方程定义, 可以得到:

$$\begin{aligned} (\partial^2 f)/(\partial x^2) &= f(x+1, y) + f(x-1, y) - 2f(x, y) \\ &\quad (7) \end{aligned}$$

$$\begin{aligned} (\partial^2 f)/(\partial y^2) &= f(x, y+1) + f(x, y-1) - 2f(x, y) \\ &\quad (8) \end{aligned}$$

结合式(6)~(8), 得到离散形式如式(9)所示, 拉普拉斯的计算结果为一个像素点的上下左右灰度值之和减去其自身 4 倍的灰度值。

$$\nabla^2 f = [f(x+1, y) + f(x-1, y) + f(x, y+1) + f(x, y-1) - 4f(x, y)] \quad (9)$$

最后得到锐化式(10):

$$g(x, y) = f(x, y) + c[\nabla^2 f(x, y)] \quad (10)$$

如图 5 所示, 图 5(a)表示的是工厂 X 光机拍摄的原始图像, 可见图片背景发暗, 胎线很难区分。经过图像降噪与增强处理之后的图片如图 5(b)所示, 明显可观测图像亮度增强, 胎线与背景分明, 人为地增大了轮胎缺陷与背景的差异性, 在很大程度上方便后续缺陷的标注工作的进行以及研究训练的推进。

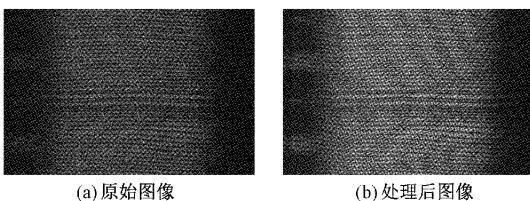


图 5 图像预处理结果对比

2.2 网络训练过程

1) 神经批采样器的训练

神经批采样器的目的是从数据集中 D 中采样一系列补丁 $\{P_1, P_2, \dots, P_N\}$, 以训练自编码器, 从而通过预测器判断数据是否具有鉴别的损失轮廓。为了实现这一点, 本文采用强化学习框架^[24], 它根据动作序列结束时获得的奖励为采取的行动分配学分。由于希望通过选择正确的训练批次来增强损失轮廓的对比度, 并帮助预测器定位异

常区域, 因此将奖励函数 R_{pred} 定义为预测损失的负值:

$$R_p = \begin{cases} -l_p, & t = N \\ 0, & \text{其他} \end{cases} \quad (11)$$

其中, 预测损失 l_p 被定义为加权二值交叉熵损失, 以解释数据中固有的不平衡:

$$l_p = -\frac{1}{K} \sum_k \frac{1}{WH} \sum_{w,H} \log \hat{y} + \alpha(1-y)\log(1-\hat{y}) \quad (12)$$

其中, K 表示批处理的大小, α 是异常像素和非异常像素之间的重加权因子, y 表示子集 D_t 中的轮胎真实注释, \hat{y} 在从预测器中获得的预测标签, 为了防止异常值较大的图像控制损失信号, 本文先取方程中维数为 $W \times H$ 的单个图像的平均值。

在实验中观察到如果直接使用标准的强化学习算法, 例如策略梯度算法, 从零开始优化神经批采样策略, 效果不尽如人意, 训练效率极低。故本文采取基于启发式的策略来训练神经批采样器, 即如果自动编码器以前从未见过异常特征, 那么它就不应该知道如何编码和解码异常信息, 从而导致异常图像的高损失。在子集 D_t 上进行行为克隆, 并通过检查相应的标签 y_{patch} 是否包含异常信息, 来为每个采样补丁分配一个奖励 R_{clone} 。神经批采样器有可能在非异常补丁附近的区域上重复采样, 为了防止这种情况, 本文设计神经批采样器通过包括一个小的覆盖奖励 R_{cover} 来覆盖数据的不同部分。为保证训练可以逐步进行, 首先优化 R_c 和 R_{cover} , 再优化 R_{pred} , 以获得异常和非异常之间的鉴别性损失轮廓。本文采用抽样的方法, 以获得更平稳地过渡:

$$\begin{aligned} R &= \beta(R_c + R_{cover}) + (1-\beta)R_p, \\ \beta &= \max(0, 1 - \frac{j}{L}) \end{aligned} \quad (13)$$

其中, L 是一个超参数, β 通过随着训练步骤数 j 的增加而更加强调 R_{pred} 来控制 R_{clone} 和真正的优化目标之间的权重。相比之下, 当网络刚刚开始训练时, R 主要由行为克隆 R_{clone} 所主导。这实现了使用行为克隆的密集奖励来引导神经批采样器的效果, 同时确保平稳过渡, 找到采样策略以提高预测结果。在定义了奖励函数后, 本文采用 REINFORCE^[25] 策略梯度算法来更新神经批采样器, 关于强化的更新规则可以写为:

$$\nabla_\theta J(\theta) = E_{\tau \sim \pi_\theta(\tau)} [\nabla_\theta \log \pi_\theta(\tau) r(\tau)] \quad (14)$$

其中, 采样策略 $\pi_\theta(\tau)$ 由神经批采样器参数化, $r(\tau)$ 是奖励的累加和, 期望使用 Monte Carlo 采样来近似。

2) 自编码器的训练

自编码器的唯一目的是提供各种各样的损失概况, 在神经批采样器产生一系列补丁后, 补丁被分成多个大小为 N 的小批次, 并输入自编码器。通过评估重建块 \hat{p}_i 和输入块 p_i 之间的重建损失 l_{ae} , 并将损失反向传播到自编码器中, 使自编码器分析重建损失值, 进而输出高价值损失

概况。为了生成不同概况的损失轮廓来训练预测器,本文使用随机权值初始化自编码器,并定期重新训练。在实际训练中这是在一个固定的数字(K)更新步骤之后完成的,其中当自编码器收敛时,权重更新变得很小。在每个更新步骤之后,评估数据集 D 的新的重建损失,并更新损失配置文件。新的重建损失值被用作神经批采样器的输入,而更新的标记子集 D_i 在FIFO缓冲区中的损失轮廓则用于训练预测器。

3) 预测器的训练

预测器基于损失轮廓进行预测,因此只需被训练成正常的分类器即可。虽然可以直接训练产生损失轮廓的自动编码器,但这容易导致批量样本在训练的时候产生的损失轮廓在类似的时间段高度相关的问题,使得梯度估计产生严重偏差,导致训练不稳定。因此,本研究将损失配置文件保存在一个FIFO缓冲区中,然后从其中随机取样,这就解决了这个问题,因为随机取样使得样本不再按时间分组在一起,而且更加独立。预测器输出预测标签后,计算加权二进制交叉熵损失来更新预测器,从图1中也可以看出相同的计算损失用于更新神经批处理采样器。

2.3 实验结果

本文改进后的编码器结构可以大大提高训练速度,实验中也大大改善图像重建后的清晰度,对纹理类目标检测效果尤佳,通过对比传统的AE、dAE、dVAE编码器结构,本研究提出的sVAE编码器结构性能优异,具体数据如表1(d 表示密度, s 表示空间)。表1中,avg表示的是每个样本的重建时间以s为单位的平均值,骰子得分可以看出自编码器在重建时的精度。

表1 各编码器模型性能对比表

模型	z	DICE ($\mu \pm \sigma$)	avg
AE	512	0.62764 ± 0.14617	0.01286
dAE	$16 \times 16 \times 64$	0.62636 ± 0.19780	0.01445
dVAE	512	0.56619 ± 0.17790	0.01297
sVAE	$16 \times 16 \times 64$	0.69227 ± 0.19585	0.01083

图6可以见得,在所有实验条件相同的情况下本文提出的sVAE模型确实能够达到符合本设计的满意效果。

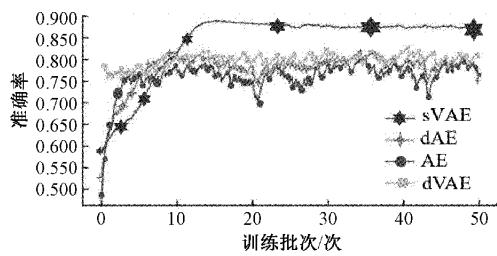


图6 各编码器重建精度对比

对本文提出的Nbsad-Net,使用自制的轮胎数据集针对轮胎气泡缺陷与几个经典分类网络做了对比实验,包括

U-Net、Fast RCNN、Fastr RCNN、R-CNN和SPP。

选用的数据集图片数量为1340张,气泡缺陷类型为390张,通过表2可以看出本文的网络有较好表现,在训练速度上仅次于Fastr RCNN,精度上达到新高,在召回率上也体现了本设计算法的优越性。

表2 各先进算法对轮胎气泡缺陷性能比较

算法	训练	测试	准确率	召回率	F1
	时间/h	时间/s	(acc)%	(Recall)%	
SPP	5	0.73	78.06	72.02	0.75
R-CNN	36	0.94	75.75	73.74	0.74
Fast-RCNN	4.5	0.58	76.13	79.32	0.78
Fastr-RCNN	3.6	0.26	77.41	80.64	0.79
U-Net	40	1.22	65.69	60.59	0.63
Nbsad-Net	3.7	0.86	84.87	87.27	0.86

如图7所示轮胎异常检测效果图,该图中3行分别表示轮胎X光原始图像、预测器预测异常图像和轮胎X光缺陷真实图像。可以看出本文提出的网络在轮胎气泡缺陷检测中效果比较突出,虽然预测器生成的预测缺陷图像有少量噪声,但并不影响整体得异常检测效果。

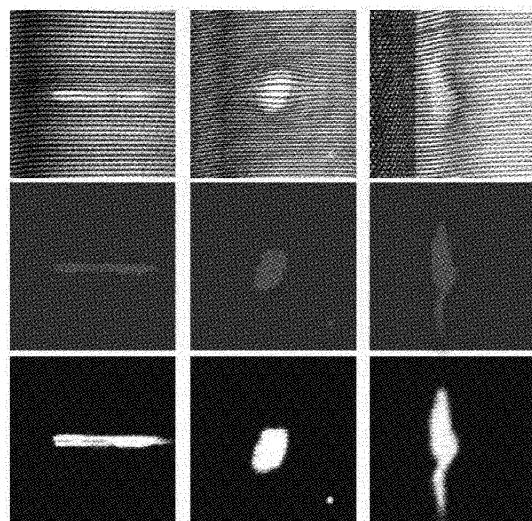


图7 异常检测效果图

图8为R-CNN、Faster-RCNN和本文提出的Nbsad-Net检测算法的loss曲线对比。结果显示在迭代次数达到200次时,本文提出的算法开始收敛,而另外两种算法仍然剧烈波动,可以见得本文提出的检测算法泛化能力更强,对轮胎的气泡类缺陷检测效果更好。

为了进一步展示Nbsad-Net普适性,增加多类别实验,选取300张杂质类缺陷X光轮胎样本图,1000张无缺陷X光轮胎样本图组成新的数据集。在此数据集下对比了Fastr RCNN、R-CNN、U-Net和Nbsad-Net的精度、效率和稳定性。实验数据结果如表3所示,所示结果皆为三

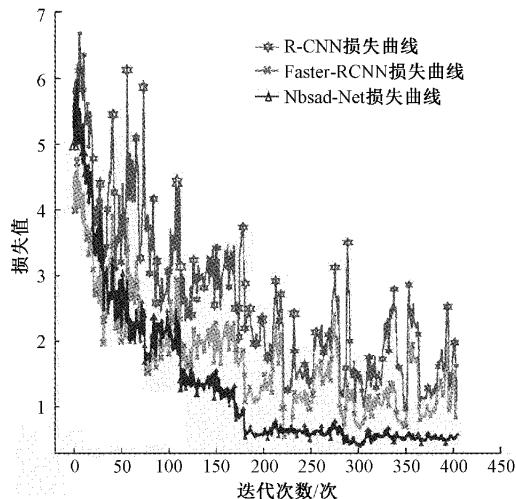


图 8 三种模型的损失曲线对比图

次实验的平均值和一倍标准差。

表 3 优化结束后统计结果

算法	准确率/%	耗时/min	标准差
R-CNN	98.39	1167.5	0.026 43
Fastr-RCNN	98.53	776.3	0.038 62
U-Net	98.56	1825.9	0.009 36
Nbsad-Net	98.75	219.4	0.006 71

表 3 中的准确率是 3 次实验精度的平均值;耗时是 3 次实验所需平均时间,该项指标反应该算法的时间性能;标准差则为 3 次实验准确率的标准差,该项指标体现了该算法的稳定性。各算法的准确率对比如图 9 所示。

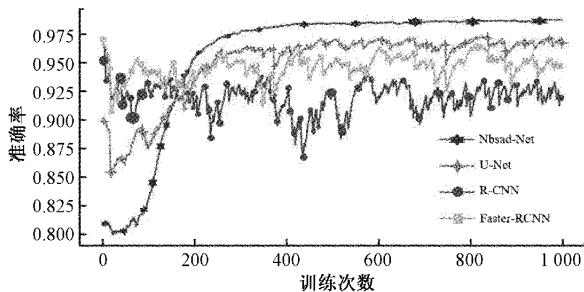


图 9 四种算法精度曲线对比图

3 结 论

针对异常检测中正负样本不均衡,且在图像空间做异常检测时由于 Auto-encoder 自身的泛化能力生成的样本不准确问题,本文提出在损失轮廓的特征空间做异常检测方法,使其更适用于自制的轮胎缺陷图像样本集。该算法通过使用神经批采样器、定期初始化的自动编码器和异常预测器来完成图像样本的分类和定位检测工作。并且为了实现异常图像检测准确率的提高,将分类判断标准从图

像空间转为特征空间,以损失值差异来完成分类定位。而且通过定期初始化批采样器以及重新训练自动编码器,形成多样化输入,从而更好的完成预测器的训练工作。通过自制测试集进行测试可以发现,即使测试集中异常样本占比比训练集更低,仍然可以表现出较好的性能,因此经过实验结果论证,Nbsad-Net 在本研究自制的轮胎缺陷图像样本集中具备适用性而且优于传统检测方法。

参 考 文 献

- [1] CHEN L C, PAPANDREOU G, KOKKIONS I, et al. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(4): 834-848.
- [2] 黄荷,俞亚萍,张之江.基于神经网络的密集人群视频异常检测[J].电子测量技术,2017,40(11):103-107.
- [3] LONG J, SHELHAMERE E, DARRELL T. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(4):640-651.
- [4] 周晓彦,王珂,李凌燕.基于深度学习的目标检测算法综述[J].电子测量技术,2017,40(11):89-93.
- [5] 陈晓荣,刘亚茹,石高辉.基于机器视觉的光纤几何参数检测算法设计[J].电子测量技术,2019,42(6):82-86.
- [6] 赵勇,李怀宇.基于通用距离测量的机器学习方法用于图像分类和聚类[J].电子测量技术,2017,40(9):136-140.
- [7] 蒋忠凌,廖俊必,黄玉波,等.基于机器视觉的化成箔缺陷在线检测系统设计[J].电子测量技术,2015,38(7):27-32.
- [8] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks [J]. Advances in Neural Information Processing Systems, 2014, 27(2): 2672-2680.
- [9] TSA B, PSA B, SMW B, et al. f-AnoGAN: Fast unsupervised anomaly detection with generative adversarial networks [J]. Medical Image Analysis, 2019, 56:30-44.
- [10] HYUNJON P, JONGYOUN N, BUMSUB H. Learning Memory Guided Normality for Anomaly Detection [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2020.
- [11] RAHMANII M, ATIA G. COHERENCE P: Fast, Simple, and Robust Principal Component Analysis [J]. IEEE Transactions on Signal Processing, 2017, 65(23):6260-6275.

- [12] RAVANBKHSH M, SANGINRTO E, NABI M, et al. Training adversarial discriminators for cross-channel abnormal event detection in crowds[C]. 2019 IEEE Winter Conference on Applications of Computer Vision(WACV), IEEE, 2019.
- [13] SABOKROU M, KHALOOEI M, FATHY M, et al. Adversarially learned one-class classifier for novelty detection[C]. IEEE/CVF Conference on Computer Vision & Pattern Recognition, IEEE, 2018.
- [14] 崔雪红,刘云,王传旭,等.基于卷积神经网络的轮胎缺陷 X 光图像分类[J].电子测量技术,2017,40(5):168-173.
- [15] YANG B, SHAO Q M, LI W B, et al. Deep convolutional neural networks controlled by discriminatively orthogonal feature generation and its application[J]. Acta Electronica Sinica, 2018, 46(10): 2376-2383.
- [16] FEIFEI L, DENG J, LI K. ImageNet: Constructing a large-scale image database [J]. Journal of Vision, 2010,9(8):1037.
- [17] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. IEEE, IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2016.
- [18] BÖTTGER T, ULRICH M. Real-time texture error detection on textured surfaces with compressed sensing[J]. Pattern Recognition and Image Analysis, 2016,26(1):88-94.
- [19] PEIBIN C, TAO M, XU Q. Data-efficient semi-supervised learning by reliable edge mining[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2020.
- [20] CARRERA D, MANGANINI F, BORACCHI G, et al. Defect detection in SEM images of nanofibrous materials [J]. IEEE Transactions on Industrial Informatics, 2017, 13(2):551-561.
- [21] 林荣霞.基于强化学习的双足机器人的实时避障位置控制[J].电子测量技术,2019,42(10):33-37.
- [22] 孙靖文,王敏.强化组合式生成对抗网络[J].电子测量技术,2019,42(4):99-103.
- [23] 刘韵婷,于清淞,李绅科,等.基于深度学习的多模型融合图像智能检测方法研究[J].电子测量技术,2021, 44(20):168-174.
- [24] SUTTON R, BARTO A. Reinforcement learning: An introduction (Adaptive computation and machine learning) [C]. IEEE Transactions on Neural Networks, 1998.
- [25] RONALD J, WILLIAMS. Simple statistical gradient-following algorithms for connectionist reinforcement learning[J]. Machine Learning, 1992,8(3-4):229-256.

作者简介

刘韵婷,博士,副教授,主要研究方向为人工智能、传感器网络、数据分析等。
E-mail:liuyunting0224@163.com